



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

MAÍRA ARAÚJO DE SANTANA

**SISTEMAS INTELIGENTES PARA APOIO AO DIAGNÓSTICO DO CÂNCER DE MAMA
USANDO IMAGENS MAMOGRÁFICAS E TERMOGRÁFICAS**

Recife

2020

MAÍRA ARAÚJO DE SANTANA

**SISTEMAS INTELIGENTES PARA APOIO AO DIAGNÓSTICO DO CÂNCER DE MAMA
USANDO IMAGENS MAMOGRÁFICAS E TERMOGRÁFICAS**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Biomédica do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Engenharia Biomédica.

Área de concentração: Computação Biomédica.

Orientador: Prof. Dr. Wellington Pinheiro dos Santos.

Recife

2020

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

S232s Santana, Maíra Araújo de.
Sistemas inteligentes para apoio ao diagnóstico do câncer de mama usando imagens mamográficas e termográficas / Maíra Araújo de Santana - 2020.
126 folhas, il., gráfs., tabs.

Orientador: Prof. Dr. Wellington Pinheiro dos Santos.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Biomédica, 2020.
Inclui Referências e Apêndice.

1. Engenharia Biomédica. 2. Câncer de Mama. 3. Mamografia. 4. Termografia. 5. Inteligência artificial. 6. Sistemas Inteligentes. 7. Diagnóstico. 8. Wavelets. I. Santos, Wellington Pinheiro dos (Orientador). II. Título.

UFPE

610.28 CDD (22. ed.) BCTG/2020-198

MAÍRA ARAÚJO DE SANTANA

**SISTEMAS INTELIGENTES PARA APOIO AO DIAGNÓSTICO DO CÂNCER DE MAMA
USANDO IMAGENS MAMOGRAFICAS E TERMOGRAFICAS**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Biomédica do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Engenharia Biomédica.

Aprovada em: 18/02/2020.

BANCA EXAMINADORA

Prof. Dr. Wellington Pinheiro dos Santos (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Ricardo Emmanuel de Souza (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Sidney Marlon Lopes de Lima (Examinador Externo)
Universidade Federal de Pernambuco

Dedico a minha mãe, Inês Helena, e minhas avós, Maria e Selma, por serem esses exemplos inspiradores de mulheres fortes, generosas e gratas.

AGRADECIMENTOS

A Deus, por ser e estar, sempre.

Aos meus pais, Inês e Heleno, pelos incentivos e, principalmente, por sempre me ensinarem a buscar algo que me mova, pelo qual eu tenha paixão, porque disso que vem a satisfação, pessoal e profissional, e a alegria de ser. Acho que estou no caminho certo, graças a vocês.

Aos meus avós, Selma, Edilson, Maria e Heleno, pelo cuidado, acolhimento, torcida e interesse. Sou extremamente grata por conhecê-los, conviver e aprender com vocês. Junto com eles agradeço pelo apoio de toda a família.

A Ícaro, por me ensinar a ser mais, pelos “puxões de orelha” inocentes, pelas escutas e pelos comentários críticos, mesmo quando ainda não entende muito bem o conteúdo.

A Karol, pela companhia, incentivo, cuidado e por ser comigo, em todos os momentos.

A Eli, pelo cuidado, atenção e tranquilidade diários.

Ao meu orientador, Wellington Pinheiro, pelo cuidado, carinho e confiança. Pessoa que, além de ser um educador, é esse “paizão”, alguém para quem sei que posso recorrer, mesmo que só para conversar sobre a vida. Já escuto o “isso não se agradece”, mas, mesmo assim, meu muito obrigada também pela disponibilidade, dedicação e ensinamentos de sempre.

A Manu, Paulo, Cacá, Gabi, Bernardo, Isinha, Rodrigo, Juliana, Amanda, Jessiane, Giselle, Aninha, Duda, Nathaly, Rafa, Emerson, Milton, Kátia, Ana Júlia, Stelio e tantos outros seres iluminados que essa vida me deu. Sem vocês, de perto ou de longe, a vida não teria tantas cores.

A Lau, Vanni, Mayara, Mamari e a todo o “País Gesttus”, por esse jeitinho incrível que só vocês têm de perceber, incluir, incentivar, renovar, valorizar, cuidar e ser refúgio, em qualquer circunstância.

Aos professores Ricardo Emmanuel e Sidney Lima pela atenção e contribuições para essa dissertação.

A todo o Departamento de Engenharia Biomédica, em especial aos professores Ricardo Yara, Marcelo Cairrão, Edval Santos e Rosa Dutra, pelos conhecimentos compartilhados; e aos servidores Juliana e Rangel, pela disponibilidade, cuidado e eficiência.

Conseguir produzir flores num terreno agreste, flores que durem e resistam, não é tarefa para uma geração. [...] Pressupõe continuidade de esforços. Exige um processo de tentativa e erro, uma seleção cuidadosa de sementes, um uso sábio de técnicas diversas, um equilíbrio delicado entre poda e adubação, pacientes exercícios de adaptação ao ambiente, redescoberta das espécies locais. Em outras palavras, pede um talento especial, muita força de vontade e muito amor, paralelamente a um bocado de trabalho e informação. Precisa de muita paixão e disciplina férrea.

Mas vale a pena. O resultado desse trabalho continuado pode ser uma alegria para sempre, aquela coisa toda feita de beleza, de que falava o poeta. Não porque nos jardins se possam colher louros para fazer as coroas que na Grécia antiga representavam as mais altas honras que um mortal podia receber. Mas porque nos jardins se podem plantar as sementes daquilo que um dia trará a beleza das flores, o alimento dos frutos, a proteção da sombra, o oxigênio que nos permite viver (MACHADO, 2001).

RESUMO

O câncer de mama já é a forma mais mortal de câncer entre mulheres. Muito embora sua ocorrência não seja função do nível de desenvolvimento econômico e social, a mortalidade do câncer de mama está diretamente relacionada a estratégias de prevenção da doença, tais como campanhas educativas e tecnologias para apoio ao diagnóstico precoce do câncer de mama por meio de ferramentas de detecção e classificação de lesões de mama. O padrão na prática clínica para apoio ao diagnóstico do câncer de mama por imagem ainda é a mamografia por raios-x. No entanto, essa técnica tem como desvantagens, além do custo, o uso de radiações ionizantes, que por sua vez podem ainda estar relacionados a fatores causadores de câncer, e a impossibilidade de utilização em pacientes mais jovens. A termografia de mama se baseia nas mudanças metabólicas resultantes do surgimento de células alteradas no tecido mamário, que por sua vez resultam em modificações na distribuição de temperatura da mama. Ela tem se estabelecido como técnica complementar à mamografia, servindo como sistema de triagem, possibilitando a detecção precoce de lesões de mama e diminuindo a mortalidade associada à doença. Sistemas inteligentes, baseados na identificação de padrões em imagens com lesões de mama, aliados à combinação entre descritores de forma e de textura e à decomposição em série de Wavelets, aliados a máquinas de aprendizado conexionistas, têm se mostrado bastante eficientes na automatização da análise mamográfica. É possível tomar essa metodologia como ponto de partida para a automatização da análise de termogramas de mama. Esta proposta tem como objetivo investigar diversas abordagens para desenvolver um sistema de apoio ao diagnóstico do câncer de mama para a classificação de regiões de interesse em mamografias e termogramas de mama. A solução foi validada usando duas bases de imagens clínicas reais, sendo uma de termogramas e outra de regiões de interesse de mamografias. A base de imagens termográficas foi obtida em projetos de pesquisa-ação desenvolvidos junto a movimentos sociais e ao Hospital das Clínicas da UFPE. A base de imagens de mamografias adotada é a IRMA, desenvolvida na Aachen University of Technology, Alemanha, usando as bases públicas DDSM e MIAS, e cedida para uso acadêmico pelo Prof. Thomas Deserno. Excelentes desempenhos foram obtidos utilizando descritores baseados em Wavelets, tanto para detecção da existência de lesões quanto para a classificação do tipo de lesão presente nas imagens de ambas as técnicas. Para os termogramas de mama, foi obtida acurácia média em torno de 99% e mais de 0,95 de índice kappa médio. Resultados acima de 95% de acurácia média, com índice kappa médio em torno de 0,95, foram obtidos para a classificação das imagens contendo regiões de interesse de mamografias.

Palavras-chave: Câncer de mama. Mamografia. Termografia. Inteligência artificial. Sistemas inteligentes. Diagnóstico. Wavelets.

ABSTRACT

Breast cancer is already the deadliest type of cancer among women. Although its incidence is not a function of the level of economic and social development of a country, breast cancer mortality is directly related to disease prevention strategies, such as educational campaigns and technologies to support early diagnosis of breast cancer through tools to detect and classify breast lesions. The gold standard in clinical practice for breast cancer diagnosis by imaging is still x-ray mammography. However, this technique has some disadvantages: the high cost, the use of ionizing radiation, which is a cancer-causing factor itself, and the impossibility of use in younger patients. Breast thermography is based on metabolic changes resulting from the presence of altered cells in the breast tissue, resulting in changes in the temperature distribution in the breast surface. It is being established as a complementary technique to mammography, as a screening system, enabling early detection of breast lesions and decreasing mortality associated to the disease. Intelligent systems based on pattern identification in images of breast lesion, combined to the use of shape and texture descriptors, as well as the Wavelets serial decomposition, combined to connectionist learning machines, have been shown to be very efficient in automating mammographic analysis. You can take this method as a starting point for automating breast thermogram analysis. This proposal aims to investigate several approaches to develop a support system for breast cancer diagnosis, by classifying regions of interest in mammograms and breast thermograms. The solution was validated using two real clinical image databases, one of thermograms and one of regions of interest of mammograms. The thermographic images database was obtained from action research projects developed with social movements and the Hospital das Clínicas from UFPE. We adopted IRMA database of mammographic images, which was developed at Aachen University of Technology, Germany, using the DDSM and MIAS public databases, and provided for academic use by Prof. Thomas Deserno. Excellent performances were obtained using Wavelet-based descriptors, both for detecting the existence of lesions and for the classification of the type of lesion present in the images from both techniques. For breast thermograms, average accuracy was obtained around 99% and more than 0.95 for average kappa statistic. Results above 95% of average accuracy, with average kappa statistic around 0.95, were obtained for the classification of images containing regions of interest of mammograms.

Keywords: Breast cancer. Mammography. Thermography. Artificial intelligence. Intelligent systems. Diagnosis. Wavelets.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 – Desenho esquemático da anatomia da mama | 19 |
| Figura 2 – Estrutura básica de um mamógrafo | 22 |
| Figura 3 – Faixa de radiação captada por câmeras térmicas no espectro eletromagnético | 23 |
| Figura 4 – Exemplos de câmeras térmicas | 25 |
| Figura 5 – Proposta final do trabalho | 44 |
| Figura 6 – Filtros para uma vizinhança-8 | 46 |
| Figura 7 – Esquema geral da DWNN | 47 |
| Figura 8 – Método utilizado para validação da máquina de aprendizado | 47 |
| Figura 9 – Exemplos de imagens de cada uma das possíveis classes do banco de dados de termografias de mama. No canto superior esquerdo encontra-se um exemplo da classe sem lesão; logo ao seu lado, no canto superior direito, está uma imagem contendo lesão do tipo cística. As imagens inferiores esquerda e direita são, respectivamente, de lesões benigna e maligna. | 48 |
| Figura 10 – Posições utilizadas na realização do exame de termografia de mama. Na porção superior esquerda estão T1 e T2, que são imagens frontais de ambas as mamas, com os braços em posicionamentos distintos. MD apresenta a imagem frontal apenas da mama direita, enquanto que ME mostra a mama esquerda nessa mesma posição. As imagens inferiores são de vistas laterais, sendo LEMD e LEME imagens da lateral externa das mamas direita e esquerda, respectivamente; LIMD e LIME correspondem à visão lateral interna de cada mama. | 49 |
| Figura 11 – Procedimentos de preparação para a aquisição das imagens termográficas | 49 |
| Figura 12 – Aparato mecânico utilizado na sala de aquisição. Em (1) encontram-se os trilhos utilizados para mover o suporte da câmera (2) em direção à paciente, posicionada na cadeira giratória apresentada em (3); as barras em (4) são utilizadas para o posicionamento dos braços durante o exame. | 50 |
| Figura 13 – Mamogramas dos diferentes tecidos mamários: (a) adiposo (tipo I), (b) fibroglandular (tipo II), (c) heterogeneamente denso (tipo III) e (d) extremamente denso (tipo IV). | 52 |
| Figura 14 – Exemplos de imagens da base IRMA | 52 |
| Figura 15 – Janela de inicialização do SID-Termo | 54 |
| Figura 16 – Janela do SID-Termo para seleção dos atributos | 55 |
| Figura 17 – Fluxo de usabilidade do sistema proposto | 58 |

| | |
|--|----|
| Figura 18 – Boxplot dos resultados de (a) acurácia e (b) kappa utilizando Haralick e Zernike para extração de atributos e imagens de Termografia | 60 |
| Figura 19 – Boxplot dos resultados de (a) acurácia e (b) kappa utilizando DWNN para extração de atributos e imagens de Termografia | 62 |
| Figura 20 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando DWNN para extração de atributos e imagens de Mamografia de mamas predominante adiposas (tipo I). | 67 |
| Figura 21 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando DWNN para extração de atributos e imagens de Mamografia de mamas com todas as constituições teciduais (3 classes). | 68 |
| Figura 22 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando Haralick e Zernike para extração de atributos e imagens de Mamografia de mamas predominante adiposas (tipo I). | 70 |
| Figura 23 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando Haralick e Zernike para extração de atributos e imagens de Mamografia de mamas com todas as constituições teciduais (3 classes). | 71 |
| Figura 24 – Janela para carregamento da imagem no sistema de apoio ao diagnóstico do Câncer de Mama. Em (a) está a janela para carregamento de imagens de Termografia de mama e em (b) pode ser visualizado o carregamento de uma imagem de região de interesse de Mamografia. | 72 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 – Momentos de Haralick | 28 |
| Tabela 2 – Momentos de Zernike | 29 |
| Tabela 3 – Funções de <i>kernel</i> para SVM | 31 |
| Tabela 4 – Funções de <i>kernel</i> para ELM | 32 |
| Tabela 5 – Resumo dos trabalhos relacionados | 41 |
| Tabela 6 – Quantidade de imagens por classe | 50 |
| Tabela 7 – Organização das bases de dados de mamografia | 53 |
| Tabela 8 – Configuração dos classificadores | 56 |
| Tabela 9 – Exemplo de matriz de confusão | 57 |
| Tabela 10 – Resultados de acurácia e kappa utilizando Haralick e Zernike para extração de atributos e imagens de Termografia | 60 |
| Tabela 11 – Resultados de acurácia e kappa utilizando DWNN com função média para extração de atributos e imagens de Termografia | 61 |
| Tabela 12 – Melhores configurações para cada base de dados dos experimentos com Mamografia utilizando DWNN. | 64 |
| Tabela 13 – Resultados de acurácia e kappa utilizando DWNN para representar imagens de Mamografia de diferentes tipos de tecidos | 65 |
| Tabela 14 – Resultados de acurácia e kappa utilizando DWNN para representar imagens de Mamografia com todos os tipos de tecido | 66 |
| Tabela 15 – Resultados de acurácia e kappa utilizando Haralick e Zernike para representar imagens de Mamografia com as bases de dados com mamas de tecido adiposo e com todos os tipos de tecidos e três classes. | 69 |
| Tabela 16 – Matriz de confusão para o melhor e o pior resultados utilizando a base de Termografia de mama | 71 |
| Tabela 17 – Métricas de sensibilidade, especificidade e eficiência da abordagem utilizando a base de Termografia de mama | 72 |
| Tabela 18 – Matriz de confusão para o melhor e o pior resultados utilizando a base imagens de Mamografia com mamas do tipo II. | 73 |
| Tabela 19 – Métricas de sensibilidade, especificidade e eficiência da abordagem utilizando a base de Mamografia | 73 |

SUMÁRIO

| | | |
|------------|--|-----------|
| 1 | INTRODUÇÃO | 14 |
| 1.1 | Motivação e Justificativa | 14 |
| 1.2 | Objetivos | 17 |
| 1.3 | Organização do trabalho | 17 |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 19 |
| 2.1 | Anatomia e Fisiologia da Mama | 19 |
| 2.2 | Câncer de Mama | 20 |
| 2.2.1 | Métodos de diagnóstico | 21 |
| 2.2.2 | Mamografia | 22 |
| 2.2.3 | Termografia de Mama | 23 |
| 2.3 | Sistemas Inteligentes em Saúde | 24 |
| 2.4 | Princípios de Reconhecimento de Padrões | 25 |
| 2.4.1 | Métodos de Extração de Atributos | 27 |
| 2.4.2 | Métodos de Classificação | 29 |
| 3 | TRABALHOS RELACIONADOS | 34 |
| 3.1 | Termografia de Mama | 34 |
| 3.2 | Mamografia | 37 |
| 3.3 | Avaliação de ambas as técnicas | 39 |
| 3.4 | Considerações | 40 |
| 4 | PROPOSTA: SISTEMAS INTELIGENTES PARA APOIO AO DIAGNÓSTICO DO CÂNCER DE MAMA | 44 |
| 4.1 | Deep-Wavelet Neural Network | 44 |
| 4.2 | Experimentos propostos | 46 |
| 4.2.1 | Bases de dados | 47 |
| 4.2.1.1 | <i>Termografia</i> | 47 |
| 4.2.1.2 | <i>Mamografia</i> | 51 |
| 4.2.2 | Extração de atributos | 53 |
| 4.2.3 | Classificação | 54 |
| 4.3 | Considerações | 57 |
| 5 | RESULTADOS E DISCUSSÃO | 59 |
| 5.1 | Resultados Termografia | 59 |
| 5.1.1 | Momentos de Haralick e Zernike e Termografia | 59 |
| 5.1.2 | Deep-Wavelet Neural Network e Termografia | 61 |

| | | |
|------------|--|-----------|
| 5.2 | Resultados Mamografia | 62 |
| 5.2.1 | Deep-Wavelet Neural Network e Mamografia | 63 |
| 5.2.2 | Momentos de Haralick e Zernike e Mamografia | 66 |
| 5.3 | Protótipo de um Sistema de Apoio ao Diagnóstico do Câncer de Mama | 68 |
| 5.4 | Considerações | 69 |
| 6 | CONCLUSÃO | 74 |
| 6.1 | Dificuldades encontradas | 76 |
| 6.2 | Contribuições | 76 |
| 6.3 | Trabalhos futuros | 80 |
| | REFERÊNCIAS | 81 |
| | APÊNDICE A – TABELAS DE RESULTADOS EXPANDIDAS | 89 |

1 INTRODUÇÃO

Este capítulo aborda as principais motivações para o desenvolvimento do presente estudo, apresentando a problemática do câncer de mama, bem como os principais desafios atualmente existentes para o diagnóstico dessa doença. São também descritos os objetivos geral e específicos e, por fim, a organização desse documento.

1.1 Motivação e Justificativa

O câncer, em todas as suas formas, se tornou um dos maiores problemas de saúde pública do século XX em todo o mundo, independente dos níveis de desenvolvimento social e econômico das diferentes nações do globo (GROOT et al., 2006). De todas as formas de câncer, o de mama é a mais perigosa de carcinoma para mulheres mais velhas e de meia idade (GROOT et al., 2006), sendo também a forma mais comum de câncer entre mulheres (GROOT et al., 2006). O câncer de mama está entre os cinco tipos de câncer mais frequente no mundo (SHRIVASTAVA et al., 2017). Só no Brasil ele corresponde a cerca de 28% dos novos casos de câncer por ano. Apesar de, no geral, haver um bom prognóstico, esta doença é ainda responsável pelo maior índice de mortalidade por câncer na população feminina (GONÇALVES et al., 2016). De acordo com o Ministério da Saúde (MS), a detecção precoce de tumores, que consiste na identificação do câncer em estágios iniciais, é essencial no sentido de reduzir a mortalidade pela doença (GONÇALVES et al., 2016).

O câncer de mama vem se proliferando tanto em países ditos desenvolvidos quanto em países subdesenvolvidos e em desenvolvimento, acompanhando o aumento da expectativa de vida média da população, o inchaço das cidades, o esvaziamento gradual da zona rural e a adoção de novas formas de consumo, mais agressivas (GROOT et al., 2006). Muito embora o risco de câncer de mama possa ser diminuído por meio de estratégias preventivas, tais como a efetivação de campanhas educativas que estimulam a inspeção visual e o toque das mamas, mesmo uma boa e bem aceita campanha de prevenção não pode eliminar a maioria dos tipos de câncer de mama, pois acabam sendo diagnosticados muito tardiamente (GROOT et al., 2006). Logo, a existência e a disponibilidade de tecnologias para detecção precoce do câncer de mama nos sistemas públicos de saúde podem contribuir para aumentar as chances de cura e opções de tratamento (GROOT et al., 2006).

Atualmente, o principal método utilizado para a identificação de lesões na mama é a mamografia, que consiste em um escaneamento da mama através da aplicação de raios-x (MAITRA; BANDYOPADHYAY, 2017). No entanto, apesar dos avanços tecnológicos que acarretaram na melhoria da técnica e da qualidade das imagens, ainda existem situações em

que a mamografia é insuficiente para identificar as lesões, principalmente em seus estágios iniciais, quer seja por limitações do próprio método ou por inconsistências no diagnóstico dos especialistas devido à grande variabilidade dos casos clínicos (BANDYOPADHYAY, 2010). Por esse motivo, investigações utilizando métodos como ultrassonografia, ressonância magnética e exames clínicos em geral vêm sendo associadas aos resultados obtidos através da mamografia, no intuito de tornar o diagnóstico mais robusto (GONÇALVES et al., 2016). Mesmo com a combinação dessas técnicas, o Ministério da Saúde ainda afirma que a maioria dos casos corretamente identificados atualmente é de lesões em estágio avançado, o que dificulta o tratamento, quando é possível fazê-lo, e aumenta a necessidade de realizar procedimentos invasivos como biópsias e mastectomias (retirada total ou parcial da mama) (GONÇALVES et al., 2016).

Apesar de a mamografia ainda ser o método não invasivo mais confiável em uso na prática clínica, a termografia de mama vem despontando como um interessante complemento à análise mamográfica. A aquisição de imagens de termografia de mama consiste em um processo não invasivo, indolor, não sujeito à exposição a radiações ionizantes nem exigindo a compressão da mama da paciente, tal como ocorre na aquisição de imagens mamográficas. Métodos alternativos como a termografia de mama vêm sendo explorados como ferramentas auxiliares para o diagnóstico precoce do câncer mamário.

A termografia se baseia na aquisição de imagens, registradas através de uma câmera de infravermelho, que apresentam a distribuição de temperatura na região. O funcionamento geral da câmera consiste na captura da radiação infravermelha emitida pela superfície de interesse. A técnica possibilita a investigação de efeitos fisiológicos causados por doenças a partir da análise da variação de temperatura na região, no caso da existência de células cancerígenas, o crescimento metabólico interfere no fluxo sanguíneo, resultando no aumento da temperatura superficial da região lesionada. Estudos afirmam que a utilização da termografia pode antecipar em até 10 (dez) anos o diagnóstico de lesões na mama, pois a partir dela podem ser extraídas informações relacionadas a alterações fisiológicas, as quais tendem a surgir antes das anatômicas (ETEHADTAVAKOL; NG, 2013). Além disso, o uso da termografia de mama como método de triagem pode vir a reduzir bastante a exposição desnecessária de pacientes às radiações ionizantes e a outros exames.

Nesse sentido, a combinação de conhecimento especialista com métodos de análise digital de imagens em termografias de mama pode contribuir para a melhoria do diagnóstico, do prognóstico e do tratamento do câncer de mama (SALMERI et al., 2009; NORDIN et al., 2008; BANDYOPADHYAY, 2010). Assim como em outras abordagens de apoio ao diagnóstico por imagem (SANTOS et al., 2006a; SANTOS et al., 2006b; SANTOS et al., 2008; SANTOS; SOUZA; SANTOS-FILHO, 2007; SANTOS et al., 2008; SANTOS et al., 2008b; SANTOS et al., 2009c; SANTOS et al., 2009b; SANTOS et al., 2009a; SANTOS et al., 2008a; SANTOS et al., 2009; SANTOS; ASSIS; SOUZA, 2009), a extração de atributos

é um aspecto essencial na obtenção de bons resultados na análise de imagens de mama (NORDIN et al., 2008; BANDYOPADHYAY, 2010; BOQUETE et al., 2012; BOUJELBEN et al., 2009; MASCARO et al., 2009). O uso de técnicas de CBIR (*Content-Based Image Retrieval*, Recuperação de Imagens Baseada em Contexto) na representação dos atributos pode contribuir para análises mais precisas (LEW et al., 2006). Diversos trabalhos têm explorado esses aspectos e atingido bons resultados (AZEVEDO et al., 2015a; CORDEIRO; BEZERRA; SANTOS, 2017; LIMA; SILVA-FILHO; SANTOS, 2016; CORDEIRO; SANTOS; SILVA-FILHO, 2017; CORDEIRO; SANTOS; SILVA-FILHO, 2016b; CORDEIRO; SANTOS; SILVA-FILHO, 2016a; CORDEIRO; SANTOS; SILVA-FILHO, 2013; AZEVEDO et al., 2015b; LIMA et al., 2015; RODRIGUES et al., 2019; CRUZ; CRUZ; SANTOS, 2018; VASCONCELOS; SANTOS; LIMA, 2018).

No geral, a acurácia no diagnóstico utilizando as técnicas convencionais está em torno de 70-90%, percentual esse que diminui para menos de 60% quando se trata de mulheres abaixo dos 40 anos (URBAIN, 2005). Quando se trata da termografia de mama, embora esteja sendo utilizada e estudada em vários países ao redor do mundo (ETEHAD-TAVAKOL; NG, 2013), essa técnica é ainda escassamente difundida no Brasil e, por esse motivo, existem poucos especialistas capacitados para extrair informações relevantes a partir da análise das imagens termográficas. Esses fatores, associados à vasta variabilidade dos casos clínicos, tornam a identificação e diferenciação de lesões mamárias a partir de imagens uma tarefa difícil aos olhos humanos, principalmente quando se trata de lesões pequenas ou de difícil acesso. Ao se verem diante desses desafios, diversas pesquisas têm se dedicado ao estudo e desenvolvimento de sistemas inteligentes de classificação para serem usados como assistentes de especialistas, no intuito de otimizar a acurácia do diagnóstico.

Assim sendo, levando em consideração o relativo sucesso de abordagens relacionadas à inteligência artificial e a necessidade de soluções que possibilitem o diagnóstico precoce do câncer de mama, o presente trabalho propõe desenvolver um sistema computacional de suporte ao diagnóstico a partir da análise de imagens de mamografia e termografia de mama. Tal sistema busca identificar e classificar as lesões mamárias em seus estágios iniciais, reduzindo, portanto, custos com exames, tratamentos e, principalmente, o índice de mortalidade por câncer de mama. Essa solução estará disponível na forma de serviço *web*, através do qual as imagens poderão ser enviadas à nuvem e o sistema emitirá, automaticamente, um laudo.

O presente estudo propõe ainda uma nova ferramenta computacional para extração de atributos de imagens, a *Deep-Wavelet Neural Network* (DWNN), que consiste em uma arquitetura profunda e sem treinamento, inspirada na decomposição em Wavelet em múltiplos níveis.

1.2 Objetivos

O objetivo principal do presente trabalho é o de desenvolver um sistema inteligente para apoio ao diagnóstico não invasivo do câncer de mama por meio da análise automatizada de imagens de mamogramas e termogramas de mama. Tal sistema busca identificar e classificar as lesões mamárias em seus estágios iniciais, reduzindo, portanto, custos com exames, tratamentos e, principalmente, o índice de mortalidade por câncer de mama. Essa solução será disponível na forma de serviço web, através do qual as imagens poderão ser enviadas à nuvem e o sistema emitirá, automaticamente, um laudo.

Este projeto tem os seguintes objetivos específicos:

- a) Desenvolver um sistema de representação de imagens termográficas por meio de características de forma e textura e definir quais dessas características são suficientes para o diagnóstico por imagem, investigando atributos que conjuguem espaço e frequência;
- b) Desenvolver um sistema de representação de imagens mamográficas por meio de características de forma e textura e definir quais dessas características são suficientes para o diagnóstico por imagem, investigando atributos que conjuguem espaço e frequência;
- c) Construir uma máquina de aprendizado conexionista para classificação de imagens termográficas de mama, com habilidade de detectar e classificar lesões de mama;
- d) Construir uma máquina de aprendizado conexionista para classificação de áreas de interesse em imagens mamográficas, com habilidade de detectar e classificar lesões de mama;
- e) Desenvolver uma solução para triagem e apoio ao diagnóstico do câncer de mama.

1.3 Organização do trabalho

Inicialmente é apresentada uma fundamentação teórica de alguns conceitos utilizados como base para o desenvolvimento do estudo aqui proposto. Em seguida, no Capítulo 3, são destacados trabalhos relevantes na área de diagnóstico do câncer de mama utilizando ferramentas computacionais e imagens de mamografia e de termografia de mama. O Capítulo 4 expõe a proposta desse estudo, que consiste na avaliação de sistemas inteligentes para apoio ao diagnóstico do câncer de mama. Logo em seguida vem o capítulo de resultados, onde é realizada uma avaliação quantitativa e qualitativa das técnicas exploradas. Por fim, o Capítulo 6 apresenta as conclusões alcançadas, assim como uma breve descri-

ção da contribuição científica proveniente do trabalho, além de serem pontuadas algumas possibilidades de trabalhos futuros.

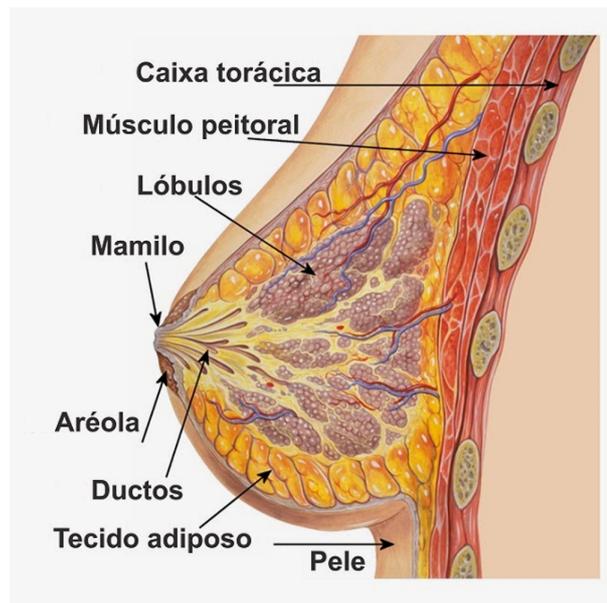
2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo é dedicado ao estudo dos conceitos teóricos importantes para orientar a análise e interpretação desta pesquisa.

2.1 Anatomia e Fisiologia da Mama

A mama humana consiste em uma glândula exócrina situada na porção anterior do tórax e cuja principal função está relacionada à produção, ao armazenamento e à liberação do leite materno. As mamas são compostas por estroma e lobos, sendo esses últimos formados a partir de duas outras estruturas: os lóbulos e os ductos. A Figura 1 ilustra a organização anatômica das mamas.

Figura 1 – Desenho esquemático da anatomia da mama



Fonte: Adaptado de Maes (2019).

Constituídos por conjuntos de 10 a 100 unidades alveolares, os lóbulos são glândulas produtoras de leite, enquanto que os ductos consistem em pequenos tubos responsáveis pelo transporte do leite até o mamilo, por onde é excretado. O estroma, por sua vez, é uma combinação de tecido adiposo, tecido fibroglandular, vasos sanguíneos e vasos linfáticos que envolve as demais estruturas mamárias.

A constituição do estroma é essencial para a determinação da densidade mamária, pois ela está relacionada à proporção dos tecidos adiposo e fibroglandular presente nas mamas. No geral, mulheres mais jovens possuem um predomínio de tecido fibroglandular em relação ao adiposo e, por esse motivo, apresentam mamas mais densas. Com o passar

dos anos, a mama feminina passa por um fenômeno denominado liposs substituição, onde ocorre uma gradual redução dos componentes fibroglandulares de forma simultânea ao aumento dos componentes adiposos. A liposs substituição ocorre naturalmente, mas pode ser acelerada caso a mulher engravide ou amamente ou pode ser retardada, como no caso de mulheres com excesso de peso ou que fazem uso de hormônios.

2.2 Câncer de Mama

Assim como todos os tipos de câncer, o câncer de mama surge de um desbalanceamento na reprodução celular, de forma que o organismo passa a produzir células anormais de maneira desenfreada, resultando em um agrupamento de células que não são capazes de se estruturar funcionalmente (WEINBERG, 2008).

Para suprir as necessidades vitais de todas essas células acumuladas, o organismo passa a recrutar cada vez mais vasos sanguíneos para a região, desencadeando um processo contínuo de angiogênese. A capacidade e a velocidade com a qual um tumor induz a formação de novos vasos determinam sua invasibilidade, de maneira que quanto mais irrigado ele é, mais rápido ele irá se desenvolver e mais fácil é o acesso ao resto do corpo, através dos sistemas sanguíneo e linfático.

Anatomicamente falando, a maioria dos casos de câncer de mama, em torno de 80%, se inicia nas células que revestem os ductos mamários, enquanto que cerca de 10% dos cânceres desse tipo têm início nos lóbulos e uma quantidade ainda menor se inicia em outros tecidos (ACS, 2019). Quanto ao gênero, existe uma predominância clara de incidência da doença na população feminina, com apenas 1% dos casos acometendo pessoas do sexo masculino (ACS, 2019).

Existem alguns fatores de risco que estão relacionados ao desenvolvimento do câncer de mama, dentre eles os mais fortes são o gênero e a idade, visto que o maior grupo de risco é de mulheres entre 50 e 60 anos. Outros fatores importantes, que estão relacionados ao estilo de vida adotado, são o excesso de peso, o consumo de bebidas alcoólicas, o tabagismo, o sedentarismo, o uso de terapias de reposição hormonal e a exposição a radiações ionizantes, principalmente em indivíduos mais jovens. Existem ainda fatores de risco que não podem ser modificados, os quais incluem o histórico familiar e mutações genéticas, em especial as que acometem os genes BRCA1 e BRCA2, responsáveis por regular o metabolismo celular (ACS, 2019; BRASILEIRO-FILHO, 2011; COELHO et al., 2018; ROBBINS et al., 2005; COSTA; SOLLA; TEMPORÃO, 2004).

Uma vez identificado um câncer, existe uma série de possíveis intervenções terapêuticas para combatê-lo, as quais podem ser locais, como cirurgias e radioterapia, ou sistêmicas, tais como quimioterapia, terapia hormonal e imunoterapia. A escolha da melhor intervenção é feita levando em consideração as características da lesão, especialmente sua

classificação, seu tamanho, sua histologia e o envolvimento dos linfonodos. Atualmente, mesmo com os avanços tecnológicos que vêm melhorando o prognóstico do câncer de mama, ainda existe uma alta taxa de mortalidade associada a essa doença, pois a eficácia do tratamento está relacionada ao estágio em que a doença é diagnosticada (ACS, 2019). Ou seja, quanto mais cedo é realizado o diagnóstico, melhor tende a ser o prognóstico e a chance de cura da paciente, melhorando também sua qualidade de vida e reduzindo, portanto, a taxa de mortalidade pela doença.

2.2.1 Métodos de diagnóstico

O câncer de mama já é mundialmente reconhecido como um problema de saúde pública, situação essa que só pode ser combatida a partir do investimento em estratégias de prevenção e diagnóstico precoce. Como prevenção estão, principalmente, as ações que envolvem mudanças no estilo de vida, de forma a evitar fatores de risco da doença. Já o diagnóstico precoce consiste na identificação da doença em estágios iniciais, de maneira que o quadro clínico possa ser mais facilmente revertido (MIGOWSKI; DIAS, 2015).

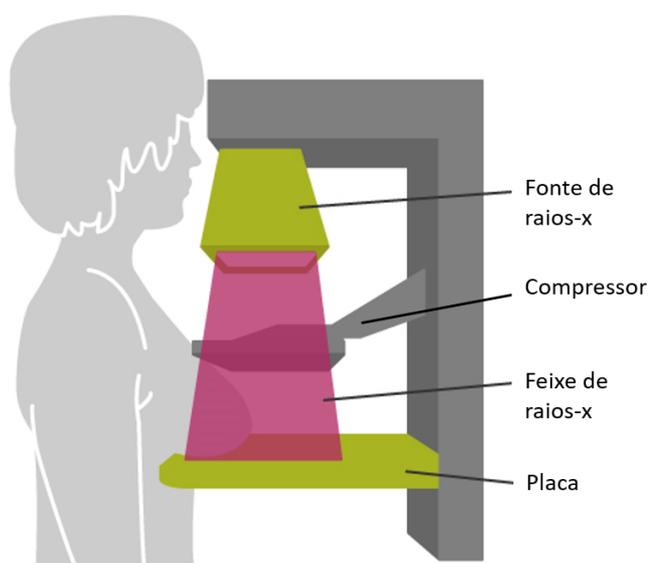
Esse diagnóstico só é possível a partir da otimização e combinação de técnicas de rastreio da doença, no caso do câncer de mama, isso é feito, na maioria das vezes, através de exames de palpação das mamas e de técnicas de diagnóstico por imagem. A palpação da mama consiste em um exame em que são observadas alterações anatômicas como nódulos palpáveis ou modificações no aspecto da mama, como vermelhidão, dor, ferimentos e assimetria. Existem duas configurações para o exame de palpação, podendo ser o autoexame, realizado pela própria paciente, ou o exame clínico, realizado por um profissional. Contudo, estudos apontam que um câncer pode levar até 10 anos para se tornar palpável, nesse sentido, os exames de imagem assumem papel fundamental na detecção precoce visto que eles tornam a análise mamária mais robusta e sensível (ETEHADTAVAKOL; NG, 2013; ACS, 2019). Dentre os exames de imagem, os mais utilizados são mamografia, ultrassonografia, ressonância magnética e, mais recentemente, a termografia de mama.

Uma lesão maligna de mama muitas vezes é confundida com outros tipos de lesões, principalmente as benignas e os cistos. Contudo, existem alguns marcadores de forma e textura que caracterizam cada uma dessas lesões (RODRIGUES, 2008). Lesões benignas e císticas comumente apresentam estrutura mais arredondada ou ovaladas, com contornos regulares e bem definidos, enquanto que lesões malignas tendem a ser mais irregulares, com estrutura lobulada ou espiculada. Existe ainda diferenças na textura de cada um desses tipos de lesão, visto que a constituição tecidual de cada uma delas é distinta. Tais características podem ser visualizadas através dos métodos de imagem, mas muitas vezes de maneira sutil, por isso ainda existe um alto grau de confusão na diferenciação dessas lesões pela análise clínica (BANDYOPADHYAY, 2010; URBAIN, 2005).

2.2.2 Mamografia

A mamografia é mundialmente considerada a principal técnica de rastreio do câncer de mama e utiliza feixe de raios-x para a formação da imagem médica. O mamógrafo é o equipamento utilizado para a realização do exame e é basicamente constituído por uma fonte de raios, onde ficam localizados a ampola de raio-x e o colimador, uma pá de compressão e a placa onde a mama é apoiada (Figura 2).

Figura 2 – Estrutura básica de um mamógrafo



Fonte: Adaptado de Wissler (2016).

Durante o exame, a ampola dispara um feixe de raios-x, que são direcionados para a região de interesse através do colimador. Os raios incidem na paciente, interagindo com o tecido mamário, de maneira que parte deles é absorvida e outra parte se choca com a placa abaixo da mama. A compressão da mama, apesar de dolorosa e desconfortável para as pacientes, é feita para uniformizar a mama, diminuindo a sobreposição dos tecidos e, portanto, melhorando a qualidade da imagem e facilitando sua análise.

Como cada estrutura mamária absorve os raios de maneira distinta, a imagem é, então, formada a partir dessa variação da intensidade dos raios que chegam à placa, mostrando as estruturas mais densas em tons mais claros, próximos ao branco, e as menos densas em tons mais próximos ao preto. O tecido fibroglandular e as lesões mamárias consistem em estruturas mais densas, enquanto que o tecido adiposo possui pouca densidade. Por esse motivo, a identificação de lesões em mamas densas utilizando a mamografia é extremamente dificultada, especialmente em estágios iniciais, onde as alterações anatômicas são ainda pequenas.

Além do desafio da utilização da mamografia em mamas densas, uma das principais desvantagens do exame consiste na necessidade de utilização de radiação ionizante (raio-x), visto que ela, por si só, representa um fator de risco para o desenvolvimento do câncer.

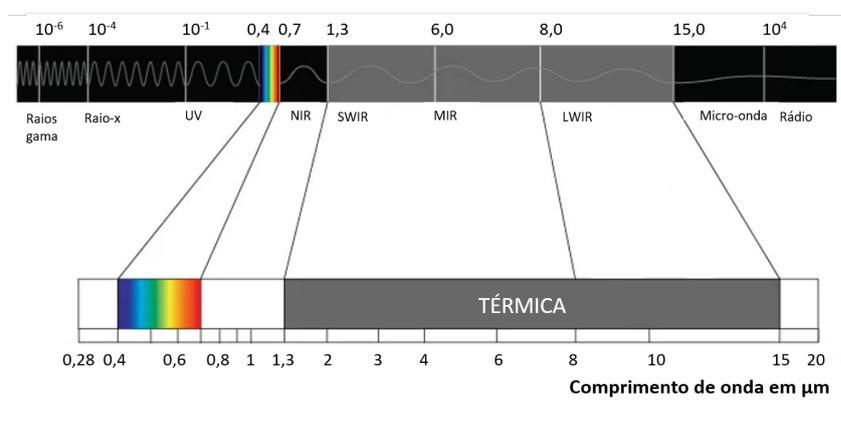
Nesse sentido, vários grupos de pesquisa e fabricantes de equipamentos vêm investindo em maneiras de minimizar a dose de radiação a qual a paciente é exposta para gerar imagens de qualidade aceitável (ZHAO et al., 2017; WISSLER, 2016). Como resultado, alguns mamógrafos mais recentes já possuem dispositivos e *softwares* cada vez mais robustos de controle e atenuação de dose (WISSLER, 2016). Contudo, visto que a mamografia é, atualmente, o padrão-ouro para rastreamento do câncer de mama, existe ainda uma série de preocupações acerca do grau de exposição das pacientes ao longo de sua vida.

Mesmo com essas limitações, a importância da mamografia é indiscutível no cenário médico atual. Os recentes avanços tecnológicos têm proporcionado um considerável aumento na sensibilidade e na segurança do exame e, portanto, um diagnóstico de melhor qualidade. Nesse sentido, a mamografia anual é mundialmente recomendada para mulheres acima dos 40 anos de idade, pois ela tem se mostrado uma boa ferramenta para o rastreamento do câncer de mama (SIU, 2016; ACOG, 2011; LAUBY-SECRETAN et al., 2015; MIGOWSKI; DIAS, 2015; ACS, 2018). No entanto, vários países, especialmente os subdesenvolvidos e emergentes, como o Brasil, possuem ainda desafios relacionados a dificuldade de acesso a esse exame, tanto devido ao alto custo associado, quanto à baixa portabilidade do sistema, muitas vezes impossibilitando o acesso a lugares mais remotos e a pessoas com dificuldade de locomoção.

2.2.3 Termografia de Mama

A termografia se baseia na aquisição de imagens, registradas através de uma câmera de infravermelho, que apresenta a distribuição de temperatura na região. A radiação infravermelha consiste em uma faixa do espectro eletromagnético com comprimentos de onda maiores do que os do espectro visível, estando entre $1,3\mu\text{m}$ e $15,0\mu\text{m}$. A Figura 3 apresenta a região do espectro associada à radiação captada por câmeras térmicas.

Figura 3 – Faixa de radiação captada por câmeras térmicas no espectro eletromagnético



Fonte: Adaptado de FLUKE (2019).

O funcionamento geral da câmera consiste na captura da radiação infravermelha

emitida pela superfície de interesse, sem a necessidade de procedimentos invasivos e sem exposição da paciente a qualquer tipo de radiação ionizante. O método é ainda portátil, indolor e não necessita de contato direto com o corpo. A partir dessa captura, a câmera fornece uma imagem que utiliza pseudocores para apresentar o mapa de temperatura superficial da região. Como a imagem é formada a partir da variação de temperatura entre regiões vizinhas da superfície de interesse, esse método é bastante sensível a alterações nas condições do ambiente em que o exame é realizado. Dessa maneira, é necessário que haja um controle e a medição constante de parâmetros como temperatura ambiente e umidade relativa do ar na sala.

Essa técnica possibilita a investigação de efeitos fisiológicos causados por doenças a partir da análise das temperaturas. No caso da existência de células cancerígenas, o crescimento metabólico proveniente da produção celular descontrolada interfere no fluxo sanguíneo, resultando no aumento da temperatura superficial da região lesionada (ETEHADTAVAKOL; NG, 2013).

Estudos afirmam que a utilização da termografia pode antecipar em até 10 (dez) anos o diagnóstico de lesões na mama, pois a partir dela podem ser extraídas informações relacionadas a alterações fisiológicas (aumento de fluxo sanguíneo e de temperatura), as quais tendem a surgir antes das anatômicas (formações de massas), que são identificadas pelos demais métodos (ETEHADTAVAKOL; NG, 2013). Além disso, o uso da termografia de mama como método de triagem pode vir a reduzir bastante a exposição desnecessária de pacientes às radiações ionizantes e a outros exames, reduzindo tanto o desgaste físico e emocional da paciente quanto os gastos dos estabelecimentos de saúde com realização de procedimentos.

Atualmente, a tecnologia das câmeras térmicas tem evoluído bastante, de maneira que pode-se encontrar câmeras cada vez mais compactas, com boa resolução e baixos custos. A Figura 4 apresenta exemplos de diferentes versões de câmeras térmicas. Tais inovações podem democratizar o acesso a esse método que vem se mostrando eficiente para a detecção e diferenciação de lesões mamárias (ETEHADTAVAKOL; NG, 2013; PEREIRA et al., 2017; SANTANA et al., 2018; SANTANA et al., 2018). Nesse contexto, a popularização da termografia de mama surge como uma poderosa ferramenta para a disseminação do rastreamento do câncer de mama, especialmente em regiões menos privilegiadas socialmente e de difícil acesso.

2.3 Sistemas Inteligentes em Saúde

Com o advento da Revolução 4.0, a Inteligência Artificial (IA) tem se tornado cada vez mais difundida e utilizada em diversos setores da sociedade, incluindo a área médica. Atualmente, a IA já é utilizada como uma maneira de otimizar os serviços prestados por

Figura 4 – Exemplos de câmeras térmicas



Fonte: A Autora (2020).

profissionais de saúde em vários locais do mundo, especialmente como ferramenta auxiliar na tomada de decisão e na realização de procedimentos médicos. Para se tornar uma ferramenta funcional, é necessário que um sistema dotado de IA seja treinado utilizando dados reais, a partir dos quais os algoritmos possam estabelecer relações, associar características e reconhecer padrões para diferenciar condições.

No âmbito do câncer de mama, a mamografia é, atualmente, a principal técnica de rastreamento da doença, contudo, a interpretação dessas imagens, especialmente em mamas densas, ainda é uma tarefa desafiadora aos olhos humanos devido a limitações da técnica e à vasta variabilidade clínica. Dessa maneira, tem-se investido na combinação da mamografia com outras técnicas de imagem, dentre elas a termografia de mama. No entanto, como a termografia ainda é pouco explorada, existe uma carência de massa crítica especializada, capaz de extrair informações relevantes a partir desse tipo de imagem. Considerando essas limitações, diversos grupos vêm investindo na utilização de sistemas inteligentes como forma de automatizar e melhorar a análise desses e outros tipos de imagens, de maneira a auxiliar a tomada de decisão dos profissionais de saúde.

2.4 Princípios de Reconhecimento de Padrões

O Reconhecimento de Padrões é um dos ramos da IA que está relacionado à Aprendizagem de Máquina, ou seja, a utilizar algoritmos que possibilitem o aprendizado de alguma tarefa pelo computador. Existem, basicamente, quatro categorias de aprendizagem:

supervisionada, por reforço, não-supervisionada e semi-supervisionada.

Na aprendizagem supervisionada há um professor que monitora o processo de aprendizagem, orientando para o que deve ser feito, de maneira a associar as entradas e as saídas do sistema, ambas fornecidas. Na aprendizagem por reforço, por outro lado, não existe um professor orientando a tomada de decisão, mas sim um *feedback* apontando se a decisão tomada foi certa ou errada. A aprendizagem não-supervisionada consiste em um método mais difícil, no qual a saída não é fornecida para o treinamento, de maneira que o algoritmo precisa encontrar formas de organizar os dados a partir dos critérios estabelecidos por ele mesmo até convergir para uma solução ótima. Dada a dificuldade de convergência dos métodos não-supervisionados, foram propostos métodos semi-supervisionados, que funcionam como um meio termo entre os supervisionados e os não-supervisionados. Na aprendizagem semi-supervisionada não é fornecida a saída exata, mas sim um conjunto de possíveis saídas no qual a saída correta esteja inserida, de forma que cabe ao algoritmo encontrá-la.

No contexto de sistemas para apoio ao diagnóstico, mais precisamente em abordagens como a utilizada no presente trabalho, comumente são utilizados métodos de aprendizagem supervisionada, pois ambos os parâmetros, de entrada (imagens) e de saída (diagnósticos), são conhecidos e fornecidos para o algoritmo. Utilizando essas informações, o sistema busca maneiras de associar os dados recebidos, ou seja, agrupar as imagens de acordo com o tipo de diagnóstico, por exemplo. Em seguida, os conhecimentos adquiridos pelo algoritmo na fase de treinamento ou aprendizagem são colocados à prova na fase de teste, na qual apenas as entradas são fornecidas e ele deve classificá-las de acordo com os padrões reconhecidos durante o treinamento.

Apesar de, em sua maioria, os algoritmos serem bioinspirados, ou seja, tomarem como base a natureza e, muitas vezes, a forma como o ser humano se comporta, a maneira como um computador "pensa" não é comparável a forma de percepção e de organização das ideias no cérebro humano. Assim sendo, a forma como uma máquina percebe e caracteriza um determinado objeto não segue os mesmos padrões utilizados pelo ser humano. Nesse sentido, para que um computador seja capaz de analisar um conjunto de dados, é necessário que eles sejam representados de maneira inteligível para essa máquina. No âmbito da IA, essa representação é comumente chamada de atributos, os quais são extraídos a partir dos dados brutos e passam a representar o conjunto de dados inicial. É esse conjunto de atributos que é fornecido como entrada para o algoritmo de classificação.

Existem alguns fatores que podem comprometer o desempenho da classificação utilizando IA. Inicialmente, é importante salientar que, em IA, um método treinado e bem sucedido para um determinado conjunto de dados não pode ser extrapolado para um conjunto de dados que não tenha relação com o inicial, isso pode acarretar na diminuição do desempenho do sistema, pois o método pode não ser o mais adequado para solucionar o novo

problema proposto. Baixos desempenhos também podem estar associados a métodos de representação e/ou de classificação insatisfatórios, o que pode ser solucionado modificando a técnica de extração de atributos e o algoritmo de classificação, respectivamente.

Outra questão comum em problemas que envolvem IA é a superespecialização do sistema, também conhecida por *overfitting*. Nesse caso, não são obtidos baixos desempenhos, mas sim desempenhos recorrentemente muito bons ou muito parecidos, geralmente iguais aos valores máximos. O *overfitting* normalmente acontece quando há pouca variabilidade de dados ou quando são utilizadas bases de dados pequenas, podendo, portanto, ser solucionado a partir da aquisição ou geração de novos dados, bem como a partir da utilização de estratégias de validação cruzada.

2.4.1 Métodos de Extração de Atributos

Nessa seção são apresentados alguns conceitos básicos para a compreensão do funcionamento geral dos métodos aqui utilizados para extrair atributos das imagens.

a) Momentos de Haralick

O descritor de Haralick extrai atributos relacionados às texturas presentes nas imagens, a partir de cálculos estatísticos associados às matrizes de co-ocorrência da imagem em escala de cinza. Essas matrizes apresentam a ocorrência de determinadas intensidades dos pixels, representando a distribuição espacial e dependência dos níveis de cinza em regiões dessa imagem. Cada $p(i, j)$ da matriz consiste na probabilidade de passar de um pixel com nível de cinza i para outro pixel com nível de cinza j , de acordo com uma determinada distância e um ângulo da vizinhança (HARALICK; SHANMUGAM; DINSTEIN, 1973). A matriz de co-ocorrência considera a relação entre um pixel referência e sua vizinhança. Nesse trabalho, foram calculados os 13 momentos de Haralick apresentados na Tabela 1. Utilizou-se os ângulos 0° , 45° , 90° e 135° , para obter as matrizes de co-ocorrência, a partir das quais foram calculados os momentos da Tabela 1. Para a extração dos atributos de uma imagem com esse método foram consideradas duas versões da imagem, sendo a primeira com a imagem em níveis de cinza e a segunda da imagem preprocessada, utilizando como filtro os mapas de Kohonen. Esse processo resultou em um total de 104 atributos por imagem.

A partir dos momentos de Haralick, é possível diferenciar texturas que não seguem um certo padrão de repetição ao longo da imagem. A textura é uma propriedade intrínseca das superfícies e contém informações importantes acerca de sua composição estrutural e sua relação com o ambiente ao seu redor. Dessa maneira, optou-se por experimentar a extração desses atributos, visto que as composições teciduais de

Tabela 1 – Momentos de Haralick

| Atributo | Expressão |
|-------------------------------------|--|
| Segundo Momento Angular | $f_1 = \sum_i \sum_j \{p(i,j)\}^2$ |
| Contraste | $f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \right\}_{ i-j =n}$ |
| Correlação | $f_3 = \frac{\sum_i \sum_j (ij)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$ |
| Variância | $f_4 = \sum_i \sum_j (i - \mu)^2 p(i,j)$ |
| Momento de Diferença Inverso | $f_5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i,j)$ |
| Média da Soma | $f_6 = \sum_{i=2}^{2N_g} i p_{x+y}(i)$ |
| Variância da Soma | $f_7 = \sum_{i=2}^{2N_g} (i - f_6)^2 p_{x+y}(i)$ |
| Entropia da Soma | $f_8 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log \{p_{x+y}(i)\}$ |
| Entropia | $f_9 = - \sum_i \sum_j p(i,j) \log (p(i,j))$ |
| Variância da Diferença | $f_{10} = \text{variância de } p_{x-y}$ |
| Entropia da Diferença | $f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log \{p_{x-y}(i)\}$ |
| Medidas de Informação da Correlação | $f_{12} = \frac{HXY - HXY1}{\max \{HX, HY\}}$ |
| | $f_{13} = (1 - \exp [-2.0(HXY2 - HXY)])^{1/2}$ |

onde, $HXY = - \sum_i \sum_j p(i,j) \log(p(i,j))$, $HXY1 = - \sum_i \sum_j p(i,j) \log\{p_x(i)p_y(j)\}$ e $HXY2 = - \sum_i \sum_j p_x(i)p_y(j) \log\{p_x(i)p_y(j)\}$

Fonte: Adaptado de Haralick, Shanmugam e Dinstein (1973).

diferentes tipos de lesões são extremamente relevantes para identificá-las e diferenciá-las.

b) Momentos de Zernike

O descritor de Zernike é uma ferramenta vastamente utilizada para extrair informação relacionada à forma ou geometria, a partir de uma imagem. Os momentos de Zernike são invariantes a rotação, não redundantes e robustos a ruídos (KAN; SRINATH, 2001). Para calcular esses momentos, o centro da imagem é considerado como o centro de um disco unitário, e são calculados a partir das projeções da função de intensidade de uma imagem sobre as funções de base ortogonal. Cada um dos 64 momentos são calculados a partir da família de polinômios de Zernike, $V_{n,m}$, descritos

pelas Equações 2.1 e 2.2.

$$V_{n,m}(\rho, \theta) = R_{n,m}(\rho)^{-jm\theta} \quad (2.1)$$

$$R_{n,m} = \sum_{s=0}^{\frac{n-|m|}{2}} (-1)^s \frac{(n-s)!}{s! \left(\frac{n+|m|}{2} - s\right)! \left(\frac{n-|m|}{2} - s\right)!} \rho^{n-2s} \quad (2.2)$$

Os 64 descritores são divididos, igualmente, em dois grupos de 32 momentos de ordem (n) baixa e 32 de ordem alta, de tal forma que n e m das Equações 2.1 e 2.2 assumem os valores apresentados na Tabela 2. Os atributos relacionados às formas de uma imagem também são relevantes no âmbito da diferenciação de lesões de mama, visto que também há padrões geométricos diferentes para cada tipo de lesão.

Tabela 2 – Momentos de Zernike

| Grupo | n | m | Número de momentos | | |
|-------|----|--------------|--------------------|--------|----|
| 1 | 3 | 1,3 | 32 | | |
| | 4 | 0,2,4 | | | |
| | 5 | 1,3,5 | | | |
| | 6 | 0,2,4,6 | | | |
| | 7 | 1,3,5,7 | | | |
| | 8 | 0,2,4,6,8 | | | |
| | 9 | 1,3,5,7,9 | | | |
| | 10 | 0,2,4,6,8,10 | | | |
| | 2 | 10 | | 2,6,10 | 32 |
| | | 11 | | 3,7,11 | |
| 12 | | 0,4,8,12 | | | |
| 13 | | 1,5,9,13 | | | |
| 14 | | 2,6,10,14 | | | |
| 15 | | 3,7,11,15 | | | |
| 16 | | 0,4,8,12,16 | | | |
| 17 | | 1,5,9,13,17 | | | |

Fonte: A Autora (2019).

2.4.2 Métodos de Classificação

Como algoritmos de classificação, o presente trabalho propõe verificar o desempenho de alguns dos métodos mais utilizados, como Redes Bayesianas (Bayes Net e Naive Bayes), Perceptron Multicamadas (MLP, do inglês *Multilayer Perceptron*), Máquina de Vetor de Suporte (SVM, do inglês *Support Vector Machine*) e algoritmos baseados em árvores de decisão (J48, *Random Tree* e *Random Forest*). Foram também explorados métodos desenvolvidos mais recentemente, como a Máquina de Aprendizado Extremo (ELM, do inglês *Extreme Learning Machine*), bem como variações da mesma, como a *Morphological*

Extreme Learning Machine (mELM). Os principais conceitos de cada um desses métodos são brevemente introduzidos nessa seção.

a) Redes Bayesianas

Bayes Net e Naive Bayes são classificadores baseados na Teoria da Decisão de Bayes. Os classificadores bayesianos, também chamados de procedimento de teste pela hipótese de Bayes buscam encontrar um risco médio mínimo, minimizando a probabilidade de erro de classificação. Eles utilizam probabilidade condicional para criar o modelo de dados, considerando um conjunto de decisões corretas e um conjunto de decisões incorretas. Cada uma das decisões é ponderada pelo produto da frequência com a qual ela ocorre e do custo envolvido na tomada de decisão (HAYKIN, 2007). Para uma distribuição Gaussiana, as redes bayesianas se comportam como um classificador linear, cujo comportamento é comparável ao de um perceptron de camada única.

No algoritmo Bayes Net, a probabilidade de ocorrência de uma classe é avaliada a partir dos valores dados pelas demais, assumindo dependência entre os atributos. O tipo de busca a ser utilizada é o parâmetro mais relevante dessa rede. Naive Bayes, por outro lado, considera que todos os atributos são independentes entre si, sendo apenas conectados à classe. Por esse motivo, o algoritmo é considerado "*naive*", ou ingênuo, visto que ele não permite dependência entre os atributos, o que representa uma condição pouco realista (CHENG; GREINER, 2001).

b) Perceptron Multicamadas

A rede Perceptron Multicamadas (MLP, do inglês *Multilayer Perceptron*) consiste em uma generalização do perceptron de camada única, na qual os neurônios da rede possuem uma função de ativação não-linear, sendo, portanto, capazes de resolver problemas mais complexos. A MLP possui um conjunto de unidades sensoriais que constroem as camadas de entrada (*input layer*), oculta (*hidden layer*) e de saída (*output layer*). Essa rede pode ainda possuir mais de uma camada oculta, com número variado de neurônios por camada, os quais são dissociados dos neurônios das demais camadas e extraem as características mais significativas do vetor de entrada (atributos) para favorecer o aprendizado (HAYKIN, 2007).

O treinamento da MLP é realizado de forma supervisionada, através da regra de aprendizagem por correção de erro, que é responsável por ajustar os pesos sinápticos, para aproximar a resposta da rede da resposta esperada. Esse ajuste é realizado a partir de um algoritmo de retropropagação de erro (*error back-propagation*), o qual é constituído por duas etapas: propagação e retropropagação. Na primeira etapa o vetor de entrada se propaga, para frente, ao longo da rede, passando por cada uma das camadas, gerando, ao fim, um conjunto de saída que corresponde à resposta da

rede. Em seguida, na retropropagação, essa resposta da rede é subtraída da resposta alvo, produzindo assim o sinal de erro que irá ajustar os pesos (HAYKIN, 2007).

c) Máquina de Vetor de Suporte

A Máquina de Vetor de Suporte (SVM, do inglês *Support Vector Machine*) consiste em outro método que pode ser utilizado para a classificação de padrões. Como ideia geral, a SVM busca construir um hiperplano capaz de separar padrões diferentes, ou seja, que sirva como uma superfície de decisão. Por exemplo, dado um problema de classificação linearmente separável, pode-se utilizar um hiperplano linear para separar as diferentes classes. Uma das principais características desse algoritmo é a sua capacidade de fornecer, em muitos casos, um bom desempenho de generalização (HAYKIN, 2007). No entanto, esse desempenho pode ser reduzido com o aumento da complexidade do hiperplano construído.

Essa máquina utiliza aprendizagem por vetor de suporte, o qual é um subconjunto dos dados de treinamento. O tipo da máquina varia de acordo com o tipo de núcleo (*kernel*) do produto interno entre um vetor de suporte y e um vetor do espaço de entrada x , o qual pode ser usado para construir o hiperplano ótimo. A Tabela 3 apresenta possíveis funções de kernel, as quais foram utilizadas no presente trabalho. Ao longo do estudo foi utilizado o algoritmo de Otimização Sequencial Mínima (SMO, do inglês *Sequential minimal optimization*) para treinamento da SVM e a estratégia de um-contratodos para lidar com o problema de classificação não-binária.

Tabela 3 – Funções de *kernel* para SVM

| Tipo de SVM | Kernel |
|------------------------------------|--|
| Máquina de aprendizagem polinomial | $K(\mathbf{x}, \mathbf{y}) = (\langle \mathbf{x}, \mathbf{y} \rangle + 1)^E$ |
| Rede de função de base radial | $K(\mathbf{x}, \mathbf{y}) = \exp(-\gamma * \langle \mathbf{x} - \mathbf{y}, \mathbf{x} - \mathbf{y} \rangle)$ |

onde E e γ são especificados pelo usuário.

Fonte: A Autora (2019).

d) Máquina de Aprendizado Extremo

A Máquina de Aprendizado Extremo (ELM, do inglês *Extreme Learning Machine*) é um método de treinamento para redes *feedforward* de camada única que foi inicialmente proposto como forma de superar algumas limitações associadas a outros métodos, tais como a presença de mínimos locais, super-especialização da rede e treinamentos demorados. Para isso, a ELM utiliza elementos herdados das SVMs e das MLPs de maneira mais flexível. Uma ELM é, basicamente, composta pelas camadas de entrada, oculta e de saída, de forma que os neurônios da camada escondida têm seus pesos aleatoriamente estabelecidos, além de possuírem *kernels* configuráveis pelo usuário, o qual também deve definir a quantidade de neurônios na camada. Já na camada de saída, os neurônios possuem *kernels* lineares, cujos pesos são determinados de

maneira não iterativa, através da inversa generalizada de Moore-Penrose (HUANG et al., 2012; HUANG, 2014). Alguns estudos apontam vantagens da ELM em relação a sua versatilidade, seu bom desempenho em problemas multiclases e sua baixa complexidade computacional, mesmo sendo um método não linear (HUANG; ZHU; SIEW, 2006; HUANG et al., 2012; AZEVEDO et al., 2015a).

Há, também, a Máquina Morfológica de Aprendizado Extremo (mELM, do inglês *Morphological Extreme Learning Machine*), proposta por Azevedo et al. (2015a), que consiste em uma ELM com *kernels* da camada escondida inspirados nos operadores matemáticos de dilatação e erosão. Esses operadores são não-lineares e buscam realizar modificações de forma ao mesmo tempo em que preservam a relação de inclusão dos objetos. O principal objetivo da mELM é o de combinar a habilidade das redes morfológicas de construir fronteiras de decisão não lineares com a simplicidade da ELM (AZEVEDO et al., 2015a). Nesse trabalho, ambos os *kernels* morfológicos foram experimentados, além do *kernel* sigmoidal, para a ELM convencional; tais funções podem ser visualizadas na Tabela 4.

Tabela 4 – Funções de *kernel* para ELM

| Tipo de kernel | Função |
|-----------------------|---|
| Sigmoidal | $K(\mathbf{x}, \mathbf{w}) = \tanh(a\mathbf{x}^T \mathbf{w} + c)$ |
| Dilatação | $K_\delta(\mathbf{x}, \mathbf{w}) = \bigvee_{i=1}^n (x_i \wedge w_i)$ |
| Erosão | $K_\epsilon(\mathbf{x}, \mathbf{w}) = \bigwedge_{i=1}^n (x_i \vee \bar{w}_i)$ |

Fonte: A Autora (2019).

e) Árvores de Decisão

As árvores de decisão são outro tipo de aprendizado de máquina supervisionado. No geral, as árvores são formadas por nós, estruturas que armazenam informações. Em uma árvore existem nós de várias categorias: raiz, folha, pai e filho. O nó raiz consiste no ponto de partida e possui o maior nível hierárquico. Um nó pode estar ligado a outro, estabelecendo a relação pai-filho, em que o nó filho deriva de um nó pai. Os nós folha, por sua vez, consistem em nós terminais, ou seja, que não possuem filhos, e representam uma decisão a ser tomada. Dessa maneira, utilizando tais árvores, uma decisão é tomada ao se percorrer algum caminho que parte do nó raiz e chega a um nó folha. Existem vários tipos de árvores de decisão que, no geral, se diferenciam pela forma pela qual a estrutura é percorrida ou como os dados são distribuídos ao longo da árvore, dentre esses tipos, os métodos J48, *Random Tree* e *Random Forest* são os mais utilizados.

O classificador J48 busca construir uma árvore de decisão a partir de uma base de dados para obter conhecimento e, assim, moldar a tomada de decisão. Nessa abordagem, o atributo mais significativo é a raiz da árvore (PAHWA; PAPREJA; MIGLANI, 2014). Já o método *Random Tree*, considera apenas alguns atributos em

cada nó da árvore, os quais são aleatoriamente selecionados (GEURTS; ERNST; WEHENKEL, 2006). O algoritmo *Random Forest* também utiliza árvores de decisão para realizar a classificação. Esse classificador consiste em uma combinação de árvores que dividem os dados de maneira hierárquica, de forma que, a partir de um vetor de entrada, e depois de gerada uma certa quantidade de árvores, definida pelo usuário, cada árvore vota em uma classe do problema. No final, a classe mais votada é a escolhida como a predição do classificador (BREIMAN, 2001).

3 TRABALHOS RELACIONADOS

Este capítulo é dedicado a revisão de trabalhos relacionados ao uso de imagens de termografia de mama e de mamografia associadas a técnicas computacionais de reconhecimento automático de padrões.

3.1 Termografia de Mama

No trabalho de Ng et al. (2002), eles buscaram treinar uma rede neural de retropropagação para identificar lesões benignas ou malignas a partir de um banco de dados com 200 imagens de termografia de mama. Foram experimentadas quatro maneiras distintas de representar as imagens, através dos aspectos a seguir:

- a) Conjunto 1: Média, mediana, moda, desvio padrão e *skewness*.
- b) Conjunto 2: Média, mediana e moda.
- c) Conjunto 3: Idade, histórico familiar, terapia de reposição hormonal, idade da menarca, presença de nódulo palpável, cirurgia ou biópsia prévia, presença de secreção mamilar, dor na mama, menopausa em idade acima dos 50 anos, teve primeiro filho com idade acima de 30 anos.
- d) Conjunto 4: Combinação dos atributos dos conjuntos 2 e 3.

A rede neural utilizada nesse estudo foi configurada para ter uma taxa de aprendizagem de 0,5, com *momentum* igual a 0,4 e função de ativação do tipo sigmoidal. Nesse estudo, foi utilizada apenas uma configuração de classificador, visto que o objetivo dos autores era o de analisar os diferentes conjuntos de atributos, comparando a eficácia de cada um deles na representação das imagens térmicas, de acordo com o método proposto.

Nesse sentido, foi observado que as acurácias dos conjuntos 1, 2 e 4 foram semelhantes entre si, com valor aproximado de 61%, contudo, enquanto que o erro médio quadrático associado a classificação utilizando o conjunto 4 foi de 0,05, ambos os demais conjuntos (1 e 2), apresentaram erro igual a 0,12. O grupo 3, por sua vez, resultou em um erro intermediário de 0,09, no entanto, a acurácia obtida a partir dessa representação foi em torno de 53%, quase 10% menor do que a com os demais conjuntos.

Quanto à sensibilidade do sistema, o grupo 2 apresentou o maior valor, 70%, logo em seguida vieram os grupos 1 e 4, com pouco mais de 65%, e, por fim, o grupo 3, com a menor sensibilidade, de quase 50%. Já em relação a especificidade, o conjunto 3 apresentou o

melhor resultado, próximo de 80%, enquanto que os demais conjuntos obtiveram resultados piores e semelhantes entre si, em torno de 40%. Dessa maneira, mesmo apresentando resultados menos satisfatórios, o grupo 3 demonstrou resultar em menores índices de falsos positivos, mas isso não foi suficiente para melhorar a especificidade do grupo 4, que também continha informações do grupo 3. No geral, foram atingidos baixos valores de erros, mas os resultados obtidos, especialmente de sensibilidade e acurácia, foram pouco satisfatórios, visto que trata-se de uma aplicação em seres humanos.

Arora et al. (2008), também buscaram realizar uma classificação binária de lesões malignas e benignas a partir de imagens de termografia de mama. Em seu trabalho, os autores utilizaram 94 imagens (320×240), de aquisição própria e cujos diagnósticos foram previamente comprovados por biópsia, dos quais 60 continham lesão maligna e 34 apresentavam lesão benigna.

Durante a aquisição foi utilizada a técnica de *cold stress*, na qual é direcionado ar frio às mamas durante a aquisição das imagens. Nesse estudo, foram utilizadas 3 técnicas distintas de análise das imagens: *Blinded screening mode* (SBS), avaliação clínica e rede neural artificial (ANN). A primeira técnica resulta em uma pontuação de risco, que varia de 0 (zero), risco mínimo, a 7, risco muito alto. Os dois outros métodos fornecem um resultado binário, se é maligna ou é benigna. A partir dos experimentos os autores verificaram que a abordagem utilizando ANN se destacou positivamente, em relação às demais, obtendo uma acurácia de 81,8%, enquanto que a para o SBS foi de 66,7% e 71,4% para a análise clínica.

Uma abordagem um pouco mais diferente foi proposta por Zadeh et al. (2017), que optaram por combinar um método de aprendizagem não supervisionada com um de supervisionada. Os autores utilizaram Mapa Auto-Organizável (SOM, do inglês *Self-Organizing Map*) para realizar tanto o processo de agrupamento (*clustering*), visto que as imagens não possuíam uma classe de saída preestabelecida, quanto o processo de extração de características, relacionadas à textura morfológica. Para a etapa de classificação optou-se por usar uma rede MLP e validação cruzada com 5 folds. Foram utilizadas duas bases de dados distintas, a primeira com 50 imagens e cujo processo de aquisição foi mais bem padronizado, e a segunda com 200 imagens sem muito rigor em relação à padronização.

As bases de dados foram analisadas separadamente e, mais uma vez, foi realizada uma classificação binária, mas agora do tipo câncer *versus* não-câncer. Utilizando a primeira base de dados, o método proposto alcançou até 100%, tanto de sensibilidade quanto de especificidade. Esses resultados diminuíram um pouco para a segunda base, a qual apresentou uma sensibilidade de 88%, com 99% de especificidade na detecção do câncer de mama. Apesar de terem usado validação cruzada durante o treinamento, os resultados, especialmente para a primeira base de dados, podem indicar superespecialização do sistema, dada a baixa dimensionalidade da base.

No estudo de Raghavendra et al. (2016), utilizou-se 50 imagens (1280×1024), igualmente divididas em duas classes: saudável e com lesão maligna. Seu objetivo principal foi o de avaliar o desempenho de diversos classificadores inteligentes na tarefa de agrupar as imagens em suas respectivas classes. Para a extração de atributos das imagens, eles utilizaram o método de Histograma de Gradientes Orientados (HOG, do inglês *Histogram of Oriented Gradients*); em seguida, esses atributos passaram por dois processos, o primeiro de redução de dimensionalidade, utilizando a técnica KLPP (*Kernel Locality Preserving Projection*), e o segundo de seleção, utilizando técnicas de seleção baseadas no teste t de Student, visto que o conjunto de atributos extraídos com o HOG foi grande e poderia conter redundância.

Por fim, foram testados os seguintes métodos de classificação: árvore de decisão, *Linear Discriminant Analysis* (LDA), *Quadratic Discriminant Analysis* (QDA), *k-Nearest Neighbour* (kNN), *Fuzzy Sugeno*, *Naive Bayes*, SVM, AdaBoost, *Probabilistic Neural Network* (PNN) e *Breast Cancer Risk Index* (BCRI). Nessa etapa, os testes foram realizados utilizando validação cruzada, com 10 folds. Dentre os métodos avaliados, a árvore de decisão atingiu os melhores resultados, com 98% de acurácia, 96% de sensibilidade e especificidade de 100%. Mais uma vez, esse sistema pode ter sofrido o efeito de superespecialização, visto que havia apenas 25 instâncias por grupo e não foi reportada a realização de nenhum tipo de expansão desses dados. O fato da árvore ter se destacado em relação aos outros classificadores também pode indicar uma baixa capacidade de generalização dos resultados.

Fernández-Ovies et al. (2019), por sua vez, também avaliou a detecção de câncer de mama utilizando o problema binário com as classes saudável e com câncer. Contudo, nesse trabalho, a classificação foi realizada através de seis configurações diferentes de redes neurais convolutivas (CNNs) e utilizando o método de validação cruzada com 5 folds. As CNNs Resnet18, Resnet34, Resnet50, Resnet152, Vgg16 e Vgg19 foram utilizados para a classificação. Quanto a base de imagens, os autores optaram por usar a VisionLab, que, no total, contém 5604 imagens (480×640), sendo algumas delas inseridas sinteticamente, para ampliar a base. 2411 dessas imagens são de mamas saudáveis, enquanto que 534 apresentam câncer, as demais imagens não foram utilizadas por não cumpriram os critérios de inclusão estabelecidos pela equipe. Visto que a CNN é um classificador extremamente sensível a classes desbalanceadas, foram selecionadas, aleatoriamente, 500 imagens de cada grupo para participarem dos experimentos de fato.

Com os experimentos, os autores verificaram que, no geral, a CNN do tipo Resnet se sobressai em relação a Vgg. A Resnet50 e a Resnet34 obtiveram os melhores desempenhos, com acurácias médias de 98,75% e 98,13%, respectivamente. Contudo a Resnet50 se mostrou menos estável, pois apresentou um desvio padrão de 1,09%, enquanto que o da Resnet34 foi de 0,63%. A Resnet18 também apresentou resultados interessantes, mas não

suficientes para superar as outras duas.

3.2 Mamografia

Em se tratando de imagens de mamografia, em seu trabalho, Azevedo et al. (2015a) propuzeram utilizar ELM com diferentes kernels para identificar mamas saudáveis, com lesão benigna e com lesão maligna. Para isso, os autores utilizaram a base de imagens IRMA, com 2796 imagens (128×128) de regiões de interesse (ROI) provenientes de mamografias, as quais são divididas também pelo tipo de tecido predominante na mama, podendo ser adiposa (I), fibrosa (II), heterogeneamente densa (III) ou extremamente densa (IV).

Dessa maneira, utilizou-se 5 cenários de avaliação distintos para verificar o desempenho das diferentes configurações do classificador. Quatro desses cenários consistiu na utilização das imagens associadas apenas a um tipo de constituição tecidual, nesses casos, cada imagem deveria ser classificada em uma das 3 classes: sem lesão, lesão benigna ou lesão maligna. Por fim, o quinto cenário utilizou todas as imagens, associando todos os tipos de tecidos e, especialmente nessa base, existem 12 classes possíveis, sendo três para cada tipo de tecido. Sendo assim, no quinto cenário de avaliação, buscou-se verificar se a ELM seria capaz de classificar as imagens não apenas pelo tipo de tecido, mas também pelo diagnóstico associado à imagem.

Para a extração de atributos, os autores avaliaram ainda diferentes combinações dos métodos de Haralick, Zernike e Wavelet, sendo todos eles testados individualmente e associados dois a dois. Os kernels da ELM foram o sigmoidal, de dilatação e de erosão, sendo os dois últimos propostos nesse mesmo estudo. Foram utilizados 100 neurônios na camada escondida do classificador e o método de validação cruzada com 10 folds.

No geral, a associação dos atributos de Wavelet e Haralick resultaram nos melhores desempenhos. Resultados próximos aos melhores foram obtidos quando apenas os atributos de Haralick foram utilizados. Os atributos de Zernike e a associação de Zernike e Wavelet resultaram nos desempenhos menos satisfatórios. Em relação ao resultado para cada uma das bases de dados, foi observado que a utilização do tecido III favoreceu a classificação, alcançando até 95% de acurácia, com 0,96 de índice kappa, utilizando o kernel de erosão. Os tecidos I, II e IV obtiveram resultados bem próximos, todos com 90% de acurácia e com índices kappa de 0,92, 0,91 e 0,93, respectivamente, sendo o primeiro resultado obtido com o kernel de erosão e os outros dois com de dilatação. Para a base de dados com todos os tecidos e 12 possíveis classes, como esperado, houve uma diminuição considerável no desempenho de classificação, de forma que foi obtida uma acurácia máxima de 65%, com kappa de 0,66, tanto para o kernel de erosão quanto de dilatação.

Já no trabalho de Becker et al. (2017), foi utilizada uma base binária (com câncer *versus* sem câncer) de construção própria, a partir da qual foram realizados dois estudos.

O primeiro foi um estudo longitudinal, no qual utilizaram exames de pacientes que estavam sendo acompanhados há 7 anos (2008-2015), resultando em 178 exames por classe. O segundo estudo foi transversal, cujos dados eram provenientes de casos do ano de 2012, com 143 exames de pacientes com câncer e 1003 de indivíduos saudáveis.

A análise das imagens foi feita a partir do *software* ViDi SuiteVersion. Inicialmente houve a seleção da ROI de cada imagem, realizada por especialistas na área. O mapa de calor da ROI foi utilizado para representar as imagens e uma dANN (*deep Artificial Neural Network*) foi utilizada como classificador. Tal método resultou em uma acurácia de 81%, com sensibilidade de 59,8% e 84,4% de especificidade, para o grupo do primeiro estudo. No segundo estudo, o desempenho foi de 85% de acurácia, com 73,7% e 72% de sensibilidade e especificidade, respectivamente.

No estudo de Wang et al. (2017), foi utilizada a base *Mammographic Image Analysis Society* (mini-MIAS), contendo 322 mamogramas (1024×1024), também com divisão de tipos de tecido, mas sendo 3 tecidos possíveis: adiposo, adiposo-glandular e denso-glandular. O intuito principal do trabalho foi o de investigar o desempenho do método de classificação proposto, Jaya-FNN, com a utilização do algoritmo Jaya para treinar uma *feed-forward neural network* (FNN). Para isso, 200 imagens foram aleatoriamente escolhidas, sendo 100 da classe de mamas saudáveis e 100 da de mamas com câncer. Em seguida, as imagens foram filtradas, para a atenuação de ruídos, e segmentadas, isolando a ROI.

Para a extração de atributos foi utilizada a *Weighted Fractional Fourier Transform* (WFRFT), resultando no espectro fracional de Fourier, que consiste em um conjunto grande de atributos. Por isso, foi utilizado o método de análise do componente principal (PCA) para reduzir a dimensionalidade desses atributos. O trabalho propõe ainda o método Jaya-FNN para classificação, o qual consiste em uma FNN cujos pesos e *bíases* são treinados a partir do algoritmo Jaya. Para validação utilizou-se o método k-fold, com 10 folds. No estudo, o desempenho do Jaya-FNN foi comparado com o de outros algoritmos amplamente explorados na literatura, levando os autores a observar que o método proposto apresentou os melhores resultados, quando comparado aos demais métodos. A utilização do Jaya-FNN resultou no menor desvio padrão e em um erro médio quadrático de 0,0093, que foi mais de 70% menor do que o segundo melhor erro. Quanto às métricas de acurácia, sensibilidade e especificidade, foram obtidos valores em torno de 92% para todas.

Magna et al. (2016) utilizaram a rede A²INET para identificar assimetrias entre mamas, a partir de imagens de mamografia de duas bases de dados de domínio público, a *Digital Dataset for Screening Mammography* (DDSM) e a mini-MIAS. A A²INET, proposta no trabalho, consiste em um modelo semi-supervisionado de uma rede imunológica artificial. Ao todo foram utilizadas 94 imagens, sendo igualmente divididas em dois grupos: mamas saudáveis e mamas assimétricas. Para representar as imagens os autores utilizaram 24 atributos extraídos a partir de uma medida de quantificação de similaridade estrutural entre

regiões, com o intuito de descrever diferenças relevantes entre ambas as mamas. Além disso, foi também aplicado o método PCA para reduzir a dimensionalidade dos atributos.

O desempenho da A²INET foi comparado ao de mais três métodos, o kNN, a *Partial Least Square-Discriminant Analysis* (PLS-DA) e uma rede neural de retropropagação. A rede proposta superou os resultados dos demais classificadores testados, visto que foi obtida uma acurácia de até 90% utilizando a A²INET, enquanto que as acurácias dos demais métodos ficaram em torno de 70%.

No estudo realizado por Rodriguez-Ruiz et al. (2019), os autores buscaram identificar o câncer de mama em imagens de mamografia de 9 bases de dados distintas, totalizando 9000 imagens de mamas com câncer, sendo 3000 delas com calcificação, e 180000 imagens de mamas saudáveis. Para a classificação foi utilizada uma rede neural convolutiva (CNN), cujos resultados foram comparados aos diagnósticos fornecidos por 101 radiologistas. O desempenho da rede foi analisado para cada uma das bases isoladamente. A partir do trabalho, os autores verificaram que o método computacional utilizado teve desempenho próximo, mas inferior, ao conhecimento especialista dos radiologistas, com especificidade entre 49% e 79% e sensibilidade máxima de 86%.

Apesar de, no estudo de Rodriguez-Ruiz et al. (2019), os autores discutirem os resultados no sentido de investigar a possibilidade de substituir o conhecimento dos radiologistas pela inteligência computacional, é importante mencionar que esse não é o escopo do presente trabalho. No estudo aqui proposto, acredita-se que o conhecimento humano não pode ser substituído, uma vez que é ele mesmo que alimenta os sistemas computacionais. Considera-se que as ferramentas inteligentes podem auxiliar na tomada de decisão de profissionais, especialmente daqueles com pouca experiência na área e/ou que se encontram em locais de difícil acesso e com pouca estrutura ou recursos à sua disposição. Nesse sentido, mesmo compreendendo que o intuito dos autores foi o de utilizar a opinião especialista como uma espécie de padrão-ouro, em uma perspectiva de apoio ao diagnóstico, não é interessante comparar o desempenho de humanos com o de máquinas.

3.3 Avaliação de ambas as técnicas

Existem ainda alguns estudos que avaliam a utilização tanto da termografia de mama quanto da mamografia para a detecção do câncer de mama. O trabalho de Omranipour et al. (2016) é um exemplo desse tipo de estudo, no qual os desempenhos das técnicas foram comparados tanto isoladamente quanto associados. Os autores utilizaram a avaliação histológica como padrão ouro para avaliar as demais técnicas e sua combinação. Mais uma vez, foi utilizada uma classificação binária, com o intuito de diferenciar imagens em que havia lesão maligna das com lesão benigna. O banco de dados foi composto de 45 imagens benignas e 87 malignas.

Em relação aos resultados, os autores observaram que o desempenho da classificação foi melhor com imagens de mamografia do que com de termografia, quando as técnicas foram analisadas isoladamente. Nessa situação, a mamografia apresentou especificidade de 73,3%, acurácia de 76,9% e sensibilidade de 80,5%. Utilizando apenas a termografia, o estudo resultou em 81,6% de sensibilidade, com especificidade e acurácia de, respectivamente, 57,8% e 69,7%.

A partir da associação de ambas as técnicas, foi observado um crescimento de mais de 10% na sensibilidade do sistema, atingindo até 96,2%. Contudo, houve diminuição tanto da especificidade, para 44,4%, quanto da acurácia, para 70,5%.

No geral, os autores compararam as técnicas no sentido de propor uma substituição da mamografia pela termografia, tanto que interpretaram os resultados como tendo apresentado uma superioridade absoluta da mamografia. Contudo, mesmo tendo alcançado acurácia e especificidade melhores, a mamografia apresentou sensibilidade menor que a da termografia, nesse estudo. Além disso, os autores não dão muito destaque aos resultados obtidos através da associação das técnicas, mesmo isso tendo desencadeado um aumento significativo na sensibilidade do diagnóstico.

De maneira oposta a proposta em Omranipour et al. (2016), o intuito do presente trabalho não é o de validar uma técnica em detrimento da outra, mas sim associá-las, quando cabível, no sentido de otimizar o diagnóstico, antecipando-o cada vez mais, e possibilitando, portanto, a identificação do câncer de mama ainda em estágios iniciais.

3.4 Considerações

Este capítulo abordou uma série de estudos recentes que utilizam métodos inteligentes de reconhecimento de padrões para a identificação do câncer de mama, tanto a partir de imagens de termografia quanto de mamografia. A Tabela 5 apresenta um resumo dos trabalhos aqui destacados, bem como os pontos principais do estudo proposto no presente trabalho.

Tabela 5 – Resumo dos trabalhos relacionados

| Trabalho | Base de dados | Proposta | Resultados |
|-------------------------------|--|--|--|
| Ng et al. (2002) | 200 imagens de Termografia | Classificação binária (benigna ou maligna) utilizando diferentes representações das imagens e um classificador. | Acurácia máxima de 61,54%, sensibilidade de 70% e 80% de especificidade. Não houve um método que se destacou, os melhores resultados foram de métodos distintos. |
| Arora et al. (2008) | 94 imagens de Termografia | Classificação binária (benigna ou maligna) utilizando diferentes técnicas de análise, dentre elas, uma rede neural artificial. | A rede neural apresentou acurácia de 81,8%, resultado 10,4% maior do que com o melhor dos demais métodos. |
| Zadeh et al. (2017) | Duas bases de dados de Termografia, uma com 50 imagens e outra com 200 | Classificação binária (câncer ou saudável) utilizando SOM e MLP para caracterizar e classificar os dados. | Sensibilidade de 100% e 88% para a primeira e a segunda bases, respectivamente; Especificidade de 100% e 99%. |
| Raghavendra et al. (2016) | 50 imagens de Termografia | Classificação binária (câncer ou saudável) utilizando HOG para extração de atributos e diversos métodos de classificação. | Até 98% de acurácia, 96% de sensibilidade e especificidade de 100%. |
| Fernández-Ovies et al. (2019) | 1000 imagens de Termografia | Classificação binária (câncer ou saudável) utilizando CNNs do tipo Resnet e Vgg. | A rede Resnet alcançou até 98,75% de acurácia e obteve desempenho melhor do que as redes Vgg |

Tabela 5 – Resumo dos trabalhos relacionados

| Trabalho | Base de dados | Proposta | Resultados |
|------------------------------|---|--|---|
| Azevedo et al. (2015a) | 2796 imagens de ROI de Mamografias (IRMA) | Foram testados 5 cenários distintos, variando também a maneira de representação das imagens e as configurações do classificador ELM | Acurácia máxima de 95%, com kappa de 0,96, para tecido do tipo heterogeneamente denso. A associação de todos os tecidos piorou a classificação em pelo menos 30%. |
| Becker et al. (2017) | 1 146 imagens de ROI de Mamografia | Classificação binária (câncer ou saudável) utilizando o mapa de calor da imagem e dANN. | Até 85% de acurácia, com sensibilidade e especificidade medianas, variando de, aproximadamente, 60% a 84%. |
| Wang et al. (2017) | 200 imagens de Mamografia | Classificação binária (câncer ou saudável) utilizando WFRFT para extração de atributos e o método Jaya-FNN para classificação. | Acurácia, Sensibilidade e Especificidade em torno de 92%, com erro de 0,0093. |
| Magna et al. (2016) | 94 imagens de Mamografia | Classificação binária (saudável ou assimétrica) utilizando A ² INET e métodos de quantificação de similaridade estrutural para extração de atributos. | Acurácia de até 90%. O método A ² INET proposto superou os demais métodos testados. |
| Rodriguez-Ruiz et al. (2019) | 189000 imagens de Mamografia | Classificação binária (câncer ou saudável) em 9 bases de dados distintas utilizando rede neural convolutiva. | Especificidade de até 79% e sensibilidade máxima de 86% |

Tabela 5 – Resumo dos trabalhos relacionados

| Trabalho | Base de dados | Proposta | Resultados |
|--------------------------|--|--|--|
| Omranipour et al. (2016) | Imagens de Termografia e Mamografia | Classificação binária (benigna ou maligna), analisando as imagens das diferentes técnicas tanto de maneira isolada quanto combinada. | Quando analisadas isoladamente, a mamografia se mostrou superior à termografia em relação a acurácia e a especificidade. Houve uma melhora na sensibilidade quando as técnicas foram associadas. |
| Presente trabalho | Imagens de Termografia e Mamografia | Avaliação de diferentes técnicas de representação e classificação das imagens com classificação não-binária | Para os termogramas de mama, foi obtida acurácia em torno de 99%. Resultados acima de 95% de acurácia foram obtidos para a classificação das imagens de mamografias. |

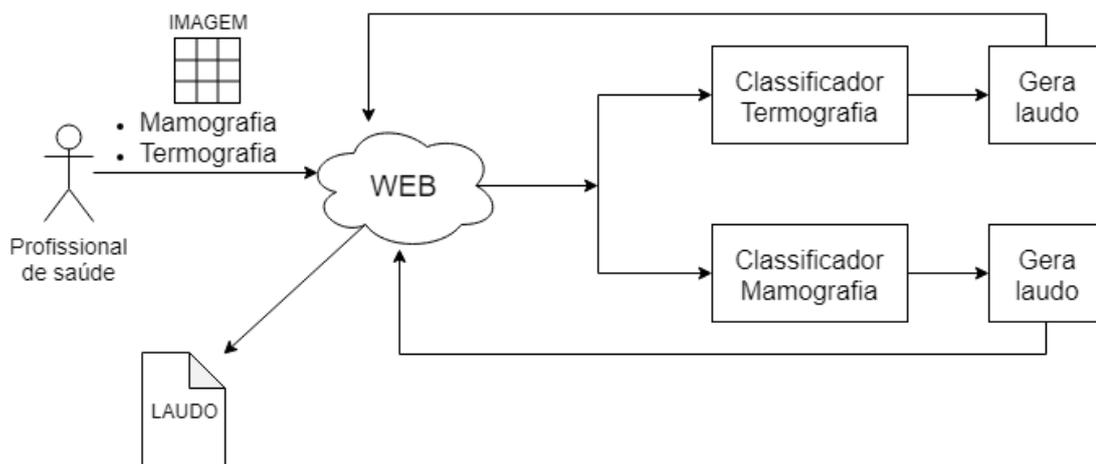
Fonte: A Autora (2019).

4 PROPOSTA: Sistemas inteligentes para apoio ao diagnóstico do câncer de mama

O presente trabalho propõe um sistema inteligente para apoio ao diagnóstico do câncer de mama utilizando imagens provenientes de exames de Termografia e Mamografia, tal sistema, esquematizado na Figura 5, busca fornecer um pré-diagnóstico automático para auxiliar a tomada de decisão de profissionais de saúde que lidam com mastologia em sua prática clínica. Nesse capítulo são apresentadas as etapas realizadas para o cumprimento da proposta.

Após a validação da máquina de aprendizado (Figura 8), foi construído um protótipo de apoio ao diagnóstico do câncer de mama usando imagens termográficas e regiões de interesse de mamogramas. Esse protótipo é constituído de solução, a ser executada em nuvem, e, futuramente, em aplicativo para dispositivos móveis. A partir desse aplicativo, o usuário poderá enviar a imagem termográfica ou a região de interesse de mamograma à nuvem, onde será feita a extração de atributos e a classificação da imagem, retornando ao aplicativo a informação de ocorrência de lesão e, caso seja detectada lesão de mama, indicar qual o seu provável tipo, servindo, assim, como sistema de triagem para exames mais complexos.

Figura 5 – Proposta final do trabalho



Fonte: A Autora (2019).

4.1 Deep-Wavelet Neural Network

Desenvolvida ao longo desse trabalho, a *Deep-Wavelet Neural Network* (DWNN) é uma rede profunda e sem treinamento para extração de atributos, inspirada no algoritmo de Mallat (MALLAT et al., 1989) para a decomposição de Wavelet em múltiplos níveis. Esse algoritmo, que surgiu como uma estratégia para a implementação da transformada

wavelet discreta, consiste na obtenção de aproximações e de detalhes de uma imagem. As aproximações são a representação de baixa frequência da imagem, conservando sua tendência geral, ao mesmo tempo em que suaviza as transições abruptas presentes nela. Já os detalhes mostram os componentes de alta frequência da imagem, realçando regiões de descontinuidade, como bordas e manchas.

Na decomposição Wavelet, filtros passa-baixa e passa-alta são aplicados a uma imagem para formar um conjunto de outras imagens de dimensão menor do que a original. A partir da filtragem passa-baixa são obtidas as aproximações e os detalhes são adquiridos através dos filtros passa-alta. Essa abordagem permite a análise das imagens nos domínios espacial e de frequência e, por isso, tem sido amplamente utilizada no reconhecimento de padrões. A DWNN utiliza um processo semelhante a esse, em que um neurônio é formado pela combinação de um dado filtro (g_i) com um processo de redução de tamanho da imagem ($\downarrow 2$), denominado *downsampling*.

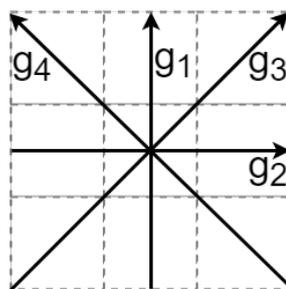
O "Deep" do nome surge da possibilidade de utilização de várias camadas, tornando o método cada vez mais profundo na medida em que são acrescentadas novas camadas. Além disso, assim como os métodos de *deep learning* convencionais, como é o caso das Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*), o processo consiste em duas etapas básicas, na primeira as imagens são submetidas a filtros, e na segunda ocorre o *pooling*. Contudo, enquanto que nos métodos convencionais os filtros não são fixos, os filtros empregados na Deep-Wavelet são fixos e dizem respeito às famílias das Wavelets, do tipo Haar. Existe ainda diferenças no processo de *pooling*, visto que a Deep-Wavelet realiza a redução de dimensionalidade das imagens a partir do processo de *downsampling*, já os métodos convencionais de *deep learning* comumente utilizam a média quadrática para a redução.

Os filtros utilizados na DWNN formam um banco de filtros, que são mantidos fixos e se repetem em todo o processo. Cada imagem de entrada é submetida a ação de todos os filtros do banco. A quantidade e as orientações dos filtros são definidos a partir da vizinhança considerada. Para uma vizinhança-8, como utilizada nesse trabalho, tem-se os filtros passa-alta apresentados na Figura 6, onde g_1 é o filtro vertical, responsável por destacar bordas horizontais, g_2 é o filtro horizontal, que destaca bordas verticais, e g_3 e g_4 são os filtros diagonais, os quais destacam as quinas da imagem.

Dessa maneira, g_1 , g_2 , g_3 e g_4 formam o banco de filtros, classificados como derivativos, visto que destacam as descontinuidades da imagem de entrada, realçando os detalhes, ou seja, as transições entre regiões diferentes passam a ser mais nítidas.

Considerando um banco com n filtros, uma imagem de entrada será submetida a n neurônios que formam a primeira camada da rede neural. Na segunda camada, cada uma das imagens resultantes da primeira serão individualmente submetidas ao mesmo banco de n filtros e ao *downsampling*, da mesma maneira como foi feito para a imagem de entrada.

Figura 6 – Filtros para uma vizinhança-8



Fonte: A Autora (2019).

O processo se repete para todas as m camadas, onde m é estabelecido pelo usuário e determina a profundidade da rede.

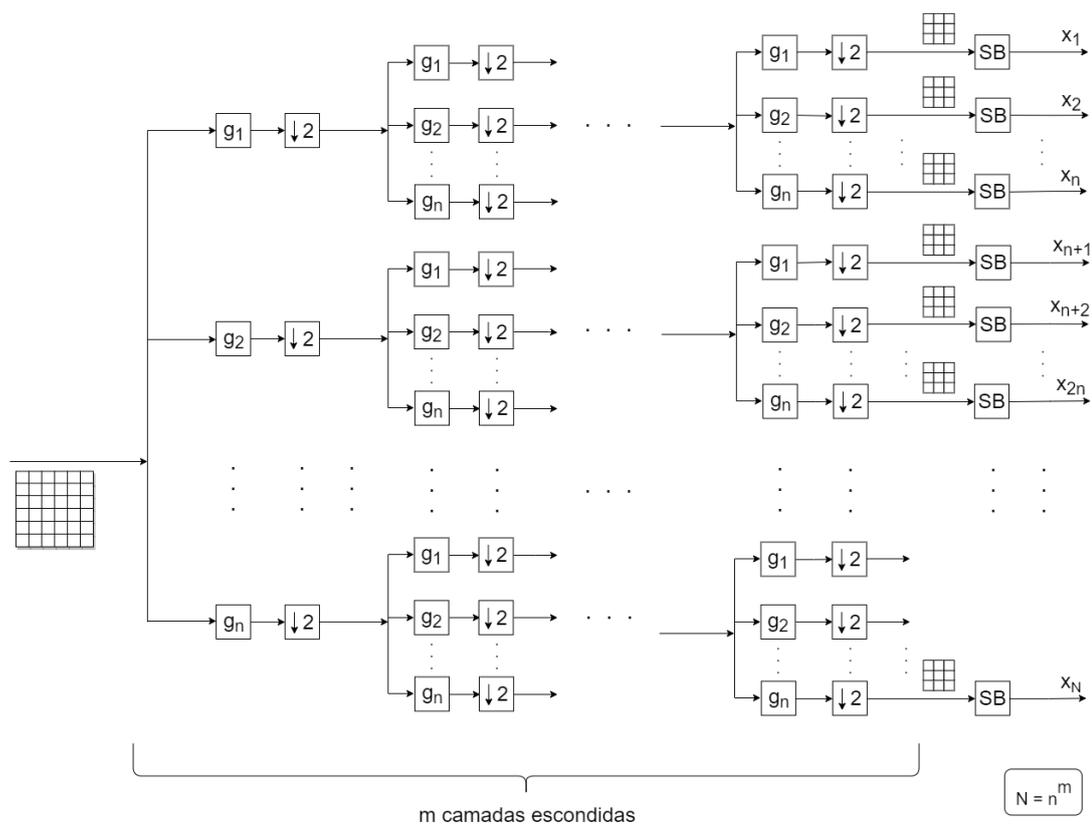
O processo de *downsampling*, que compõe cada um dos neurônios da DWNN, consiste em reduzir o tamanho da imagem, de forma que quatro pixels são substituídos por apenas um. O uso desse processo é essencial, especialmente em casos em que o número de camadas, m , é muito grande, visto que uma só imagem resulta em n outras, após passar por cada camada. Dessa maneira, o *downsampling* é responsável por diminuir o consumo de memória durante a execução do algoritmo, tornando-o computacionalmente menos custoso.

Por fim, na camada de saída da DWNN, temos os blocos de sínteses (SB), os quais são responsáveis por extrair informações das imagens resultantes de todo o processo. Nesses blocos, cada uma das n^m imagens reduzidas serão submetidas a uma função $\varphi : S \rightarrow \mathbb{R}$, em que $\varphi(\cdot)$ pode assumir uma função de máximo, média, mínimo, mediana ou moda. Assim, cada imagem é substituída por um único valor. Quando o SB é aplicado a todas as m imagens resultantes, tem-se um conjunto de x_i termos, com $1 \leq i \leq n^m$, que representam a imagem de entrada, ou seja, formam o vetor de atributos da imagem. A Figura 7 esquematiza o processo realizado pela DWNN.

4.2 Experimentos propostos

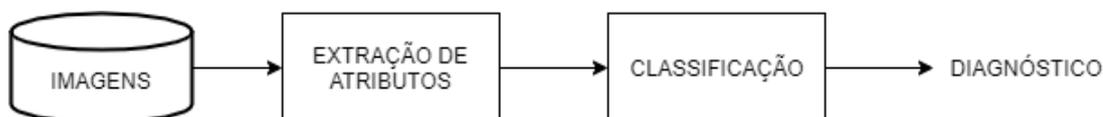
Para o desenvolvimento do sistema, foi necessário avaliar o comportamento de técnicas computacionais com as bases de imagens utilizadas. A Figura 8 apresenta um esquema geral do método utilizado para analisar as imagens de ambos os tipos, no intuito de verificar o desempenho de diversos algoritmos para identificar e classificar diferentes lesões de mama.

Figura 7 – Esquema geral da DWNN



Fonte: A Autora (2019).

Figura 8 – Método utilizado para validação da máquina de aprendizado



Fonte: A Autora (2019).

4.2.1 Bases de dados

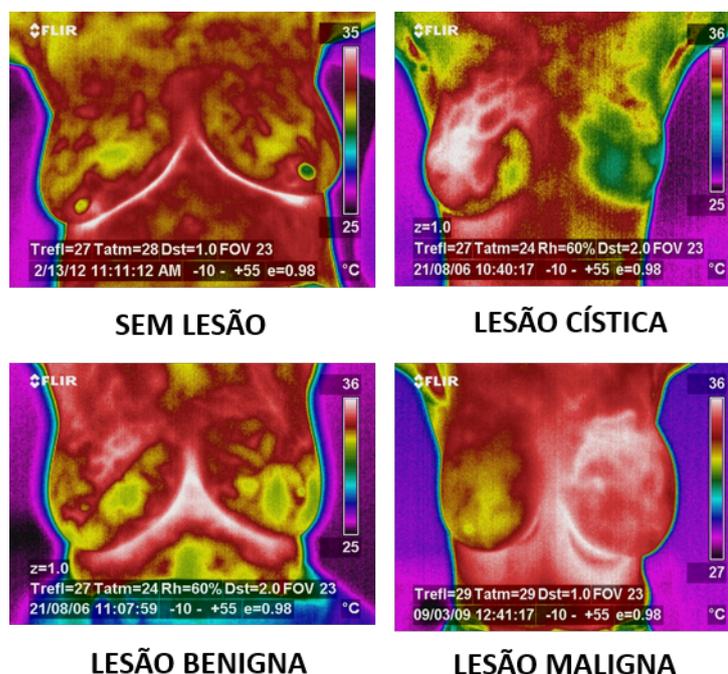
Nessa seção são apresentadas as descrições das bases de dados, desde sua composição até os procedimentos específicos utilizados para analisá-las.

4.2.1.1 Termografia

A base de imagens termográficas de mama utilizada é a do Laboratório de Imagens Térmicas do Departamento de Engenharia Mecânica da UFPE, coordenado pela Profa. Rita de Cássia Fernandes de Lima e obtidas a partir de ações de extensão realizadas em parceria com o Hospital das Clínicas da UFPE junto a mulheres da Zona da Mata Norte de Pernambuco e da Região Metropolitana do Recife, sob o registro de número 279/05 no Comitê de Ética em Pesquisa do Departamento de Ciências da Saúde da Universidade Federal de Pernambuco (CEP/CCS/UFPE).

A base é composta por 1052 imagens termográficas de mama (480×640 pixels), adquiridas a partir de uma câmera infravermelha da marca FLIR, modelo ThermaCAMTM S45, de sensibilidade térmica de $0,06^\circ\text{C}$. Tais imagens são agrupadas em 4 classes distintas, de acordo com o diagnóstico associado a elas, podendo ser de cisto, lesão maligna, lesão benigna e sem lesão, tal como ilustrado na Figura 9. Todos os diagnósticos foram estabelecidos após a investigação prévia utilizando exames específicos para cada situação, no caso de cistos, o diagnóstico foi confirmado por punção aspirativa com agulha fina (PAAF) ou ultrassonografia, as lesões malignas e benignas foram confirmadas através de biópsias e os casos da classe sem lesão foram verificados por exames de mamografia e ultrassonografia, classificados como BI-RADS 1, ou seja, sem achados (SILVA, 2015).

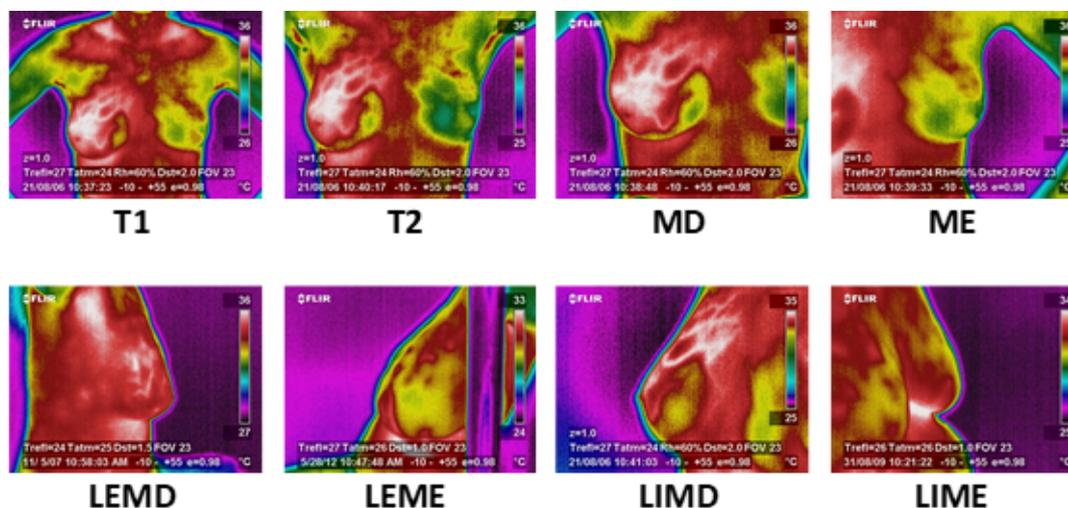
Figura 9 – Exemplos de imagens de cada uma das possíveis classes do banco de dados de termografias de mama. No canto superior esquerdo encontra-se um exemplo da classe sem lesão; logo ao seu lado, no canto superior direito, está uma imagem contendo lesão do tipo cística. As imagens inferiores esquerda e direita são, respectivamente, de lesões benigna e maligna.



Fonte: A Autora (2018).

Na base de dados existem também imagens adquiridas em 8 posições diferentes, sendo duas imagens frontais de ambas as mamas (T1 e T2), uma imagem frontal de cada uma das mamas isoladas (MD e ME) e quatro imagens laterais (LEMD, LEME, LIMD e LIME). A diferença entre as imagens T1 e T2 está no posicionamento dos braços em cada uma delas, em T1 os braços estão na cintura, enquanto que em T2 eles estão para cima. Quanto as imagens laterais, LEMD e LEME representam registros das laterais externas das mamas direita e esquerda, respectivamente; já LIMD e LIME são imagens da lateral interna de cada uma das mamas. Exemplos de cada uma dessas posições são apresentados na Figura 10.

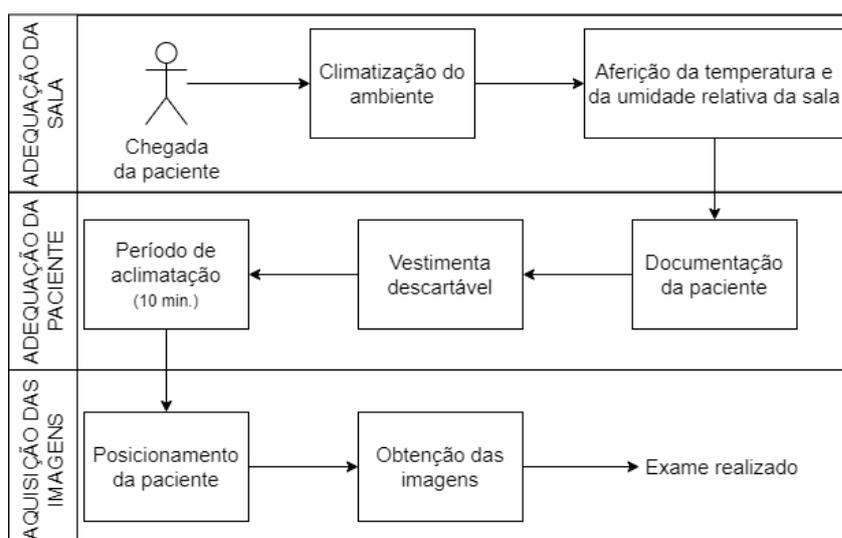
Figura 10 – Posições utilizadas na realização do exame de termografia de mama. Na porção superior esquerda estão T1 e T2, que são imagens frontais de ambas as mamas, com os braços em posicionamentos distintos. MD apresenta a imagem frontal apenas da mama direita, enquanto que ME mostra a mama esquerda nessa mesma posição. As imagens inferiores são de vistas laterais, sendo LEMD e LEME imagens da lateral externa das mamas direita e esquerda, respectivamente; LIMD e LIME correspondem à visão lateral interna de cada mama.



Fonte: A Autora (2018).

As imagens foram adquiridas seguindo o protocolo descrito por Oliveira (2012). Antes das aquisições, foi necessário realizar uma série de preparações, das pacientes e da sala de aquisição, visto que o contato entre partes do corpo e o ambiente, ou outras partes do corpo, alteram a temperatura de superfície através do processo de condução de calor. Tais procedimentos encontram-se descritos no diagrama da Figura 11.

Figura 11 – Procedimentos de preparação para a aquisição das imagens termográficas

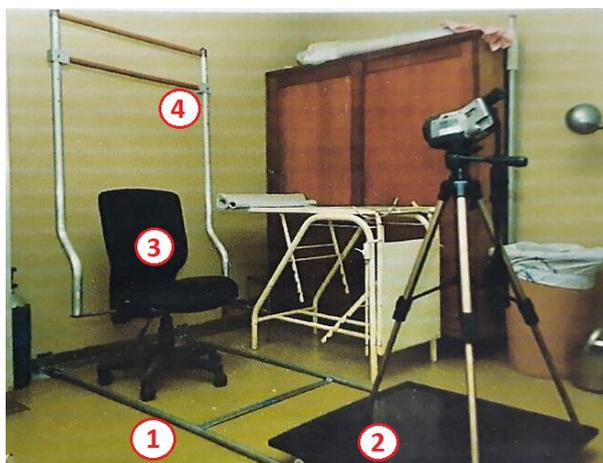


Fonte: A Autora (2019).

Para a padronização das aquisições, no intuito de evitar alterações no posicionamento dos pacientes durante o processo, foi utilizado um aparato mecânico (OLIVEIRA, 2012). A partir desse aparato, ilustrado na Figura 12, a paciente permanece sentada na

cadeira giratória (em 3) durante o exame, a qual é movimentada para alterar o ângulo da imagem. A câmera é posicionada em um tripé, que é colocado em cima de um suporte (2) que se movimenta para mais perto ou mais distante da paciente através dos trilhos (em 1). As barras horizontais (em 4) são utilizadas para o correto posicionamento dos braços das pacientes. Foram adquiridas, no mínimo, oito imagens por paciente, uma em cada posição; em alguns casos específicos foi necessário obter algumas imagens extras.

Figura 12 – Aparato mecânico utilizado na sala de aquisição. Em (1) encontram-se os trilhos utilizados para mover o suporte da câmera (2) em direção à paciente, posicionada na cadeira giratória apresentada em (3); as barras em (4) são utilizadas para o posicionamento dos braços durante o exame.



Fonte: Adaptado de Oliveira (2012).

No presente trabalho utilizou-se apenas as imagens T1 e T2, visto que esse posicionamento favorece a visualização de ambas as mamas e a identificação de possíveis anomalias e questões relacionadas à assimetrias. Dessa maneira, foram utilizadas 336 imagens, distribuídas nas 4 classes de acordo com o apresentado na Tabela 6. Visto que a quantidade de imagens por classe é diferente, foi adicionada uma etapa de balanceamento de classes para evitar vieses na classificação, visto que, com bases desbalanceadas, os algoritmos tendem a favorecer classes com mais representantes em detrimento das classes menos populosas. Nesse sentido, o balanceamento foi feito a partir da inserção de instâncias sintéticas, provenientes da combinação linear de instâncias reais (LIMA; SILVA-FILHO; SANTOS, 2016). Esse processo resultou em um total de 968 instâncias, divididas igualmente entre as classes.

Tabela 6 – Quantidade de imagens por classe

| | Cisto | Lesão Benigna | Lesão Maligna | Sem Lesão |
|--------------------------|--------------|----------------------|----------------------|------------------|
| Número de imagens | 73 | 121 | 76 | 66 |

Fonte: A Autora (2019).

As imagens de termografia utilizam a técnica de pseudo-cor, através da qual diferentes tons de RGB correspondem a diferentes valores de temperatura, de maneira

que é possível obter a matriz de temperatura de uma imagem termográfica executando a transformação inversa de pseudo-cores em temperatura. Contudo, para o processamento das imagens e padronização das informações das pseudo-cores, evitando erros devido às diferentes paletas de cores usadas na aquisição das imagens, foi necessário realizar uma conversão de RGB-JET para níveis de cinza, mapeando a matriz de temperatura para 0 a 255 níveis de cinza (8 bits). Nesse processo, os tons mais claros da escala de cinza indicam temperaturas mais altas e vice-versa. Além disso, as imagens foram analisadas em sua totalidade, sem nenhum tipo de segmentação, utilizando, portanto, a análise baseada em contexto. Apesar delas conterem informações como barras, números e etiquetas, considerou-se que, como essas informações estão sempre presentes e na mesma posição, os algoritmos as interpretaria como redundantes ou não relevantes para diferenciar as classes.

4.2.1.2 Mamografia

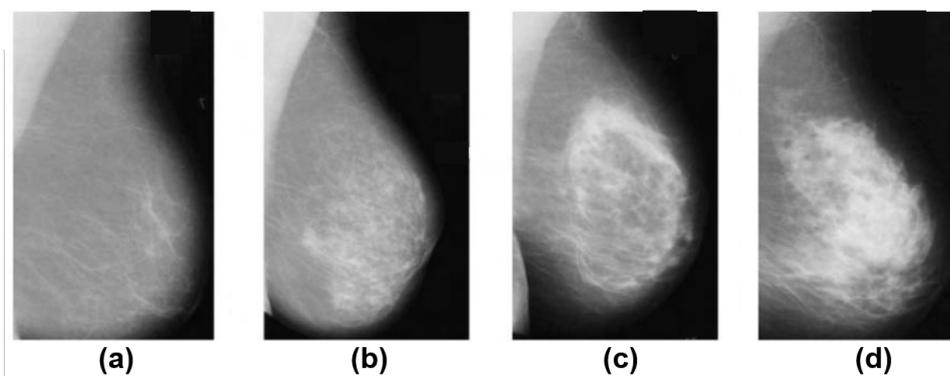
A base de imagens de mamografias adotada é a base *Image Retrieval in Medical Applications* (IRMA), com 2796 imagens (128×128 pixels) de regiões de interesse (ROI), desenvolvida na Aachen University of Technology, Alemanha, e cedida ao Grupo de Pesquisas em Computação Biomédica da UFPE, para uso acadêmico, pelo Prof. Thomas Deserno (DESERNO et al., 2012). O repositório IRMA foi montado a partir de quatro outras bases públicas:

- a) 150 imagens da base MIAS (*Mammographic Image Analysis Society*) (SUCKLING et al., 1994);
- b) 2576 imagens da DDSM (*Digital Database for Screening Mammography*) (HEATH et al., 2000);
- c) 1 imagem da base LLN (*Lawrence Livermore National Laboratory*, EUA);
- d) 69 imagens do Departamento de Radiologia da Aachen University of Technology (RWTH), Alemanha.

Nessa base as imagens são divididas de duas maneiras: pelo tipo de densidade tecidual predominante na mama e pelo diagnóstico associado ao caso clínico da paciente. Em relação ao tipo de tecido, são divididas em quatro, de acordo com a classificação BI-RADS (*Breast Imaging Reporting and Data System*) (D'ORSI et al., 1998): tecido adiposo (tipo I), tecido fibroglandular (tipo II), tecido heterogeneamente denso (tipo III) e tecido extremamente denso (tipo IV). A Figura 13 apresenta exemplos de cada uma dessas classes de tecidos mamários. Quanto ao diagnóstico associado a cada imagem, existem três classes possíveis: mamas saudáveis, com lesão maligna e com lesão benigna. Todos os diagnósticos foram

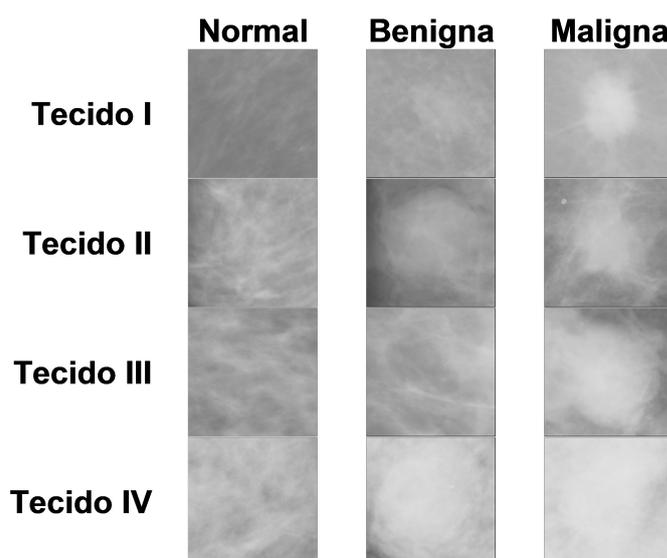
previamente estabelecidos por especialistas e utilizados para redimensionar as imagens de mamografia, isolando apenas as ROI, como ilustrado na Figura 14.

Figura 13 – Mamogramas dos diferentes tecidos mamários: (a) adiposo (tipo I), (b) fibroglandular (tipo II), (c) heterogeneamente denso (tipo III) e (d) extremamente denso (tipo IV).



Fonte: Adaptado de Silva (2017).

Figura 14 – Exemplos de imagens da base IRMA



Fonte: A Autora (2019).

Nesse trabalho foram utilizadas todas as imagens da base IRMA, as quais foram organizadas em 6 bancos de dados, sendo 4 apenas com as imagens de cada tipo de tecido, isoladamente e 2 com todas as imagens, mas uma com 3 classes (normal, benigna e maligna), onde não houve distinção de tecido, e outra com 12 classes, em que foram utilizadas as três classes, mas considerando cada tipo de tecido. A Tabela 7 detalha a organização das bases de dados de mamografia utilizadas no presente estudo. Vale ressaltar que a base IRMA utilizada já foi previamente balanceada, então a quantidade de imagens é igualmente distribuída entre os grupos/classes. Além disso, não foi necessário realizar nenhum tipo de conversão, visto que as imagens já são adquiridas em níveis de cinza.

Tabela 7 – Organização das bases de dados de mamografia

| Base de dados | Classes | Nº de imagens |
|----------------------|---|----------------------|
| Tecido I | 3 classes: I-normal, I-benigna e I-maligna | 699 |
| Tecido II | 3 classes: II-normal, II-benigna e II-maligna | 699 |
| Tecido III | 3 classes: III-normal, III-benigna e III-maligna | 699 |
| Tecido IV | 3 classes: IV-normal, IV-benigna e IV-maligna | 699 |
| Todos - 3 | 3 classes: normal, benigna e maligna | 2796 |
| Todos - 12 | 12 classes: I-normal, I-benigna, I-maligna, II-normal, II-benigna, II-maligna, III-normal, III-benigna, III-maligna, IV-normal, IV-benigna e IV-maligna | 2796 |

Fonte: A Autora (2019).

4.2.2 Extração de atributos

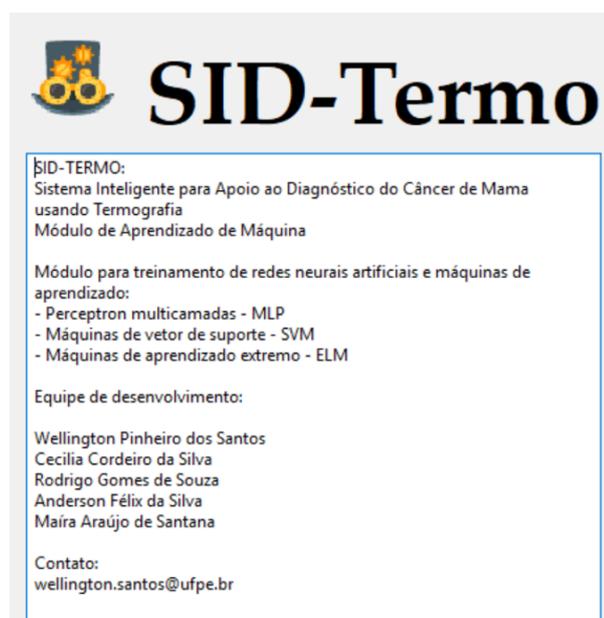
A extração de atributos consiste em representar os dados (imagens) a partir de um conjunto de características que tenham significado computacional, ou seja, descrever uma imagem de forma que a máquina (computador) consiga interpretá-la. Dado que uma máquina representa e processa informações de forma diferente de como o cérebro humano se comporta, os atributos comumente se apresentam na forma de valores reais que, muitas vezes, não possuem significado humano, mas que são facilmente compreendidos pela máquina. Os atributos extraídos de uma imagem são organizados na forma de um vetor linha, no qual cada coluna representa um atributo. Como o processo de extração é realizado para todas as imagens, o banco de dados passa então a ser organizado em um arquivo do tipo *.ARFF (Attribute Relation File Format)*, o qual possui uma matriz de dimensão $(n_{imagens}, n_{atributos})$, ou seja, cujas linhas representam cada uma das imagens do banco, enquanto que cada coluna corresponde a um atributo. Além disso, nesse arquivo também é apontada a classe da qual cada imagem faz parte, ou seja, o diagnóstico associado a cada imagem, visto que os métodos utilizados para classificação são de aprendizagem supervisionada.

No presente trabalho, para ambas as bases de imagens, foram experimentadas duas maneiras distintas de representar os dados. Na primeira delas, utilizou-se os momentos de Haralick e Zernike como extratores de atributos, representando uma imagem a partir de 168 atributos. A segunda maneira consistiu em utilizar o método *Deep-Wavelet Neural Network (DWNN)*, com 4 filtros e 5 camadas, resultando, portanto, em 1024 atributos. Nesse trabalho

foram experimentadas todas as 5 funções para o bloco de síntese (máximo, média, mínimo, mediana e moda) da DWNN.

Para essa etapa, foi utilizado o *software* SID-Termo (Figura 15), desenvolvido ao longo desse projeto. O SID-Termo consiste em um módulo de aprendizado de máquina, nele estão implementados diversos algoritmos para extrair atributos capazes de representar as imagens de entrada. Além disso, é possível aplicar alguns métodos de pré-processamento nos dados, conversão de imagens e balanceamento de classes, todos com o intuito de melhorar a representação das imagens e, conseqüentemente, otimizar os resultados adquiridos. Tais métodos de extração de atributos e de pré e pós processamento podem ser escolhidos no SID-Termo, como demonstrado na Figura 16. Alguns algoritmos de classificação também encontram-se implementados no SID-Termo, tais como redes neurais perceptron multicamadas, máquinas de vetor de suporte e máquinas de aprendizado extremo.

Figura 15 – Janela de inicialização do SID-Termo



Fonte: A Autora (2019).

4.2.3 Classificação

Após a etapa de extração de atributos, foram realizados testes com diversos algoritmos para classificação das imagens em suas respectivas classes de diagnóstico. Nessa etapa, testou-se classificadores comumente utilizados, no intuito de avaliar seus desempenhos para ambas as bases aqui utilizadas. Foram realizados testes com rede Bayesiana (Bayes Net), classificador ingênuo de Bayes (Naive Bayes), Perceptron Multicamadas (MLP), Máquina de Vetor de Suporte (SVM), Máquinas de Aprendizado Extremo (ELM), Máquinas Morfológicas de Aprendizado Extremo (mELM), além dos classificadores baseados em

Figura 16 – Janela do SID-Termo para seleção dos atributos

Fonte: A Autora (2019).

árvores de busca: J48, Random Tree e Random Forest. As configurações para cada um dos classificadores estão apresentadas na Tabela 8.

Para essa etapa, utilizou-se os ambientes WEKA (The Waikato Environment for Knowledge Analysis), versão 3.8.1, desenvolvido na University of Waikato, Nova Zelândia (HALL et al., 2009); e GNU Octave, versão 4.0.3 (EATON et al., 2018). Após a verificação do desempenho de diversos algoritmos para identificar e classificar diferentes lesões de mama, foram escolhidos os métodos mais adequados para lidar com cada um dos tipos de imagens.

Todos os testes foram realizados utilizando o método de validação cruzada do tipo $k - fold$, com 10 $folds$ (JUNG; HU, 2015). Nesse método, o conjunto completo de dados é aleatoriamente dividido em k subconjuntos com aproximadamente o mesmo tamanho, nesse caso, $k = 10$. Cada subconjunto é separado, um por um, para teste, enquanto que os nove restantes são utilizados para treino. O resultado final é, portanto, a média dos resultados obtidos com cada um dos 10 conjuntos. A utilização desse método reduz a variabilidade dos resultados, proporcionando mais robustez e confiabilidade ao treinamento e diminuindo a chance de ocorrência de *overfitting*. Além disso, cada configuração de classificador foi testada 30 vezes, com o intuito de obter informações estatísticas para comparação dos métodos. Os resultados obtidos para ambas as bases serão apresentados no Capítulo 5.

Para a avaliação do desempenho dos classificadores foram utilizadas as métricas de acurácia, índice Kappa e matriz de confusão. A acurácia (A_c) corresponde ao percentual de instâncias corretamente classificadas e pode variar de 0 a 100% (KRUMMENAUER; DOLL, 2000). Essa métrica é calculada a partir da Equação 4.1, onde $n_{corretas}$ consiste no número

Tabela 8 – Configuração dos classificadores

| Classificador | Parâmetros |
|---------------|---|
| Bayes Net | - |
| Naive Bayes | - |
| MLP | Camadas escondidas: 1 Neurônios na camada escondida: 10; 50 e 100 Taxa de aprendizado: 0.3 Momentum: 0.2 Iterações: 500 |
| SVM | Kernel: linear, polinomial (E: 2; 3; 4 e 5) e RBF (γ : 0,01; 0,25 e 0,50) |
| J48 | - |
| Random Tree | - |
| Random Forest | Árvores: 10; 50 e 100 |
| ELM | Neurônios na camada escondida: 100 Kernel: sigmoidal, dilatação* e erosão* *mELM |

Fonte: A Autora (2019).

de instâncias corretamente classificadas e n_{total} é o número total de instâncias.

$$Ac = \frac{n_{corretas}}{n_{total}} * 100\% \quad (4.1)$$

O índice, ou coeficiente, Kappa (κ) é uma métrica estatística para avaliar a concordância entre os resultados obtidos e os esperados (MCHUGH, 2012; LANDIS; KOCH, 1977). O índice pode variar no intervalo [-1,1], onde valores menores ou iguais a 0 (zero) indicam nenhuma concordância entre os resultados, valores acima de 0,8 demonstram alta concordância e os valores intermediários representam uma concordância baixa ou moderada. O Kappa fornece informação sobre o grau de reprodutibilidade do método e é calculado conforme indicado na Equação 4.2, onde P_{obtido} representa o valor observado e $P_{esperado}$ consiste no valor esperado.

$$\kappa = \frac{P_{obtido} - P_{esperado}}{1 - P_{esperado}} \quad (4.2)$$

A matriz de confusão, por sua vez, apresenta o número de instâncias classificadas em cada uma das possíveis classes. A diagonal principal da matriz apresenta as instâncias corretamente classificadas, são os verdadeiros positivos (VP) e negativos (VN). Os demais valores representam as instâncias cujas classes foram confundidas, ou seja, foram classificadas erroneamente. A partir dessa matriz é possível observar quais classes se confundem mais, além de ser possível calcular a sensibilidade e a especificidade associadas àquela classificação, as quais são métricas essenciais para avaliar a eficiência de sistemas para diagnósticos, visto que estão, respectivamente, relacionadas às taxas de falso negativo (FN)

e falso positivo (FP). Dada a matriz apresentada na Tabela 9, a sensibilidade é calculada a partir da Equação 4.3 e a especificidade através da Equação 4.4.

Tabela 9 – Exemplo de matriz de confusão

| | Classe 1 | Classe 2 |
|----------|----------|----------|
| Classe 1 | VP | FP |
| Classe 2 | FN | VN |

Fonte: A Autora (2019).

$$Sensibilidade = \frac{VN}{VN + FN} \quad (4.3)$$

$$Especificidade = \frac{VP}{VP + FP} \quad (4.4)$$

Por fim, a eficiência geral do sistema pode ser calculada a partir da relação entre a sensibilidade e a especificidade apontada na Equação 4.5.

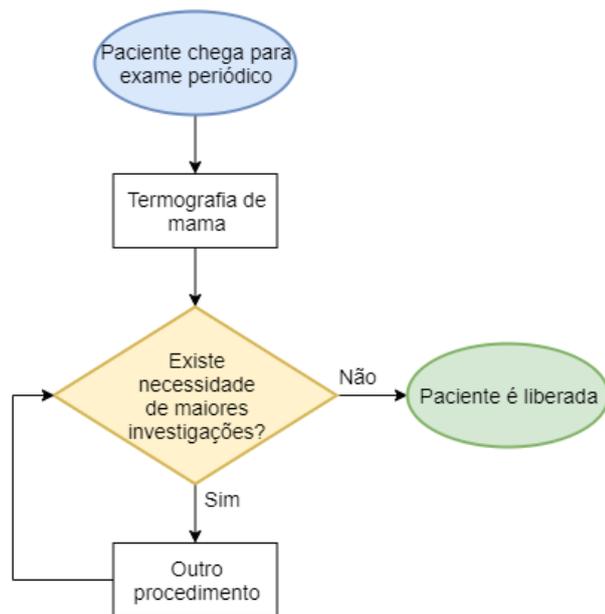
$$Eficiencia = \frac{Sensibilidade + Especificidade}{2} \quad (4.5)$$

4.3 Considerações

Neste trabalho foram verificados os desempenhos de diversos classificadores inteligentes e diferentes métodos de representação de imagens para detectar e classificar lesões de mama em imagens termográficas e mamográficas. No geral, foram utilizadas 336 imagens de 480×640 pixels de termografia de mama e 2796 imagens de 128×128 pixels de regiões de interesse de mamografias. Os métodos de Haralick, Zernike e DWNN foram utilizados para extração de atributos, tendo, esse último, sido desenvolvido ao longo do presente estudo. Os testes de classificação foram realizados com redes bayesianas, MLP, SVM, ELM e algoritmos de árvores de busca, utilizando os softwares WEKA e GNU Octave.

Neste capítulo, foi apresentado o método proposto para a análise de imagens de mamografia e termografia de mama, bem como foram discutidas as ponderações e justificativas para as escolhas feitas ao longo do processo. Nesse trabalho, propõe-se ainda um fluxo de usabilidade do sistema inteligente proposto, como apresentado na Figura 17, a partir do qual deve-se inicialmente utilizar a termografia para a triagem de pacientes, visto que é um método seguro e indolor, de forma que pode ser utilizado repetidamente sem acarretar em danos para a paciente. Em seguida, caso seja necessário, a paciente deverá ser direcionada para procedimentos mais específicos e robustos, como a mamografia e procedimentos invasivos.

Figura 17 – Fluxo de usabilidade do sistema proposto



Fonte: A Autora (2020).

5 RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados os resultados relacionados ao desempenho dos diferentes algoritmos experimentados, de acordo com o método proposto. Os resultados foram avaliados de maneiras quantitativa e qualitativa, a partir das métricas de acurácia, índice kappa, matriz de confusão, sensibilidade, especificidade e eficiência.

5.1 Resultados Termografia

Nessa seção são, inicialmente, apresentados os resultados obtidos utilizando os momentos de Haralick e Zernike para extrair os atributos das imagens de termografia de mama. Em seguida, são apresentados os resultados utilizando o método DWNN para realizar a extração dos atributos.

5.1.1 Momentos de Haralick e Zernike e Termografia

No primeiro momento, os momentos de Haralick e Zernike foram explorados para extração de atributos das imagens de termografia. Foram realizados diversos experimentos, com diferentes combinações desses descritores (PEREIRA et al., 2017; SANTANA et al., 2017; SANTANA et al., 2018; SANTANA et al., 2018). No geral, tais experimentos demonstraram que a utilização de ambos os descritores ao mesmo tempo favorece a representação das imagens em questão, melhorando, portanto, o desempenho da classificação. A Tabela 10 apresenta a média e desvio padrão (DP) dos resultados obtidos a partir da utilização dessa técnica, para as melhores configurações dos métodos de classificação. Nessa situação, a melhor configuração para o MLP foi com 100 neurônios na camada escondida; os melhores resultados para o SVM foram obtidos com o *kernel* polinomial de grau 4; para a *Random Forest*, a utilização de 100 árvores resultou no melhor desempenho desse classificador e, por fim, para o ELM, melhores resultados foram obtidos com o *kernel* dilatação. Os resultados para todas as configurações testadas podem ser encontrados na Tabela A1 do Apêndice A.

Os gráficos da Figura 18 ilustram, além das médias, informações estatísticas provenientes dos resultados obtidos utilizando os descritores de Haralick e Zernike para extração de atributos. Em (a) estão apresentados os resultados de acurácia, enquanto que em (b) são apresentados os índices kappa.

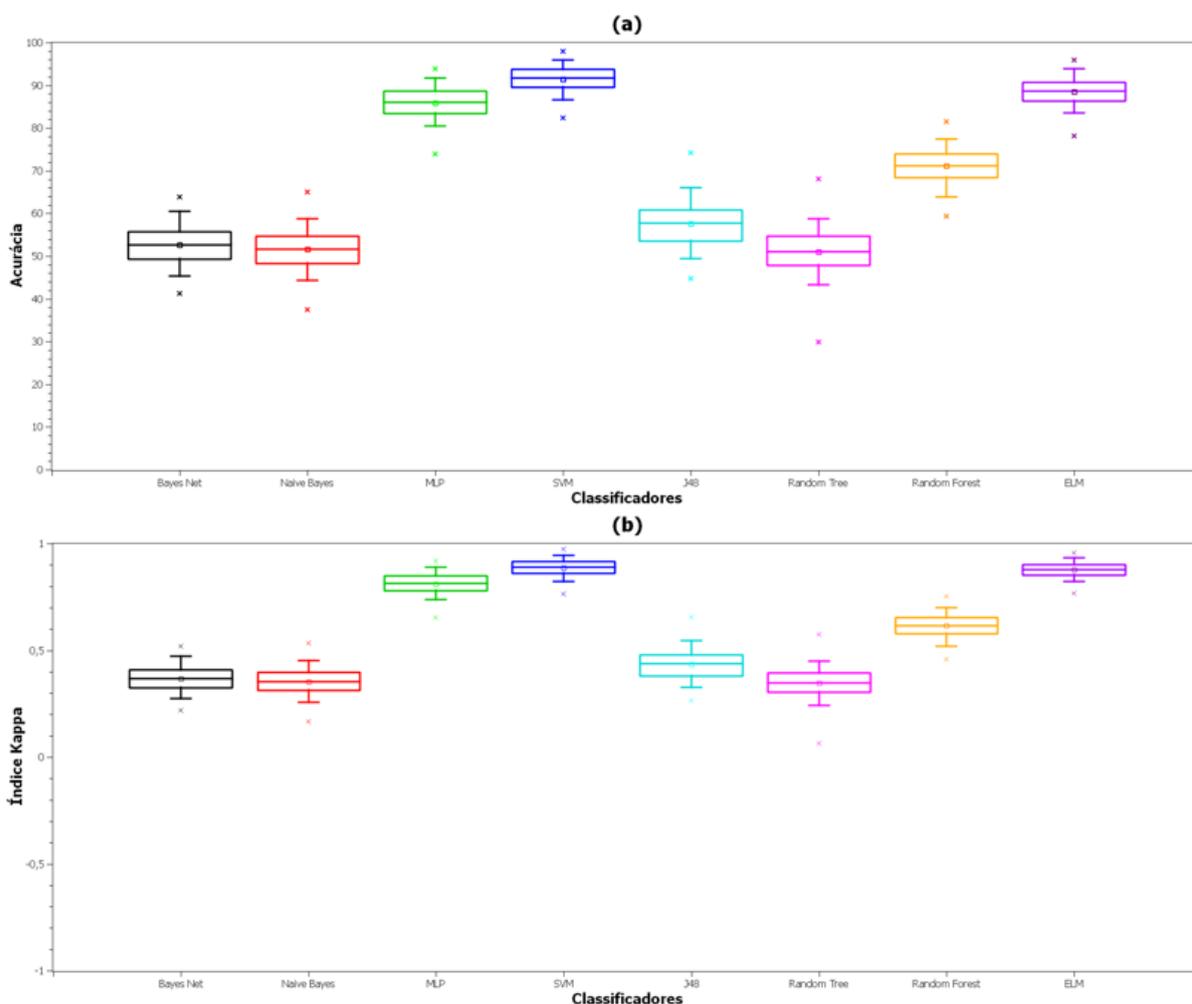
A partir da Tabela 10 e dos gráficos da Figura 18, é possível observar um destaque positivo do algoritmo SVM, com acurácia média de 91,41% e kappa médio de 0,89. Desempenhos bem próximos ao do SVM foram obtidos utilizando ELM e MLP. Um pouco mais

Tabela 10 – Resultados de acurácia e kappa utilizando Haralick e Zernike para extração de atributos e imagens de Termografia

| Classificador | Acurácia (%) | | Índice Kappa | |
|---------------|--------------|-------------|--------------|-------------|
| | Média | DP | Média | DP |
| Bayes Net | 52,56 | 4,50 | 0,37 | 0,06 |
| Naive Bayes | 51,54 | 4,58 | 0,35 | 0,06 |
| MLP | 85,90 | 3,57 | 0,81 | 0,05 |
| SVM | 91,41 | 2,91 | 0,89 | 0,04 |
| J48 | 57,58 | 5,01 | 0,43 | 0,07 |
| Random Tree | 51,01 | 5,00 | 0,35 | 0,07 |
| Random Forest | 71,11 | 4,17 | 0,61 | 0,06 |
| ELM | 88,49 | 3,25 | 0,88 | 0,03 |

Fonte: A Autora (2019).

Figura 18 – Boxplot dos resultados de (a) acurácia e (b) kappa utilizando Haralick e Zernike para extração de atributos e imagens de Termografia



Fonte: A Autora (2019).

abaixo está a *Random Forest*. Os piores resultados foram obtidos pelos classificadores bayesianos e as árvores *J48* e *Random Tree*, cujas acurácias ficaram em torno de 50%, com índice kappa entre 0,35 e 0,43. Quanto à dispersão dos dados, que podem ser visualizadas

Tabela 11 – Resultados de acurácia e kappa utilizando DWNN com função média para extração de atributos e imagens de Termografia

| Classificador | Acurácia (%) | | Índice Kappa | |
|---------------|--------------|-------------|--------------|-------------|
| | Média | DP | Média | DP |
| Bayes Net | 49,77 | 4,62 | 0,33 | 0,06 |
| Naive Bayes | 49,30 | 4,52 | 0,32 | 0,06 |
| MLP | 95,88 | 1,94 | 0,95 | 0,02 |
| SVM | 99,13 | 0,92 | 0,99 | 0,01 |
| J48 | 51,63 | 4,91 | 0,36 | 0,06 |
| Random Tree | 46,24 | 4,74 | 0,28 | 0,06 |
| Random Forest | 84,69 | 3,53 | 0,80 | 0,05 |
| ELM | 74,15 | 4,94 | 0,72 | 0,05 |

Fonte: A Autora (2019).

na Figura 18, os métodos apresentaram resultados semelhantes, contudo, os classificadores SVM e ELM obtiveram dispersões levemente menores que os demais, para ambas as métricas. Foi ainda observado que a dispersão associada ao índice kappa é, no geral, menor do que a da métrica de acurácia. Vale ressaltar que a dispersão é inversamente associada à confiabilidade dos resultados, de maneira que quanto menor a dispersão, maior é a confiabilidade do método.

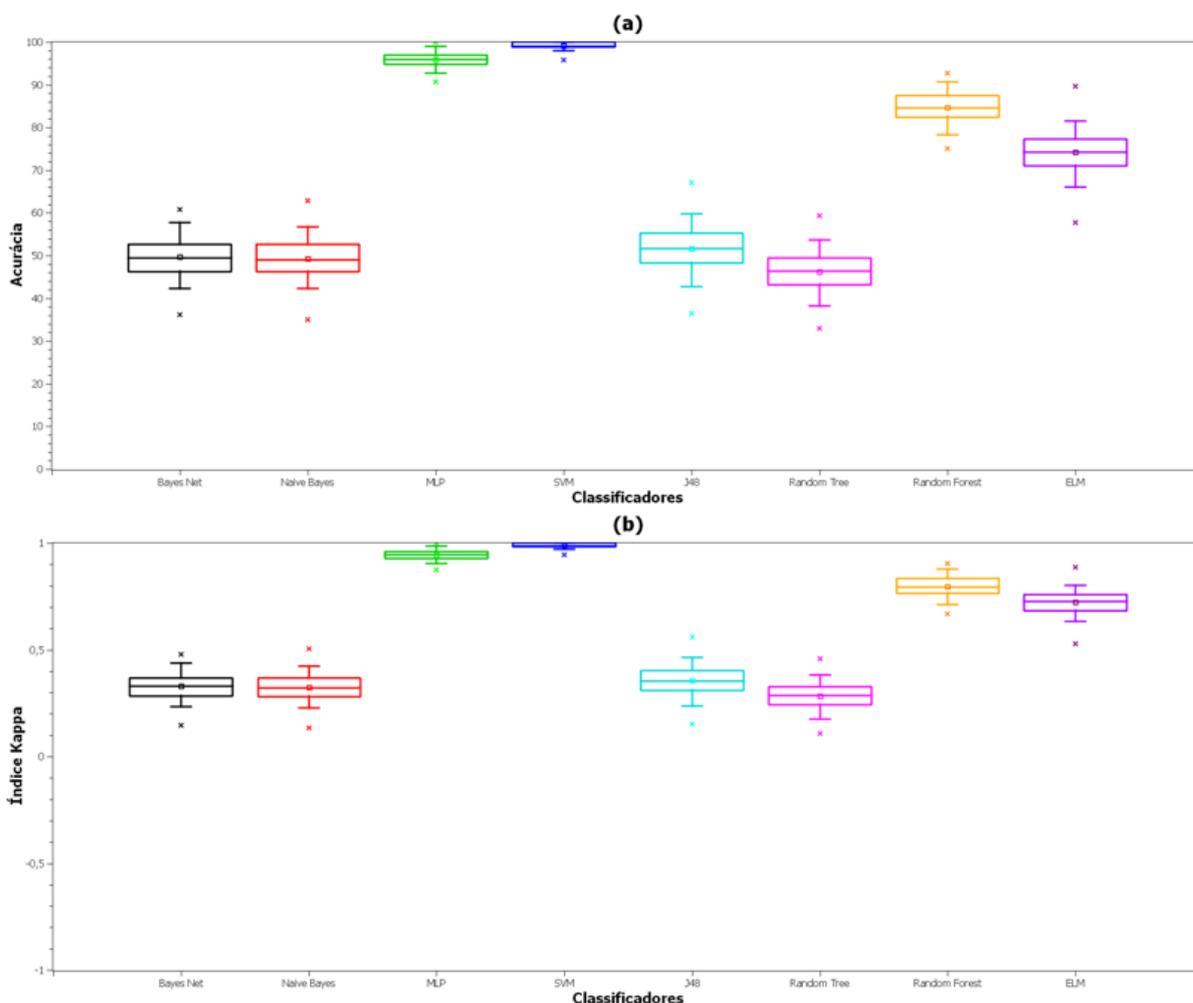
5.1.2 Deep-Wavelet Neural Network e Termografia

Em relação a base de dados obtidas a partir da extração de atributos utilizando a DWNN, foram realizados testes para as diferentes funções do bloco de síntese (SB), tal como anteriormente mencionado. Os resultados para as melhores configurações dos classificadores são apresentadas na Tabela 11. A Tabela A2 do Apêndice A apresenta os resultados expandidos, com todas as configurações testadas.

Para essa base de dados, a melhor representação das imagens foi obtida a partir da utilização da função de média. Mais uma vez, os melhores desempenhos com MLP foram obtidos com 100 neurônios da camada escondida e com 100 árvores na *Random Forest*. Para os métodos SVM e ELM, no entanto, as configurações que resultaram nos melhores desempenhos foram, respectivamente, com *kernel* linear e com *kernel* morfológico de erosão. Tais resultados podem ser visualizados, a partir de uma perspectiva estatística, nos gráficos apresentados na Figura 19.

Os experimentos realizados demonstraram que, assim como no caso anterior, os classificadores SVM e MLP se destacaram em relação aos demais, apresentando, inclusive, uma melhora significativa no desempenho de classificação. No caso da SVM, tanto a acurácia quanto o índice kappa chegaram próximos aos valores máximos, cujos valores médios foram de 99,13% e 0,99, respectivamente. Esse método também se destacou por apresentar os menores valores de desvio padrão, resultando em uma baixa dispersão dos

Figura 19 – Boxplot dos resultados de (a) acurácia e (b) kappa utilizando DWNN para extração de atributos e imagens de Termografia



Fonte: A Autora (2019).

resultados. Houve também um aumento no desempenho da *Random Forest*, tanto em relação à acurácia, como em relação ao índice kappa. Quanto a ELM, foi observada uma queda de mais de 10% no desempenho desse classificador, quando comparado com os resultados para a base de dados utilizando os atributos de Haralick e de Zernike. Mais uma vez, os classificadores bayesianos e as árvores J48 e *Random Tree* apresentaram os desempenhos menos satisfatórios, sendo ainda piores do que com a base de dados analisada anteriormente, com valores de acurácias menores do que 50% e índice kappa de, no máximo, 0,33.

5.2 Resultados Mamografia

Para a base de regiões de interesse de mamografias, inicialmente foi verificada a eficácia do método DWNN para representar as imagens de mamografia, extrapolando a abordagem utilizada para as imagens de Termografia. Em seguida, foi experimentada

a extração de atributos com os momentos de Haralick e de Zernike, contudo, para esse caso, foram analisadas apenas dois cenários, o de imagens de mamas classificadas como adiposas (tecido I), visto que consiste na constituição mamária predominante nas mulheres que são submetidas ao exame de mamografia; e o com todos os tecidos e 3 classes, para verificar o desempenho do método na situação em que há uma maior variabilidade de constituições mamárias.

5.2.1 Deep-Wavelet Neural Network e Mamografia

A Tabela 13 apresenta os resultados de acurácia e kappa para as bases de dados em que os tipos de tecidos foram analisados individualmente. Na Tabela 14, estão os resultados para as duas bases de dados em que foram utilizadas as imagens de todos os tecidos, sendo uma com 3 classes e outra com 12 classes, como explicitado no Capítulo 4. As Tabelas A3-A8 do Apêndice A, apresentam os resultados expandidos para cada uma das bases de dados.

Como mencionado anteriormente, foram testadas mais de uma configuração para os classificadores MLP, SVM, *Random Forest* e ELM. Além disso, com a DWNN, experimentou-se as 5 diferentes funções para o bloco de síntese (máximo, média, mínimo, mediana e moda). Dessa maneira, a Tabela 12 apresenta as configurações desses classificadores e do bloco de síntese que resultaram nos melhores resultados para cada uma das bases de dados estudadas, os quais estão expostos nas Tabelas 13 e 14. A partir da Tabela 12, nota-se que as funções de máximo e de média não favoreceram a representação de nenhuma das bases de dados. O tecido I e a base com todos os tecidos e 3 classes foram melhor representados pela função de mínimo, a de mediana descreveu melhor os tecidos II e III, enquanto que a função moda representou melhor as bases do tecido IV e com todos os tecidos e 12 classes.

Quanto a comparação entre os métodos de classificação, o SVM se mostrou eficaz na identificação e diferenciação das lesões de mama em todas as constituições teciduais avaliadas, alcançando mais de 90% de acurácia e índice kappa superior a 0,90 em todas situações. Vale ressaltar que o SVM também obteve baixos valores de dispersão, podendo ser considerado o melhor classificador, dentre os testados nessa proposta.

Ainda em relação a esses resultados, esperava-se que a classificação fosse melhor para a base de dados com mamas adiposas, visto que a coloração desse tecido se diferencia mais da de lesões, em imagens de mamografia, quando comparada a de outros tecidos. No entanto, utilizando a DWNN para descrever as imagens, os algoritmos tiveram um melhor desempenho na identificação de lesões em mamas fibrosas (tecido II) e heterogeneamente densas (tecido III), com acurácia máxima de 98,80% e kappa de 0,98, quanto utilizada a SVM com kernel RBF e γ igual a 0,25. Na base com o tecido adiposo, a maior acurácia foi

Tabela 12 – Melhores configurações para cada base de dados dos experimentos com Mamografia utilizando DWNN.

| Base | Melhor função | Melhores configurações |
|-------------|----------------------|---|
| Tecido I | Mínimo | MLP: 10 neurônios SVM: kernel polinomial (E=2) <i>Random Forest</i> : 100 árvores ELM: kernel dilatação |
| Tecido II | Mediana | MLP: 100 neurônios SVM: kernel RBF ($\gamma=0,25$) <i>Random Forest</i> : 100 árvores ELM: kernel erosão |
| Tecido III | Mediana | MLP: 50 neurônios SVM: kernel RBF ($\gamma=0,25$) <i>Random Forest</i> : 100 árvores ELM: kernel erosão |
| Tecido IV | Moda | MLP: 100 neurônios SVM: kernel polinomial (E=2) <i>Random Forest</i> : 100 árvores ELM: kernel erosão |
| Todos - 3 | Mínimo | MLP: 10 neurônios SVM: kernel polinomial (E=2) <i>Random Forest</i> : 100 árvores ELM: kernel erosão |
| Todos - 12 | Moda | MLP: 100 neurônios SVM: kernel polinomial (E=2) <i>Random Forest</i> : 100 árvores ELM: kernel dilatação |

Fonte: A Autora (2019).

de 96,63%, com kappa de 0,95, também obtidos através do SVM, mas agora com kernel polinomial de grau 2. No geral, os desempenhos mais baixos foram adquiridos utilizando a *Random Tree*, os quais foram, pelo menos, 20% menos satisfatórios do que os dos melhores resultados.

Quando os tecidos foram associados (Tabela 14), observou-se que os algoritmos tiveram mais dificuldade em realizar a classificação. O grau de dificuldade pareceu aumentar quando aumentou-se a quantidade de classes, de 3 para 12, visto que o desempenho dos classificadores, com exceção da SVM e da MLP, diminuíram drasticamente para a base com 12 classes. A MLP foi exceção, pois teve sua acurácia aumentada de 61,50%, com a base de 3 classes, para 70,62%, com a de 12 classes; houve também aumento do índice kappa, de 0,42 para 0,68. Foi observada ainda uma grande diminuição do desvio padrão dos resultados com MLP. A SVM também apresentou um leve aumento no desempenho, com acurácia passando de 94,02% para 94,12% e kappa de 0,91 para 0,94.

Uma questão que merece destaque é o desempenho de identificação e classificação de lesões nas imagens com tecido predominantemente denso (tecido IV), que, além de

Tabela 13 – Resultados de acurácia e kappa utilizando DWNN para representar imagens de Mamografia de diferentes tipos de tecidos

| Base | Classificador | Acurácia (%) | | Índice Kappa | |
|------------|---------------|--------------|-------------|--------------|-------------|
| | | Média | DP | Média | DP |
| Tecido I | Bayes Net | 70,37 | 3,57 | 0,56 | 0,05 |
| | Naive Bayes | 72,73 | 3,79 | 0,59 | 0,06 |
| | MLP | 48,00 | 12,85 | 0,22 | 0,19 |
| | SVM | 96,63 | 1,42 | 0,95 | 0,02 |
| | J48 | 59,75 | 4,35 | 0,40 | 0,06 |
| | Random Tree | 48,33 | 4,25 | 0,22 | 0,06 |
| | Random Forest | 82,19 | 3,07 | 0,73 | 0,05 |
| | ELM | 63,40 | 3,98 | 0,58 | 0,04 |
| Tecido II | Bayes Net | 85,85 | 3,10 | 0,79 | 0,05 |
| | Naive Bayes | 88,91 | 3,05 | 0,83 | 0,04 |
| | MLP | 93,42 | 1,89 | 0,90 | 0,03 |
| | SVM | 98,80 | 0,92 | 0,98 | 0,01 |
| | J48 | 72,23 | 3,62 | 0,58 | 0,05 |
| | Random Tree | 71,03 | 3,27 | 0,57 | 0,05 |
| | Random Forest | 89,23 | 2,51 | 0,84 | 0,04 |
| | ELM | 79,73 | 3,69 | 0,77 | 0,04 |
| Tecido III | Bayes Net | 86,81 | 2,64 | 0,80 | 0,04 |
| | Naive Bayes | 88,79 | 3,43 | 0,83 | 0,05 |
| | MLP | 93,39 | 1,97 | 0,90 | 0,03 |
| | SVM | 98,77 | 0,93 | 0,98 | 0,01 |
| | J48 | 71,72 | 3,44 | 0,58 | 0,05 |
| | Random Tree | 71,22 | 3,60 | 0,57 | 0,05 |
| | Random Forest | 89,71 | 2,46 | 0,85 | 0,04 |
| | ELM | 79,74 | 3,67 | 0,77 | 0,04 |
| Tecido IV | Bayes Net | 59,18 | 3,86 | 0,39 | 0,06 |
| | Naive Bayes | 64,24 | 9,15 | 0,46 | 0,14 |
| | MLP | 84,81 | 2,86 | 0,77 | 0,04 |
| | SVM | 96,58 | 1,50 | 0,95 | 0,02 |
| | J48 | 47,60 | 4,27 | 0,21 | 0,06 |
| | Random Tree | 42,53 | 4,20 | 0,14 | 0,06 |
| | Random Forest | 76,14 | 3,82 | 0,64 | 0,06 |
| | ELM | 55,20 | 4,55 | 0,49 | 0,05 |

Fonte: A Autora (2019).

ser o grupo mais desafiador para a detecção por imagem do câncer de mama, consiste na constituição tecidual mais presente em mulheres jovens. O fato do classificador SVM, com kernel polinomial de grau 2, alcançar 96,58% de acurácia e kappa de 0,95, reforça a hipótese de que classificadores inteligentes podem favorecer o diagnóstico do câncer de mama em estágios iniciais.

Foram ainda montados os *boxplots* dos resultados obtidos com as bases do tecido I e de todos os tecidos com 3 classes, visto que essas são as condições mais comuns de mulheres que se submetem aos exames de rastreio do câncer de mama. O quadro da

Tabela 14 – Resultados de acurácia e kappa utilizando DWNN para representar imagens de Mamografia com todos os tipos de tecido

| Base | Classificador | Acurácia (%) | | Índice Kappa | |
|------------|---------------|--------------|-------------|--------------|-------------|
| | | Média | DP | Média | DP |
| Todos - 3 | Bayes Net | 75,81 | 2,04 | 0,64 | 0,03 |
| | Naive Bayes | 67,77 | 2,10 | 0,52 | 0,03 |
| | MLP | 61,50 | 9,57 | 0,42 | 0,14 |
| | SVM | 94,02 | 1,05 | 0,91 | 0,02 |
| | J48 | 65,65 | 2,15 | 0,48 | 0,03 |
| | Random Tree | 53,35 | 2,43 | 0,30 | 0,04 |
| | Random Forest | 80,81 | 1,63 | 0,71 | 0,02 |
| | ELM | 67,01 | 2,06 | 0,63 | 0,02 |
| Todos - 12 | Bayes Net | 19,97 | 1,57 | 0,13 | 0,02 |
| | Naive Bayes | 42,49 | 4,16 | 0,37 | 0,04 |
| | MLP | 70,62 | 1,62 | 0,68 | 0,02 |
| | SVM | 94,12 | 0,89 | 0,94 | 0,01 |
| | J48 | 17,60 | 1,66 | 0,10 | 0,02 |
| | Random Tree | 14,30 | 1,45 | 0,07 | 0,02 |
| | Random Forest | 43,67 | 2,25 | 0,39 | 0,02 |
| | ELM | 26,88 | 2,06 | 0,26 | 0,02 |

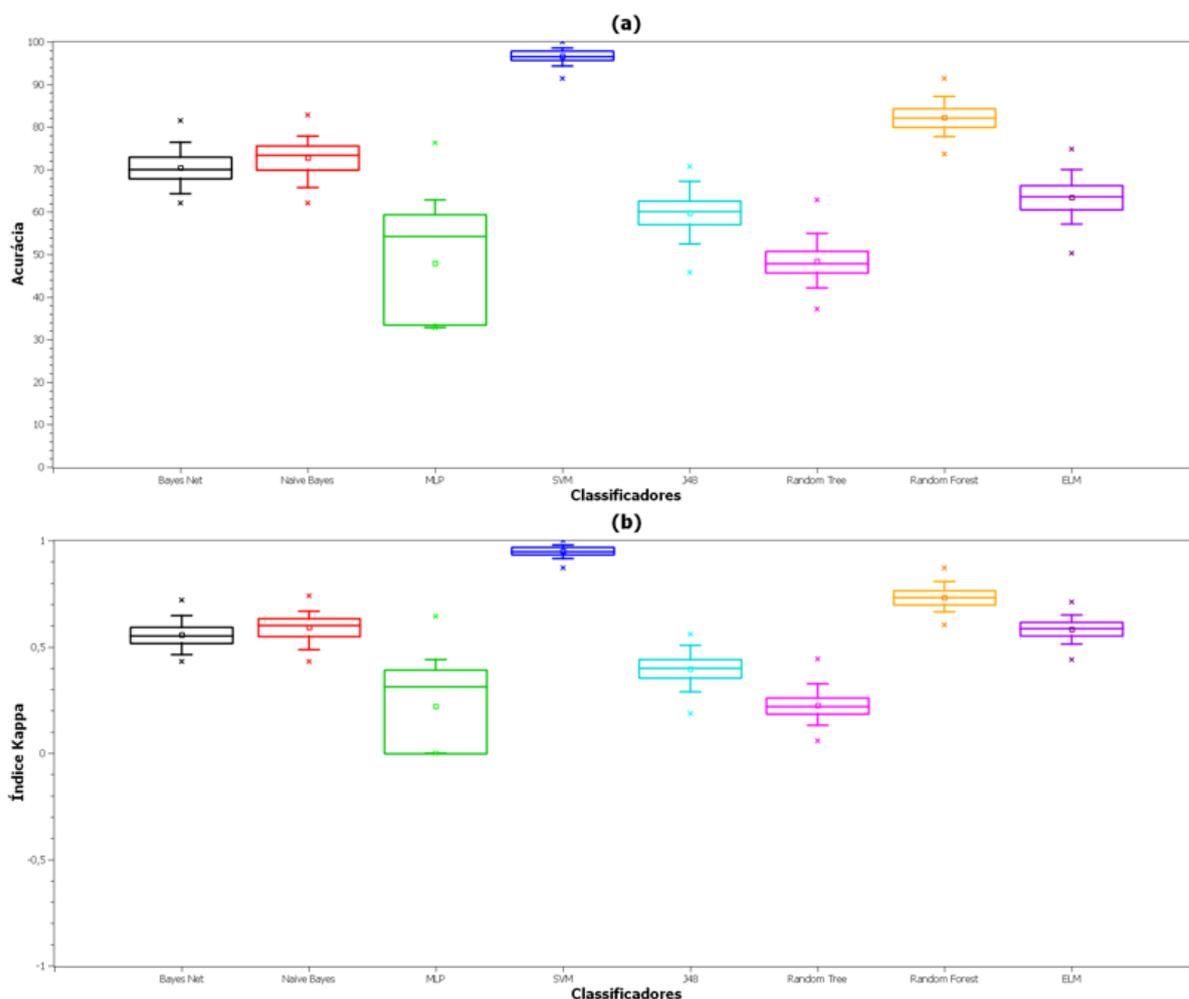
Fonte: A Autora (2019).

Figura 20 mostra os gráficos obtidos para acurácia (a) e índice kappa (b) utilizando a base do tecido I, enquanto que a Figura 21 apresenta os resultados para a base com todos os tecidos e 3 classes. A partir desses gráficos, é possível observar que, para a base de dados com o tecido I, a rede MLP apresentou uma variabilidade dos resultados muito maior do que dos outros classificadores, enquanto que, como dito anteriormente, a SVM obteve o melhor desempenho, com a menor dispersão dos dados; os demais métodos apresentaram baixas dispersões, as quais foram semelhantes entre si. Quando observada a base de dados com todos os tecidos, houve uma diminuição na dispersão da MLP, com relação a base de tecido I, contudo, ela ainda continua maior que as demais. Mais uma vez, os melhores resultados foram adquiridos com a SVM. Os demais métodos alcançaram resultados menos satisfatórios, mas com baixa variabilidade dos resultados.

5.2.2 Momentos de Haralick e Zernike e Mamografia

Em relação a representação das regiões de interesse de mamografias utilizando os momentos de Haralick e Zernike, a Tabela 15 apresenta os resultados para ambas as bases testadas. Para a base de mamas com tecido predominantemente adiposo, as melhores configurações do MLP, SVM, *Random Forest* e ELM foram, respectivamente, com 10 neurônios, kernel polinomial de grau 2, 100 árvores e kernel de erosão. Quando todos os tecidos foram associados, mantendo as três classes (normal, benigna e maligna), a MLP obteve um desempenho melhor quando utilizados 10 neurônios na camada escondida,

Figura 20 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando DWNN para extração de atributos e imagens de Mamografia de mamas predominante adiposas (tipo I).

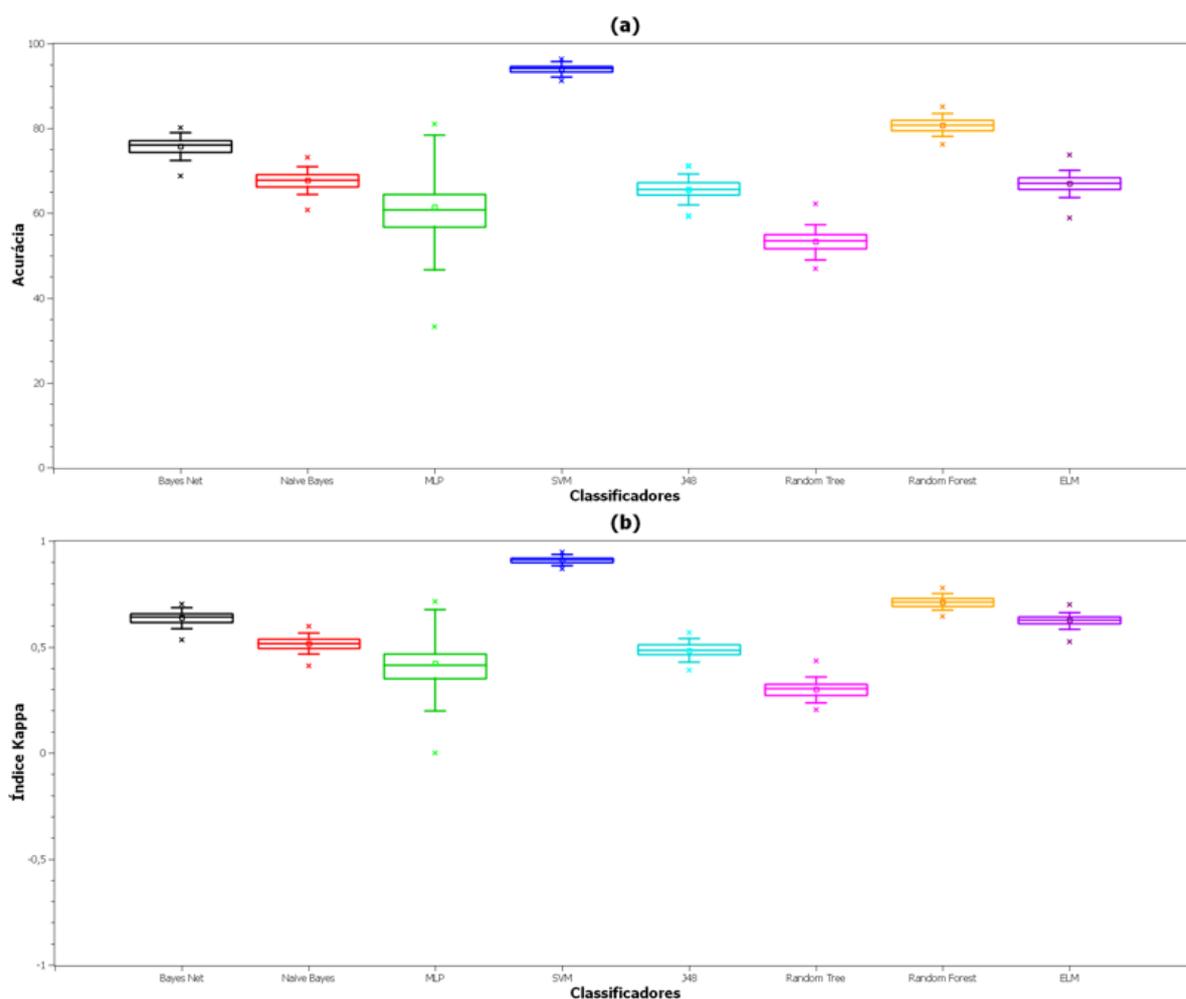


Fonte: A Autora (2019).

já a SVM se destacou mais quando utilizado kernel polinomial de grau 3; as melhores configurações da *Random Forest* e da ELM foram as mesmas obtidas com a base anterior (100 árvores e kernel de erosão). Tais resultados podem ser visualizados na íntegra nas Tabelas A9 e A10 do Apêndice A.

No caso da base de dados do tecido I, dentre todos os classificadores, o SVM se destacou positivamente, atingindo uma acurácia média de 81,27%, com índice kappa de 0,72. O ELM apresentou resultados semelhantes ao do SVM, com 81,07% de acurácia e 0,79 de kappa. Um pouco mais abaixo, mas com resultados medianos, ficaram a *Random Forest* (75,40% e 0,63) e a MLP (74,36% e 0,62). Resultados menos satisfatórios, entre 65% e 69% de acurácia, foram obtidos com os demais classificadores, dos quais a *Random Tree* apresentou os piores resultados, com 65,34% de acurácia e kappa de 0,48. Quanto à dispersão dos dados, que pode ser melhor visualizada nos gráficos da Figura 22, ela se apresentou menor nos índices kappa do que nas acurácias, os resultados entre os métodos foram parecidos, mas com os classificadores SVM e ELM um pouco mais superiores em

Figura 21 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando DWNN para extração de atributos e imagens de Mamografia de mamas com todas as constituições teciduais (3 classes).



Fonte: A Autora (2019).

relação aos demais.

Para a base de dados com todos os tecidos e 3 classes, é possível observar resultados próximos dos obtidos utilizando a base de dados com apenas mamas adiposas, mas levemente mais baixos. Os resultados mais satisfatórios foram obtidos pelos classificadores SVM, ELM, *Random Forest* e MLP, nessa ordem, com acurácia máxima de 79,01%, utilizando SVM, e kappa máximo de 0,73, com a ELM. Nessa situação, o pior desempenho foi do *Naive Bayes*, com 58,06% de acurácia e 0,37 de kappa. Tais resultados são também ilustrados na Figura 23, a partir da qual é possível verificar que não houve muita variação quanto as dispersões associadas aos métodos, nem para acurácia nem para o índice kappa.

5.3 Protótipo de um Sistema de Apoio ao Diagnóstico do Câncer de Mama

Por fim, após a verificação do desempenho de diversas técnicas de representação dos dados (extração de atributos) e de classificação automática (algoritmos inteligentes)

Tabela 15 – Resultados de acurácia e kappa utilizando Haralick e Zernike para representar imagens de Mamografia com as bases de dados com mamas de tecido adiposo e com todos os tipos de tecidos e três classes.

| Base | Classificador | Acurácia (%) | | Índice Kappa | |
|-----------|---------------|--------------|-------------|--------------|-------------|
| | | Média | DP | Média | DP |
| Tecido I | Bayes Net | 67,91 | 3,71 | 0,52 | 0,06 |
| | Naive Bayes | 68,79 | 3,70 | 0,53 | 0,06 |
| | MLP | 74,36 | 3,80 | 0,62 | 0,06 |
| | SVM | 81,27 | 3,14 | 0,72 | 0,05 |
| | J48 | 67,93 | 3,93 | 0,52 | 0,06 |
| | Random Tree | 65,34 | 3,54 | 0,48 | 0,05 |
| | Random Forest | 75,40 | 3,37 | 0,63 | 0,05 |
| | ELM | 81,07 | 3,20 | 0,79 | 0,04 |
| Todos - 3 | Bayes Net | 69,40 | 1,67 | 0,54 | 0,02 |
| | Naive Bayes | 58,06 | 1,72 | 0,37 | 0,02 |
| | MLP | 72,27 | 2,31 | 0,58 | 0,03 |
| | SVM | 79,01 | 1,73 | 0,69 | 0,02 |
| | J48 | 67,49 | 1,86 | 51 | 0,03 |
| | Random Tree | 65,40 | 1,84 | 0,48 | 0,03 |
| | Random Forest | 74,29 | 1,62 | 0,61 | 0,02 |
| | ELM | 75,44 | 1,89 | 0,73 | 0,02 |

Fonte: A Autora (2019).

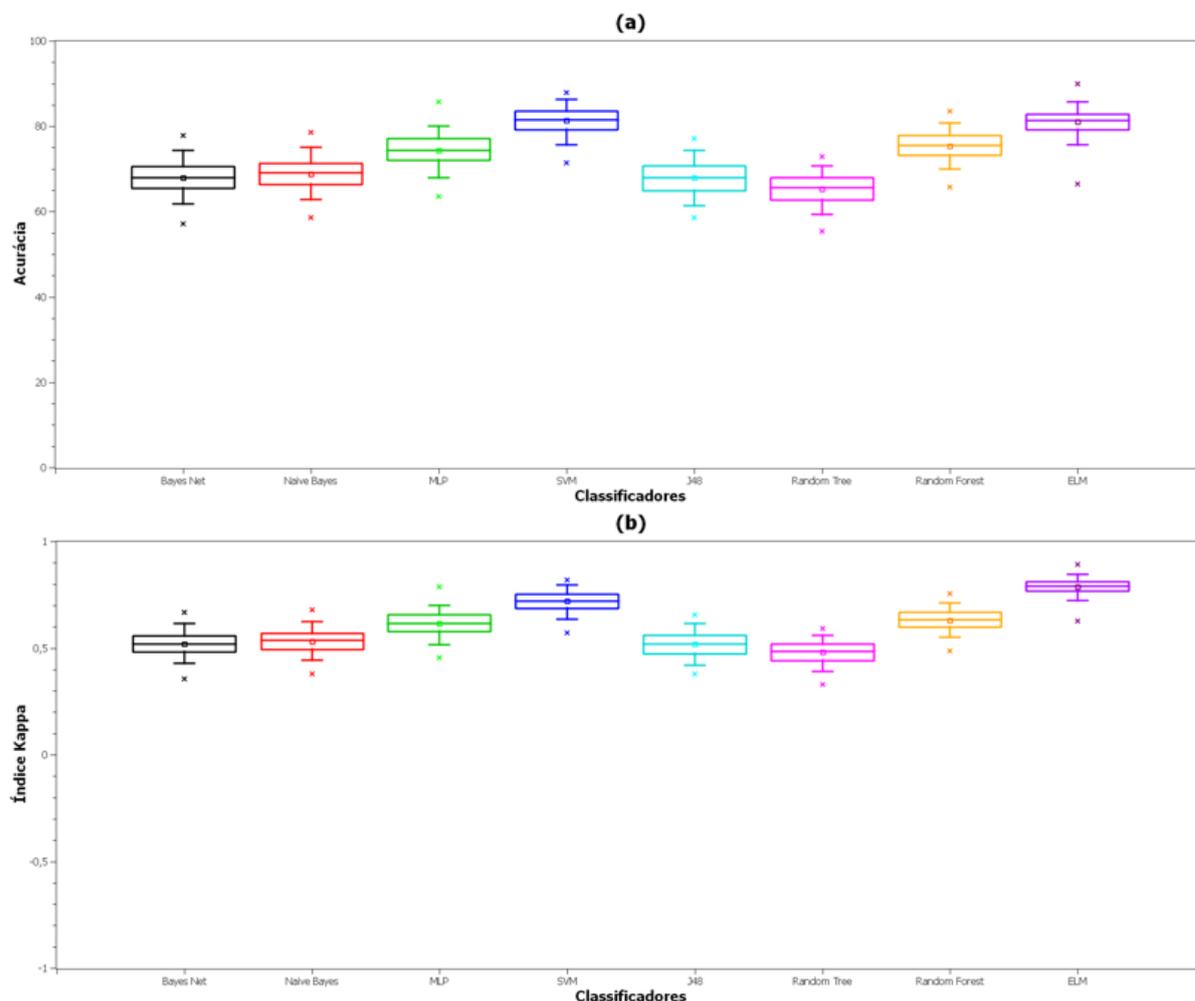
para ambas as bases, foi possível selecionar as melhores configurações obtidas para serem utilizadas em um protótipo do *software* de apoio ao diagnóstico do câncer de mama, implementado em linguagem Object Pascal. O protótipo proposto consiste em um sistema para PC, com comunicação com a nuvem, onde estão salvos os parâmetros para classificação. Como ambas as bases foram bem representadas pela DWNN e melhores classificadas quando utilizado o classificador SVM, esses foram os métodos implementados no protótipo.

A partir desse sistema o/a profissional de saúde pode carregar a imagem que deseja investigar e, após o processo de extração de atributos e classificação, o *software* retorna um laudo para auxiliar na tomada de decisão acerca dos passos seguintes a serem dados com a paciente. O sistema é compatível com imagens tanto de termografia de mama quanto de regiões de interesse de mamografia, modo esse que deve ser selecionado pelo usuário antes de carregar a imagem. A Figura 24 apresenta as janelas utilizadas para carregar os dois diferentes tipos de imagens suportados pelo sistema proposto.

5.4 Considerações

Este capítulo apresentou os resultados obtidos para identificação e classificação de lesões de mama a partir do método proposto no Capítulo 4. A análise foi feita utilizando duas bases de de imagens completamente dissociadas, sendo a primeira delas de Termografias

Figura 22 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando Haralick e Zernike para extração de atributos e imagens de Mamografia de mamas predominante adiposas (tipo I).

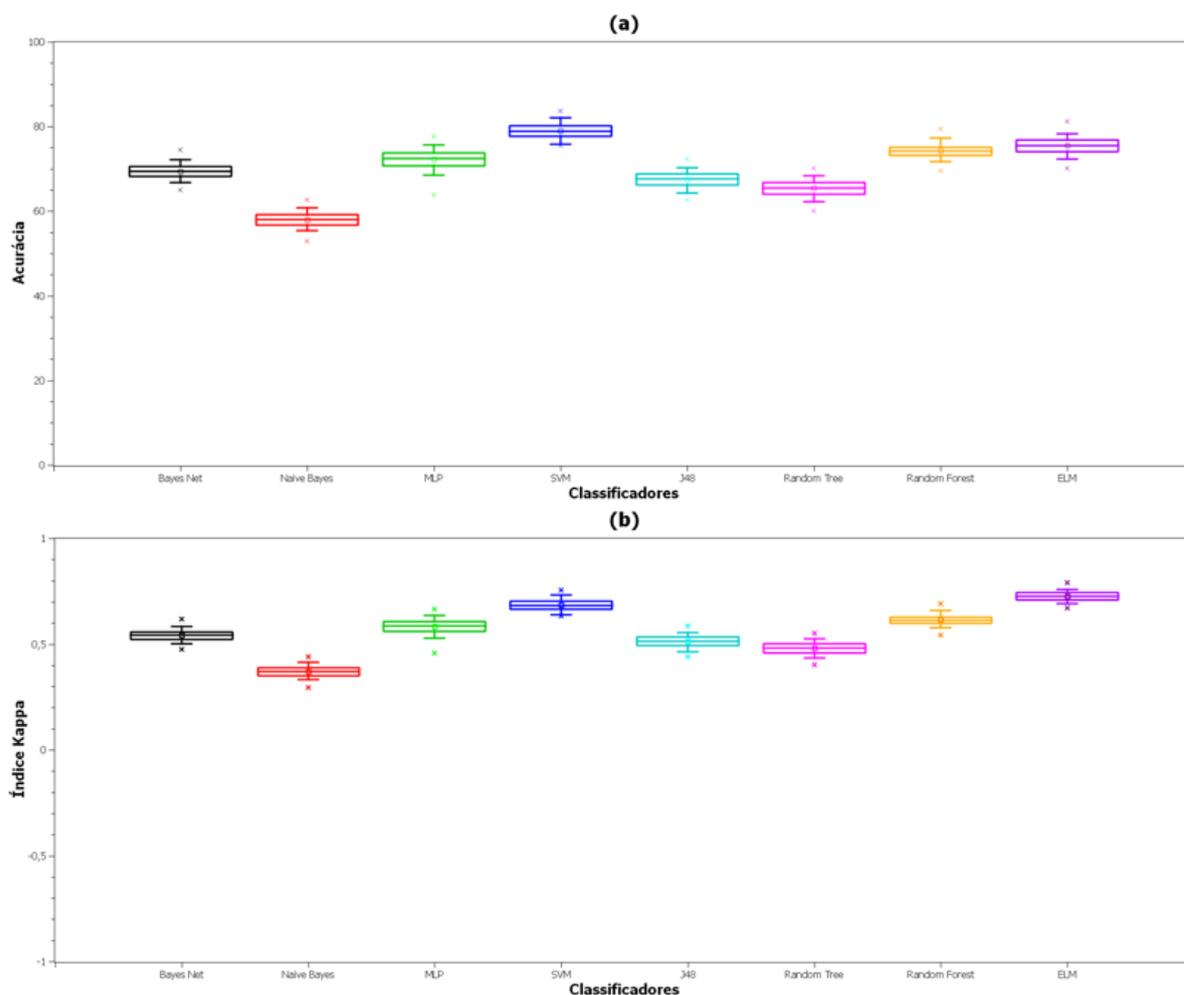


Fonte: A Autora (2019).

de Mama e a segunda de imagens provenientes de exames de Mamografia.

Em relação a base de imagens de termografia, foi observado que ela foi melhor representada pelo método DWNN, com função de média. Nessa situação, o classificador SVM atingiu resultados excelentes para a identificação e diferenciação de lesões de mama nas imagens. Os resultados menos satisfatórios, por sua vez, foram obtidos com a *Random Tree*. As matrizes de confusão para essas situações (Tabela 16) reiteram as observações anteriormente apresentadas, visto que há muito mais confusão entre as classes do pior resultado do que na melhor situação. A partir das matrizes é possível observar que, em ambos os casos, a classe de lesão benigna é a que mais se confunde com as demais, em especial com as classes de cisto e de lesão maligna, mas existe ainda confusão entre essa classe e a classe onde não há ocorrência de lesão. No entanto, como o grau de confusão é significativamente diminuído na situação em que ocorreu o melhor desempenho de classificação, foram obtidos resultados expressivos para as métricas de sensibilidade, especificidade e eficiência do sistema, tal como apresentado na Tabela 17, a partir das

Figura 23 – Boxplot dos resultados de (a) acurácia e (b) índice kappa utilizando Haralick e Zernike para extração de atributos e imagens de Mamografia de mamas com todas as constituições teciduais (3 classes).



Fonte: A Autora (2019).

quais pode-se analisar a qualidade do diagnóstico.

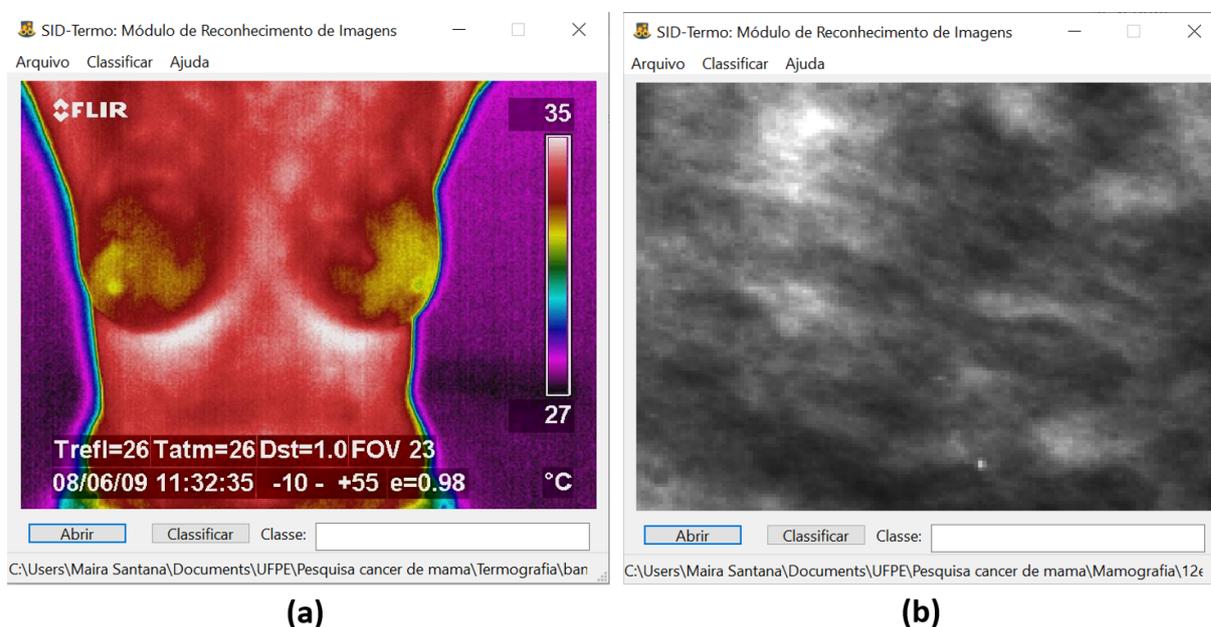
Tabela 16 – Matriz de confusão para o melhor e o pior resultados utilizando a base de Termografia de mama

| | | cística | benigna | maligna | sem lesão |
|-------------------------|------------------|----------------|----------------|----------------|------------------|
| Melhor resultado | cística | 242 | 0 | 0 | 0 |
| | benigna | 4 | 235 | 2 | 1 |
| | maligna | 1 | 0 | 241 | 0 |
| | sem lesão | 0 | 0 | 0 | 242 |
| Pior resultado | cística | 108 | 54 | 38 | 42 |
| | benigna | 36 | 99 | 58 | 49 |
| | maligna | 36 | 59 | 109 | 38 |
| | sem lesão | 40 | 45 | 34 | 123 |

Fonte: A Autora (2019).

Quanto à base de imagens de regiões de interesse de mamografia, observou-se que ela também foi melhor representada pelo método DWNN. A função do bloco de síntese

Figura 24 – Janela para carregamento da imagem no sistema de apoio ao diagnóstico do Câncer de Mama. Em (a) está a janela para carregamento de imagens de Termografia de mama e em (b) pode ser visualizado o carregamento de uma imagem de região de interesse de Mamografia.



Fonte: A Autora (2020).

Tabela 17 – Métricas de sensibilidade, especificidade e eficiência da abordagem utilizando a base de Termografia de mama

| | Sensibilidade | Especificidade | Eficiência |
|---------------|---------------|----------------|------------|
| Lesão Cística | 100,00% | 99,31% | 99,66% |
| Lesão Benigna | 97,11% | 74,92% | 86,02% |
| Lesão Maligna | 99,59% | 99,72% | 99,66% |
| Sem Lesão | 100,00% | 99,86% | 99,93% |

Fonte: A Autora (2019).

que resultou nos melhores resultados variou de acordo com a base de dados utilizada, mas, no geral, as funções de mínimo, mediana e moda se destacaram positivamente. Dentre todos os resultados observados para as diferentes bases, as melhores classificações foram obtidas as bases de tecidos II e III, em especial em mamas predominantemente compostas por tecido fibroglandular (tecido II). Nessa situação, o classificador SVM, de kernel RBF com $\gamma=0,25$, atingiu resultados excelentes para a identificação e diferenciação das classes. Os resultados menos satisfatórios, por sua vez, foram obtidos com a *Random Tree*.

As matrizes de confusão para essas situações (Tabela 18) reiteram as observações anteriormente apresentadas, visto que há muito mais confusão entre as classes do pior resultado do que do melhor. A partir das matrizes é possível observar uma confusão maior entre as classes benigna e maligna, havendo pouca ou nenhuma confusão entre alguma dessas classes e a classe de mamas saudáveis, mesmo para o pior resultado. Os resultados obtidos para as métricas de sensibilidade, especificidade e eficiência do sistema são apresentados na Tabela 19.

Tabela 18 – Matriz de confusão para o melhor e o pior resultados utilizando a base imagens de Mamografia com mamas do tipo II.

| | | normal | benigna | maligna |
|-------------------------|----------------|--------|---------|---------|
| Melhor resultado | normal | 466 | 0 | 0 |
| | benigna | 0 | 460 | 6 |
| | maligna | 0 | 8 | 458 |
| Pior resultado | normal | 450 | 11 | 5 |
| | benigna | 10 | 254 | 202 |
| | maligna | 6 | 194 | 266 |

Fonte: A Autora (2019).

Tabela 19 – Métricas de sensibilidade, especificidade e eficiência da abordagem utilizando a base de Mamografia

| | Sensibilidade | Especificidade | Eficiência |
|---------|---------------|----------------|------------|
| Normal | 100,00% | 100,00% | 100,00% |
| Benigna | 98,71% | 66,47% | 82,59% |
| Maligna | 98,28% | 99,36% | 98,82% |

Fonte: A Autora (2019).

A partir desses resultados, as melhores configurações de representação e classificação das imagens de ambos os tipos de bases de imagens foram utilizadas para a confecção de um protótipo do sistema de apoio ao diagnóstico do câncer de mama.

6 CONCLUSÃO

O presente trabalho apresentou técnicas computacionais aplicadas a resolução dos desafios associados à interpretação de imagens de mamografia e de termografia de mama. Foram exploradas diferentes formas de representar as imagens, assim como diferentes métodos para classificação. As bases de dados utilizadas foram a base IRMA, da Aachen University of Technology, com imagens de regiões de interesse de mamografia; e a base de imagens termográficas do Laboratório de Imagens Térmicas do Departamento de Engenharia Mecânica da Universidade Federal de Pernambuco. É importante salientar que não é possível realizar nenhum tipo de comparação entre as bases de dados de termografia e mamografia, visto que são totalmente dissociadas.

Em ambos os casos, os descritores baseados em Wavelets foram capazes de representar bem as imagens. Quando associados a máquinas de vetor de suporte (SVM), a identificação de lesões em termogramas de mama atingiu uma acurácia em torno de 99% e mais de 0,95 de índice kappa. O método proposto alcançou ainda resultados acima de 95% de acurácia, com índice kappa em torno de 0,95, com as imagens de mamografia. Observou-se ainda, na maioria dos casos, baixa variabilidade dos resultados, implicando, portanto, em uma maior confiabilidade dos resultados.

Em relação às métricas que avaliam a qualidade do diagnóstico, com a base de termografia, foram obtidos valores excelentes para a sensibilidade, especificidade e eficiência no diagnóstico de imagens com lesão cística e sem lesão, alcançando até 100% de sensibilidade, em ambos os casos, e valores acima de 99% para as outras duas métricas. Ainda para essa base de dados, também foram observados valores acima de 99,5%, para as três medidas, em relação ao diagnóstico de lesões malignas. Para lesões benignas, a abordagem proporcionou uma sensibilidade de 97,11%, com especificidade de 74,92% e 86,02% de eficiência.

Utilizando o banco de dados de mamografia, o sistema foi impecável na identificação de imagens de mamas normais. O desempenho foi um pouco menor para imagens com lesão maligna, ainda assim alcançando valores acima de 98% para a sensibilidade, a especificidade e a eficiência. No caso de imagens de lesões benignas, mais uma vez foi observada uma queda na qualidade do diagnóstico, especialmente para a especificidade e a eficiência, com valores de 66,47% e 82,59%, respectivamente. Nessa última situação a sensibilidade também ficou em torno de 98%.

No geral, em ambas as bases, observou-se uma maior dificuldade em diferenciar as lesões benignas das demais condições. Contudo, mesmo para essa classe, foram obtidos altas sensibilidades, ou seja, pode-se afirmar que o sistema está associado a baixas taxas

de falso negativo, o que consiste em uma característica essencial para um sistema com aplicação no processo de diagnóstico.

A aplicação do método DWNN para extração de atributos resultou em uma melhor representação das bases de dados aqui exploradas, quando comparados com aqueles obtidos usando a representação baseada em momentos de Haralick e de Zernike. Assim sendo, a DWNN se mostrou uma contribuição relevante, visto que consiste em uma arquitetura profunda, mas sem a necessidade de treinamento, de maneira que não é necessário configurar muitos parâmetros para sua utilização.

Foi verificado ainda que a SVM, com diferentes configurações de kernel, se sobressaiu em relação aos demais algoritmos de classificação. Bons resultados foram obtidos com MLP, *Random Forest* e ELM, indicando que o problema pode ser generalizado, mas de forma muitas vezes não linear. O bom desempenho desses métodos explicam os baixos resultados obtidos com as árvores de decisão (J48 e *Random Tree*), já que esses métodos comumente alcançam bons resultados quando a base é muito específica. Os desempenhos relativamente baixos com os métodos bayesianos apontam para uma considerável dependência entre os atributos, o que foi mais fortemente observado quando utilizados os momentos de Haralick e Zernike.

Os resultados obtidos reforçam o poder da Inteligência Computacional para a resolução de problemas complexos e não lineares, características recorrentes em questões associadas a aplicações biomédicas. Técnicas de aprendizado profundo (*deep learning*), tais como a DWNN, aqui explorada, vêm se mostrando eficazes para tais aplicações, visto que aumentam a complexidade da fronteira de decisão para resolução do problema de classificação.

O estudo serve também para difundir a técnica de termografia de mama, a qual já é bastante explorada no meio científico, mas ainda pouco conhecida na prática clínica. Em estudos como esse, a termografia tem se mostrado uma poderosa ferramenta a ser utilizada na triagem de pacientes no campo da mastologia. Considerando que essa técnica é portátil, indolor e segura, ela pode, facilmente, ser utilizada em clínicas para uma avaliação inicial das pacientes, auxiliando na tomada de decisão dos especialistas quanto ao melhor direcionamento a ser dado em cada caso. Alternativas como essas são especialmente importantes em locais de difícil acesso e/ou com pouca estrutura e recursos.

Além disso, o projeto pode ter impacto sobre o Sistema Único de Saúde, SUS, por meio da disponibilização de uma tecnologia que pode facilitar a triagem de pacientes com suspeita de câncer de mama, contribuindo para a geração de diagnósticos precoces e, portanto, para a redução da mortalidade pela doença. Construção de serviços de saúde complexos e de alto valor agregado tem um potencial de não somente democratizar o acesso à saúde e fortalecimento do SUS, como também alimentar um ecossistema inovador de soluções de apoio ao diagnóstico que possa contribuir para o desenvolvimento local e

nacional.

6.1 Dificuldades encontradas

Vários desafios surgiram ao longo do desenvolvimento do trabalho. Inicialmente foi necessário um empenho especial para a apropriação da problemática do câncer de mama, assim como da técnica de termografia de mama, no sentido de perceber sua relevância e aplicabilidade. Em um segundo momento, houve também um esforço para compreender o funcionamento das técnicas de inteligência computacional e de reconhecimento de padrões, assim como de representação de imagens.

Acerca dos experimentos propriamente ditos, a principal dificuldade encontrada foi do longo tempo despendido para o treinamento de alguns algoritmos, em especial as redes perceptron multicamadas e máquinas de vetor de suporte. Contudo, os custos computacionais não foram proibitivos, tanto que foi possível realizar todos os experimentos propostos.

6.2 Contribuições

O projeto envolve a construção de tecnologia não invasiva de apoio ao diagnóstico do câncer de mama, tendo potencial para gerar tecnologias locais que podem ser exploradas por empresas de base tecnológica de inovação em saúde.

Os resultados parciais do estudo culminaram em diversas contribuições, as quais podem ser exploradas e aperfeiçoadas em outras abordagens. O trabalho recebeu uma Menção Honrosa no Desafio de Aplicações Bio-Tech - BMEBioBrazil 2019, promovido pela Sociedade Brasileira de Engenharia Biomédica (SBEB) e pela IEEE Engineering in Medicine and Biology Society (EMBS-IEEE). Pelo quarto lugar nesse Desafio, recebeu-se ainda um Voto de Congratulações da Câmara Municipal do Recife - Casa de José Mariano.

Ao longo do período do Mestrado, além da pesquisa de Câncer de Mama, foi possível colaborar com outras pesquisas, extrapolando para outras áreas as técnicas computacionais e os conhecimentos explorados no presente estudo. Os estudos realizados resultaram em contribuições na forma de artigos em periódicos, trabalhos apresentados em eventos, capítulos de livro, livros, registros de patente. As produções aceitas são apresentadas a seguir.

- a) Organização do livro "Biomedical Computing for Breast Cancer Detection and Diagnosis", com a editora IGI Global, a ser lançado em 2020;
- b) Organização do livro "Understanding a Cancer Diagnosis", com a editora Nova Science, a ser lançado em 2020;

- c) Capítulo "Breast Cancer Diagnosis in Mammograms Using Wavelet Analysis, Haralick Descriptors and Autoencoder" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- d) Capítulo "Classification of Breast Lesions in Frontal Thermographic Images using a Diagnosis Aid Intelligent System" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- e) Capítulo "Breast Cancer Detection and Lesion Classification using Digital Mammographies, Machine Learning and Particle Swarm Optimization" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- f) Capítulo "Feature selection based on dialectical optimization algorithm for breast lesion classification in thermographic images" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- g) Capítulo "Features Selection Study for Breast Cancer Diagnosis using Thermographic Images, Genetic Algorithms and Particle Swarm Optimization" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- h) Capítulo "Hybrid Differential Evolution Algorithm with Simulated Annealing to reconstruct electrical impedance tomography images" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- i) Capítulo "Using Extreme Learning Machines and the Backprojection Algorithm as an alternative to reconstruct Electrical Impedance Tomography Images" para o livro *Biomedical Computing for Breast Cancer Detection and Diagnosis*, da IGI Global, 2020;
- j) Capítulo "Breast lesions classification in frontal thermographic images using intelligent systems and moments of Haralick and Zernike" para o livro *Understanding a Cancer Diagnosis*, da Nova Science, 2020;
- k) Capítulo "Dialectical Optimization Method as a Feature Selection Tool for Breast Cancer Diagnosis using Thermographic Images" para o livro *Understanding a Cancer Diagnosis*, da Nova Science, 2020;
- l) Capítulo "Method for classification of breast lesions in thermographic images using ELM classifiers" para o livro *Understanding a Cancer Diagnosis*, da Nova Science, 2020;
- m) Capítulo "Lesions detection in breast thermography using machine learning algorithms without previous segmentation" para o livro *Understanding a Cancer Diagnosis*, da Nova Science, 2020;

- n) Capítulo "Morphological Extreme Learning Machines applied to the detection and classification of mammary lesions" para o livro *Advanced Machine Vision Paradigms for Medical Image Analysis*, da Elsevier, 2020;
- o) Capítulo "Deep-Wavelet Neural Networks for breast cancer early diagnosis using mammary thermographies" para o livro *Deep Learning for Data Analytics: Foundations, Biomedical Applications and Challenges*, da Elsevier, 2020;
- p) Capítulo "Deep learning for early diagnosis of Alzheimer's disease" para o livro *Deep Learning for Data Analytics: Foundations, Biomedical Applications and Challenges*, da Elsevier, 2020;
- q) Capítulo "Electrical impedance tomography image reconstruction based on Autoencoder and Extreme Learning Machines" para o livro *Deep Learning for Data Analytics: Foundations, Biomedical Applications and Challenges*, da Elsevier, 2020;
- r) Capítulo "An EEG brain-computer interface to classify motor imagery signals" para o livro *Biomedical Signal Processing - Advances in Theory, Algorithms, and Applications*, da Springer, 2019;
- s) Artigo "Identification of Mammary Lesions in Thermographic Images: a Feature Selection Study using Genetic Algorithms and Particle Swarm Optimization", aceito para publicação no periódico *Research on Biomedical Engineering*, 2019;
- t) Artigo "Breast cancer diagnosis based on mammary thermography and extreme learning machines", publicado no periódico *Research on Biomedical Engineering*, 2018;
- u) Artigo "Desempenho de Máquinas de Aprendizado Extremo com Operadores Morfológicos para Identificação e Classificação de Lesões em Imagens Frontais de Termografia de Mama", apresentado no XXII Congresso Brasileiro de Automática, 2018;
- v) Artigo "Uso de classificadores na predição de lesões de mama a partir de imagens termográficas", apresentado no III Simpósio de Inovação em Engenharia Biomédica, 2019;
- w) Artigo "Métodos Computacionais Aplicados ao Diagnóstico de Câncer de Mama por Termografia: uma revisão de literatura", apresentado no III Simpósio de Inovação em Engenharia Biomédica, 2019;
- x) Artigo "Using Auditory Stimuli to Prevent Epileptic Seizures - A Hypothesis Test", apresentado no III Simpósio de Inovação em Engenharia Biomédica, 2019;

- y) Artigo "Uso de Batidas Binaurais associadas a Inteligência Artificial como método de detecção e prevenção de atividades epiléticas", apresentado no III Simpósio de Inovação em Engenharia Biomédica, 2019;
- z) Artigo "Inteligência Artificial Para o Apoio ao Diagnóstico da Doença de Alzheimer utilizando Imagens de Ressonância Magnética", apresentado no III Simpósio de Inovação em Engenharia Biomédica, 2019;
- aa) Artigo "Seleção de Atributos para Apoio ao Diagnóstico do Câncer de Mama Usando Imagens Termográficas, Algoritmos Genéticos e Otimização por Enxame de Partículas", apresentado no II Simpósio de inovação em Engenharia Biomédica, 2018;
- bb) Artigo "Avaliação do desempenho de classificadores inteligentes na detecção da doença de Alzheimer em imagens de ressonância magnética utilizando extratores de forma e textura", apresentado no II Simpósio de inovação em Engenharia Biomédica, 2018;
- cc) Artigo "Método para Classificação do Tipo da Lesão na Mama presentes nas Imagens Termográficas utilizando Classificador ELM", apresentado no I Simpósio de Inovação em Engenharia Biomédica, 2017;
- dd) Artigo "Classificação de Lesões em Imagens Frontais de Termografia de Mama a partir de Sistema Inteligente de Suporte ao Diagnóstico", apresentado no I Simpósio de Inovação em Engenharia Biomédica, 2017;
- ee) Apresentação em pôster do trabalho "Desenvolvimento de Rede Neural Artificial para Avaliação de Catequina por Cromatografia em Camada Delgada", no VII Simpósio Plantas Medicinais do Vale do São Francisco, 2019;
- ff) Apresentação em pôster do trabalho "Identification of Parkinson Disease in Pre-Motor Stage Using Intelligent Classifiers and Electroencephalogram Data", no X Simpósio Internacional em Neuromodulação, 2018;
- gg) Apresentação em pôster do trabalho "Automatic Recognition of Hand Movements by Electroencephalogram", no X Simpósio Internacional em Neuromodulação, 2018.

A seguir são listadas algumas produções que já foram submetidos, mas ainda não foram avaliadas.

- a) Registro da patente "Desenvolvimento de Sistema de Análise de Imagens para Quantificação de compostos polifenólicos a partir de Fingerprints por Cromatografia em Camada Delgada", no Instituto Nacional da Propriedade Industrial (INPI), 2019;

- b) Registro da patente "Dispositivo portátil baseado na entropia de sinais de eletroencefalografia que detecta iminência de crise convulsiva, emite som que bloqueia a crise e emite alerta através de telefone celular", no INPI, 2019;
- c) Artigo "Anticonvulsant Properties of the Aperiodical Binaural Acoustic Stimulation (ABAS) over Refractory Patients", submetido ao periódico *Epilepsy Research*, 2019;
- d) Artigo "LORETA Analysis of Aperiodic Binaural Acoustic Stimulation (ABAS) in Healthy Volunteers", submetido ao periódico *Epilepsy Research*, 2019;
- e) Artigo "Evidence for electroencephalogram connectivity profiles induced by photic stimulation in Parkinsonians", submetido ao periódico *European Journal of Neuroscience*, 2019;
- f) Artigo "Early Identification of Parkinson's Disease using Machine Learning and Partial Directed Coherence", submetido ao periódico *Journal of Neuroscience Methods*, 2019.
- g) Artigo "Feature Selection using Deep Learning and Multi-objective Optimization - Diagnosis of Breast Cancer using Fish School Search", submetido ao periódico *Applied Soft Computing*, 2019.

6.3 Trabalhos futuros

Existem diversas maneiras de aprimorar os resultados obtidos, uma delas consiste na utilização de técnicas para selecionar os atributos mais relevantes para representar as bases de dados, eliminando informações redundantes e, portanto, otimizando o processamento. Especialmente as bases de dados descritas pela DWNN podem se beneficiar com a aplicação desses métodos, visto que esse método extrai uma grande quantidade de atributos, muitas vezes redundantes. Outras configurações para o número de camadas e de filtros do método DWNN também podem ser avaliadas nos próximos trabalhos. Pode-se experimentar ainda a combinação da DWNN com os demais extratores de atributos, como os momentos de Zernike. Além disso, outras técnicas de classificação, utilizando *deep learning* e aprendizado não-supervisionado podem ser experimentadas.

O método de aquisição das imagens de termografia também pode ser explorado de outras maneiras, experimentando outros posicionamentos ou até mesmo buscar observar e analisar a dinâmica da alteração da temperatura das mamas. Resultados interessantes também podem ser encontrados caso seja incorporado algum processo de segmentação das imagens de termografia ou outros procedimentos que possam otimizar a análise da região de interesse, tais como Campos Receptivos Locais (LRF, do inglês *Local Receptive Field*). Por fim, os métodos aqui propostos podem vir a ser úteis em outras bases de dados, que envolvam a resolução de outros tipos de problemas.

REFERÊNCIAS

- ACOG. Practice bulletin no. 122: Breast cancer screening. *Obstetrics and Gynecology*, American College of Obstetricians-Gynecologists, v. 118, n. 2, p. 372–382, 2011.
- ACS. *Guidelines for the Early Detection of Cancer*. Atlanta: American Cancer Society, 2018.
- ACS. *Cancer Facts and Figures*. Atlanta: American Cancer Society, 2019.
- ARORA, N.; MARTINS, D.; RUGGERIO, D.; TOUSIMIS, E.; SWISTEL, A.; OSBORNE, M.; SIMMONS, R. Effectiveness of a noninvasive digital infrared thermal imaging system in the detection of breast cancer. *The American Journal of Surgery*, Elsevier, v. 196, n. 1, p. 523–526, 2008.
- AZEVEDO, W.; LIMA, S.; FERNANDES, I.; ROCHA, A.; CORDEIRO, F.; SILVA-FILHO, A.; SANTOS, W. Morphological extreme learning machines applied to detect and classify masses in mammograms. In: IEEE. *2015 International Joint Conference on Neural Networks (IJCNN)*. Killarney, 2015. p. 1–8.
- AZEVEDO, W. W.; LIMA, S. M.; FERNANDES, I. M.; ROCHA, A. D.; CORDEIRO, F. R.; SILVA-FILHO, A. G. da; SANTOS, W. P. dos. Fuzzy morphological extreme learning machines to detect and classify masses in mammograms. In: IEEE. *Fuzzy Systems (FUZZ-IEEE), 2015 IEEE International Conference on*. [S.l.], 2015. p. 1–8.
- BANDYOPADHYAY, S. K. Survey on segmentation methods for locating masses in a mammogram image. *International Journal of Computer Applications*, Citeseer, v. 9, n. 11, p. 25–28, 2010.
- BECKER, A. S.; MARCON, M.; GHAFOR, S.; WURNIG, M. C.; FRAUENFELDER, T.; BOSS, A. Deep learning in mammography: diagnostic accuracy of a multipurpose image analysis software in the detection of breast cancer. *Investigative Radiology*, v. 52, n. 7, p. 434–440, 2017.
- BOQUETE, L.; ORTEGA, S.; MIGUEL-JIMÉNEZ, J. M.; RODRÍGUEZ-ASCARIZ, J. M.; BLANCO, R. Automated detection of breast cancer in thermal infrared images, based on independent component analysis. *Journal of Medical Systems*, Springer, v. 36, n. 1, p. 103–111, 2012.
- BOUJELBEN, A.; CHAABANI, A. C.; TMAR, H.; ABID, M. Feature extraction from contours shape for tumor analyzing in mammographic images. In: IEEE. *Digital Image Computing: Techniques and Applications, 2009. DICTA'09*. [S.l.], 2009. p. 395–399.
- BRASILEIRO-FILHO, G. *Bogliolo Patologia*. 8. ed. Rio de Janeiro: Guanabara Koogan, 2011.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001.
- CHENG, J.; GREINER, R. Learning bayesian belief network classifiers: Algorithms and system. *Advances in Artificial Intelligence*, Springer, v. 2056, n. 1, p. 141–151, 2001.

COELHO, A. S.; SANTOS, M. A. D. S.; CAETANO, R. I.; PIOVESAN, C. F.; FUIZA, L.; MACHADO, R. L. D.; FEURINE, A. Predisposição hereditária ao câncer de mama e sua relação com os genes *brca1* e *brca2*: revisão da literatura. *Revista Brasileira de Análises Clínicas*, v. 50, n. 1, p. 17–21, 2018.

CORDEIRO, F.; SANTOS, W.; SILVA-FILHOA, A. Segmentation of mammography by applying growcut for mass detection. *Studies in health technology and informatics*, v. 192, p. 87, 2013.

CORDEIRO, F. R.; BEZERRA, K. F.; SANTOS, W. P. dos. Random walker with fuzzy initialization applied to segment masses in mammography images. In: *2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*. Thessaloniki: [s.n.], 2017. p. 156–161.

CORDEIRO, F. R.; SANTOS, W.; SILVA-FILHO, A. G. Analysis of supervised and semi-supervised growcut applied to segmentation of masses in mammography images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, Taylor & Francis, v. 5, n. 4, p. 297–315, 2017.

CORDEIRO, F. R.; SANTOS, W. P.; SILVA-FILHO, A. G. An adaptive semi-supervised fuzzy growcut algorithm to segment masses of regions of interest of mammographic images. *Applied Soft Computing*, Elsevier, v. 46, p. 613–628, 2016.

CORDEIRO, F. R.; SANTOS, W. P.; SILVA-FILHO, A. G. A semi-supervised fuzzy growcut algorithm to segment and classify regions of interest of mammographic images. *Expert Systems with Applications*, Elsevier, v. 65, p. 116–126, 2016.

COSTA, H.; SOLLA, J.; TEMPORÃO, J. G. *Controle do Câncer de Mama: Documento de Consenso*. 1. ed. Rio de Janeiro: Ministério da Saúde, 2004.

CRUZ, T.; CRUZ, T.; SANTOS, W. Detection and classification of lesions in mammographies using neural networks and morphological wavelets. *IEEE Latin America Transactions*, IEEE, v. 16, n. 3, p. 926–932, 2018.

DESERNO, T. M.; SOIRON, M.; OLIVEIRA, J. E. de; ARAÚJO, A. d. A. Computer-aided diagnostics of screening mammography using content-based image retrieval. In: *Proceedings of Society of Photo-Optical Instrumentation Engineers (SPIE)*. [S.l.: s.n.], 2012. v. 8315, p. 831527–831527.

D'ORSI, C.; SICKLES, E.; MENDELSON, E.; MORRIS, E. *ACR BI-RADS atlas, breast imaging reporting and data system*. 3. ed. Reston, VA: American College of Radiology, 1998.

EATON, J. W.; BATEMAN, D.; HAUBERG, S.; WEHBRING, R. *GNU Octave: A high-level interactive language for numerical computations*. 4. ed. Maryland: Free Software Foundation, 2018.

ETEHADTAVAKOL, M.; NG, E. Y. Breast thermography as a potential non-contact method in the early detection of cancer: a review. *Journal of Mechanics in Medicine and Biology*, World Scientific, v. 13, n. 02, p. 1330001, 2013.

FERNÁNDEZ-OVIES, F. J.; ALFÉREZ-BAQUERO, E. S.; ANDRÉS-GALIANA, E. J. de; CERNEA, A.; FERNÁNDEZ-MUÑIZ, Z.; FERNÁNDEZ-MARTÍNEZ, J. L. Detection of breast cancer using infrared thermography and deep neural networks. In: ROJAS, I.; VALENZUELA,

O.; ROJAS, F.; ORTUÑO, F. (Ed.). *Bioinformatics and Biomedical Engineering*. Cham: Springer International Publishing, 2019. p. 514–523.

FLUKE. *What is infrared thermography?* 2019. Disponível em: <<https://www.fluke.com/en-us/learn/best-practices/measurement-basics/thermography/what-is-infrared-thermography>>. Acesso em: 24/10/2019.

GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. *Machine Learning*, Springer, v. 63, n. 1, p. 3–42, 2006.

GONÇALVES, J. G.; SIQUEIRA, A. D. S. E.; ROCHA, I. G. de A.; LIMA, E. F. F. de; ALVES, L. da S.; SILVA, B. O. da; MENDONÇA, P. E. X. de; MERHY, E. E.; LAND, M. G. P. Evolução histórica das políticas para o controle do câncer de mama no brasil. *DIVERSITATES International Journal*, v. 8, n. 1, 2016.

GROOT, M. T.; BALTUSSEN, R.; GROOT, C. A. Uyl-de; ANDERSON, B. O.; HORTOBÁGYI, G. N. Costs and health effects of breast cancer interventions in epidemiologically different regions of africa, north america, and asia. *The Breast Journal*, Wiley Online Library, v. 12, n. s1, p. S81–S90, 2006.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. *ACM SIGKDD Explorations Newsletter*, v. 11, n. 1, p. 10–18, 2009.

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

HAYKIN, S. *Redes Neurais: Princípios e Prática*. 2. ed. São Paulo: Bookman, 2007.

HEATH, M.; BOWYER, K.; KOPANS, D.; MOORE, R.; KEGELMEYER, W. P. The digital database for screening mammography. In: *In Proceedings of the 5th International Workshop on Digital Mammography*. [S.l.: s.n.], 2000. p. 212–218.

HUANG, G.; ZHOU, H.; DING, X.; ZHANG, R. Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 42, n. 2, p. 513–529, 2012.

HUANG, G.-B. An insight into extreme learning machines: Random neurons, random features and kernels. *Cognitive Computation*, v. 6, n. 3, p. 376–390, Sep 2014.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. *Neurocomputing*, v. 70, n. 1, p. 489 – 501, 2006.

JUNG, Y.; HU, J. A k-fold averaging cross-validation procedure. *Journal of Nonparametric Statistics*, Taylor & Francis, v. 27, n. 2, p. 167–179, 2015.

KAN, C.; SRINATH, M. D. Combined features of cubic b-spline wavelet moments and zernike moments for invariant character recognition. In: *Proceedings International Conference on Information Technology: Coding and Computing*. [S.l.: s.n.], 2001. p. 511–515.

KRUMMENAUER, F.; DOLL, G. Statistical methods for the comparison of measurements derived from orthodontic imaging. *European Journal of Orthodontics*, v. 22, n. 3, p. 257–269, 06 2000.

- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 5 1977.
- LAUBY-SECRETAN, B.; SCOCCIANTI, C.; LOOMIS, D.; BENBRAHIM-TALLAA, L.; BOUVARD, V.; BIANCHINI, F.; STRAIF, K. Breast-cancer screening — viewpoint of the iarc working group. *New England Journal of Medicine*, v. 372, n. 24, p. 2353–2358, 2015.
- LEW, M. S.; SEBE, N.; DJERABA, C.; JAIN, R. Content-based multimedia information retrieval: State of the art and challenges. *ACM Trans. Multimedia Comput. Commun. Appl.*, Association for Computing Machinery, New York, NY, USA, v. 2, n. 1, p. 1–19, fev. 2006.
- LIMA, S.; AZEVEDO, W.; CORDEIRO, F.; SILVA-FILHO, A.; SANTOS, W. Feature extraction employing fuzzy-morphological decomposition for detection and classification of mass on mammograms. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference*. [S.l.: s.n.], 2015. v. 2015, p. 801–804.
- LIMA, S. M. de; SILVA-FILHO, A. G. da; SANTOS, W. P. dos. Detection and classification of masses in mammographic images in a multi-kernel approach. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 134, p. 11–29, 2016.
- MACHADO, A. M. *Texturas: sobre leitura e escritos*. Rio de Janeiro: Nova Fronteira, 2001.
- MAES, J. *O seio da mulher humana é uma flor simétrica, perfeita e assustadora? Não é bem assim*. 2019. Disponível em: <<https://hypescience.com/imagem-viral-de-seios-por-dentro-assustou-mulheres-mas-nao-condiz-com-a-realidade/>>. Acesso em: 14/01/2020.
- MAGNA, G.; CASTI, P.; JAYARAMAN, S. V.; SALMERI, M.; MENCATTINI, A.; MARTINELLI, E.; NATALE, C. D. Identification of mammography anomalies for breast cancer detection by an ensemble of classification models based on artificial immune system. *Knowledge-Based Systems*, Elsevier, v. 101, p. 60–70, 2016.
- MAITRA, I. K.; BANDYOPADHYAY, S. K. Identification of abnormal masses in digital mammogram using statistical decision making. *Hybrid Intelligence for Image Analysis and Understanding*, John Wiley & Sons, Ltd Chichester, UK, p. 339–368, 2017.
- MALLAT, S. G. et al. Multifrequency channel decompositions of images and wavelet models. *IEEE Trans. Acoustics, Speech, and Signal Processing*, v. 37, n. 12, p. 2091–2110, 1989.
- MASCARO, A. A.; MELLO, C. A.; SANTOS, W. P.; CAVALCANTI, G. D. Mammographic images segmentation using texture descriptors. In: IEEE. *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.], 2009. p. 3653–3653.
- MCHUGH, M. L. Interrater reliability: the kappa statistic. *Biochemia Medica, Medicinska naklada*, v. 22, n. 3, p. 276–282, 2012.
- MIGOWSKI, A.; DIAS, M. Diretrizes para a detecção precoce do câncer de mama no brasil. *Rio de Janeiro: Instituto Nacional de Câncer José Alencar Gomes da Silva*, 2015.
- NG, E.-K.; FOK, S.; PEH, Y.; NG, F.; SIM, L. Computerized detection of breast cancer with artificial intelligence and thermograms. *Journal of medical engineering & technology*, Taylor & Francis, v. 26, n. 4, p. 152–157, 2002.

NORDIN, Z. M.; ISA, N. A. M.; ZAMLI, K. Z.; NGAH, U. K.; AZIZ, M. E. Semi-automated region of interest selection tool for mammographic image. In: IEEE. *2008 International Symposium on Information Technology*. [S.l.], 2008. v. 1, p. 1–6.

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

OMRANIPOUR, R.; KAZEMIAN, A.; ALIPOUR, S.; NAJAFI, M.; ALIDOOSTI, M.; NAVID, M.; ALIKHASSI, A.; AHMADINEJAD, N.; BAGHERI, K.; IZADI, S. Comparison of the accuracy of thermography and mammography in the detection of breast cancer. *Breast Care*, Karger Publishers, v. 11, n. 4, p. 260–264, 2016.

PAHWA, P.; PAPREJA, M.; MIGLANI, R. Performance analysis of classification algorithms. *vol*, v. 3, p. 50–58, 2014.

PEREIRA, J.; SANTANA, M.; LIMA, N.; SOUSA, F.; LIMA, R. de; SANTOS, W. dos. Método para classificação do tipo da lesão na mama presentes nas imagens termográficas utilizando classificador elm. In: *Anais do I Simpósio de Inovação em Engenharia Biomédica - SABIO 2017*. [S.l.: s.n.], 2017. p. 11.

RAGHAVENDRA, U.; ACHARYA, U. R.; NG, E.; TAN, J.-H.; GUDIGAR, A. An integrated index for breast cancer identification using histogram of oriented gradient and kernel locality preserving projection features extracted from thermograms. *Quantitative InfraRed Thermography Journal*, Taylor & Francis, v. 13, n. 2, p. 195–209, 2016.

ROBBINS, S. L.; SCHNEIDER, N. R.; COTRAN, R. S.; KUMAR, V.; HAGLER, H. K. *Patologia de Robbins & Cotran: bases patológicas das doenças: estudo de casos interativos*. 8. ed. São Paulo: Elsevier, 2005.

RODRIGUES, A. L.; SANTANA, M. A. de; AZEVEDO, W. W.; BEZERRA, R. S.; BARBOSA, V. A.; LIMA, R. C. de; SANTOS, W. P. dos. Identification of mammary lesions in thermographic images: feature selection study using genetic algorithms and particle swarm optimization. *Research on Biomedical Engineering*, Springer, v. 35, n. 3, p. 213–222, 2019.

RODRIGUES, C. I. *Sistemas CAD em Patologia Mamária*. Dissertação (Mestrado) — Faculdade de Engenharia da Universidade do Porto, Setembro, 2008.

RODRIGUEZ-RUIZ, A.; LÅNG, K.; GUBERN-MERIDA, A.; BROEDERS, M.; GENNARO, G.; CLAUSER, P.; HELBICH, T. H.; CHEVALIER, M.; TAN, T.; MERTELMEIER, T. et al. Stand-alone artificial intelligence for breast cancer detection in mammography: comparison with 101 radiologists. *JNCI: Journal of the National Cancer Institute*, Narnia, v. 111, n. 9, p. 916–922, 2019.

SALMERI, M.; MENCATTINI, A.; RABOTTINO, G.; ACCATTATIS, A.; LOJACONO, R. Assisted breast cancer diagnosis environment: A tool for dicom mammographic images analysis. In: IEEE. *2009 IEEE International Workshop on Medical Measurements and Applications*. [S.l.], 2009. p. 160–165.

SANTANA, M.; PEREIRA, J.; LIMA, N.; SOUSA, F.; LIMA, R. de; SANTOS, W. dos. Classificação de lesões em imagens frontais de termografia de mama a partir de sistema inteligente de suporte ao diagnóstico. In: *Anais do I Simpósio de Inovação em Engenharia Biomédica - SABIO 2017*. [S.l.: s.n.], 2017. p. 16.

SANTANA, M.; SILVA, W.; SILVA, A.; PEREIRA, J. M.; BARBOSA, V. A.; DINIZ, C. A.; ALMEIDA, M.; LIMA, R.; SANTOS, W. Desempenho de máquinas de aprendizado extremo com operadores morfológicos para identificação e classificação de lesões em imagens frontais de termografia de mama. In: *Congresso Brasileiro de Automática [Anais]*. [S.l.: s.n.], 2018.

SANTANA, M. A. d.; PEREIRA, J. M. S.; SILVA, F. L. d.; LIMA, N. M. d.; SOUSA, F. N. d.; ARRUDA, G. M. S. d.; LIMA, R. d. C. F. d.; SILVA, W. W. A. d.; SANTOS, W. P. d. Breast cancer diagnosis based on mammary thermography and extreme learning machines. *Research on Biomedical Engineering*, SciELO Brasil, v. 34, n. 1, p. 45–53, 2018.

SANTOS, W. P.; ASSIS, F. M.; SANTOS-FILHO, R. E. S. P. B.; LIMA-NETO, F. B. Dialectical Multispectral Classification of Diffusion-Weighted Magnetic Resonance Images as an Alternative to Apparent Diffusion Coefficients Maps to Perform Anatomical Analysis. *Computerized Medical Imaging and Graphics*, v. 33, n. 6, p. 442–460, 2009.

SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E. MRI Segmentation using Dialectical Optimization. In: EMBS-IEEE. *31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Minneapolis, USA, 2009. p. 5752–5755.

SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E.; ALBUQUERQUE, A. C. T. C.; SIMAS, M. L. B. A Monospectral Approach for fMRI Analysis using Kohonen Self-Organized Networks and Objective Dialectical Classifiers. *International Journal of Innovative Computing and Applications*, v. 1, n. 4, p. 260–273, 2008.

SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E.; SANTOS-FILHO, P. B. Evaluation of Alzheimer's Disease by Analysis of MR Images using Objective Dialectical Classifiers as an Alternative to ADC Maps. In: EMBS-IEEE. *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Vancouver, Canada, 2008. p. 5506–5509.

SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E.; MENDES, P. B.; MONTEIRO, H. S. S.; ALVES, H. D. A Dialectical Method to Classify Alzheimer's Magnetic Resonance Images. In: SANTOS, W. P. (Ed.). *Evolutionary Computation*. Vukovar: InTech, 2009. p. 473–486.

SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E.; SANTOS-FILHO, P. B. Dialectical Classification of MR Images for the Evaluation of Alzheimer's Disease. In: Naik, G. R. (Ed.). *Recent Advances in Biomedical Engineering*. Vukovar: InTech, 2009. p. 241–250.

SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E.; MENDES, P. B.; MONTEIRO, H. S. S.; ALVES, H. D. Dialectical Non-Supervised Image Classification. In: CIS-IEEE. *IEEE Congress on Evolutionary Computation (CEC 2009)*. Trondheim, 2009. p. 2480–2487.

SANTOS, W. P.; SOUZA, R. E.; SANTOS-FILHO, P. B. Evaluation of Alzheimer's disease by analysis of MR images using multilayer perceptrons and Kohonen SOM classifiers as an alternative to the ADC maps. In: EMBS-IEEE. *29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Lyon, France, 2007. p. 2118–2121.

SANTOS, W. P.; SOUZA, R. E.; SANTOS-FILHO, P. B.; LIMA-NETO, F. B.; ASSIS, F. M. A Dialectical Approach for Classification of DW-MR Alzheimer's Images. In: CIS-IEEE. *IEEE World Congress on Computational Intelligence (WCCI 2008)*. Hong Kong, China, 2008. p. 1728–1735.

SANTOS, W. P.; SOUZA, R. E.; SILVA, A. F. D.; PORTELA, N. M.; SANTOS-FILHO, P. B. Análise multiespectral de imagens cerebrais de ressonância magnética ponderadas em difusão usando lógica nebulosa e redes neurais para avaliação de danos causados pela doença de Alzheimer. In: SOCIEDADE BRASILEIRA DE FÍSICA MÉDICA. *XI Congresso Brasileiro de Física Médica*. Ribeirão Preto, Brasil, 2006.

SANTOS, W. P.; SOUZA, R. E.; SILVA, A. F. D.; PORTELA, N. M.; SANTOS-FILHO, P. B. Avaliação da doença de Alzheimer por análise de imagens de RMN utilizando redes MLP e máquinas de comitê. In: SOCIEDADE BRASILEIRA DE ENGENHARIA BIOMÉDICA. *XX Congresso Brasileiro de Engenharia Biomédica*. São Pedro, Brasil, 2006.

SANTOS, W. P.; SOUZA, R. E.; SILVA, A. F. D.; SANTOS-FILHO, P. B. Evaluation of Alzheimer's disease by analysis of MR images using multilayer perceptrons and committee machines. *Computerized Medical Imaging and Graphics*, v. 32, n. 1, p. 17–21, 2008.

SHRIVASTAVA, S. R.; SHRIVASTAVA, P. S.; JEGADEESH, R. et al. Ensuring early detection of cancer in low-and middle-income nations: World health organization. *Archives of Medicine and Health Sciences*, Medknow Publications, v. 5, n. 1, p. 141, 2017.

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

SILVA, W. W. A. da. *Máquinas morfológicas de aprendizado extremo aplicadas à detecção e classificação de lesões em mamografias*. Tese (Doutorado) — Centro de Informática da Universidade Federal de Pernambuco, Recife, 2017.

SIU, A. L. Screening for breast cancer: Us preventive services task force recommendation statement. *Annals of internal medicine*, American College of Physicians, v. 164, n. 4, p. 279–296, 2016.

SUCKLING, J.; PARKER, J.; DANCE, D.; ASTLEY, S.; HUTT, I.; BOGGIS, C.; RICKETTS, I.; STAMATAKIS, E.; CERNEAZ, N.; KOK, S. et al. The mammographic image analysis society digital mammogram database. In: EXCERTA MEDICA. [S.l.]: Elsevier, 1994. p. 375–386.

URBAIN, J.-L. Breast cancer screening, diagnostic accuracy and health care policies. *Canadian Medical Association Journal*, Canadian Medical Association, v. 172, n. 2, p. 210–211, 2005.

VASCONCELOS, J. de; SANTOS, W. dos; LIMA, R. de. Analysis of methods of classification of breast thermographic images to determine their viability in the early breast cancer detection. *IEEE Latin America Transactions*, IEEE, v. 16, n. 6, p. 1631–1637, 2018.

WANG, S.; RAO, R. V.; CHEN, P.; ZHANG, Y.; LIU, A.; WEI, L. Abnormal breast detection in mammogram images by feed-forward neural network trained by jaya algorithm. *Fundamenta Informaticae*, IOS press, v. 151, n. 1-4, p. 191–211, 2017.

WEINBERG, R. A. *A biologia do câncer*. [S.l.]: Artmed Editora, 2008.

WISSLER, R. *Entendendo a Radiação Médica: Mamografia*. 2016. Disponível em: <<http://www.radiacao-medica.com.br/tipos-de-imagens-medicas/raios-x/mamografia/>>. Acesso em: 15/01/2020.

ZADEH, H. G.; MONTAZERI, A.; KAZEROUNI, I. A.; HADDADNIA, J. Clustering and screening for breast cancer on thermal images using a combination of som and mlp. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, Taylor & Francis, v. 5, n. 1, p. 68–76, 2017.

ZHAO, A.; SANTANA, M.; SAMEI, E.; LO, J. Comparison of effects of dose on image quality in digital breast tomosynthesis across multiple vendors. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Medical Imaging 2017: Physics of Medical Imaging*. [S.l.], 2017. v. 10132, p. 101324E.

APÊNDICE A – TABELAS DE RESULTADOS EXPANDIDAS

Tabela A1 – Desempenho dos classificadores utilizando Haralick e Zernike para extração de atributos e imagens de Termografia

| Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|--------------|-------------|--------------|-------------|
| | | Média | DP | Média | DP |
| Bayes Net | - | 52,56 | 4,50 | 0,37 | 0,06 |
| Naive Bayes | - | 51,54 | 4,58 | 0,35 | 0,06 |
| MLP | 10 neurônios | 80,65 | 4,08 | 0,74 | 0,05 |
| | 50 neurônios | 85,65 | 3,72 | 0,81 | 0,05 |
| | 100 neurônios | 85,90 | 3,57 | 0,81 | 0,05 |
| SVM | kernel linear | 78,65 | 4,14 | 0,72 | 0,06 |
| | kernel polinomial (E=2) | 90,63 | 3,06 | 0,88 | 0,04 |
| | kernel polinomial (E=3) | 91,11 | 3,03 | 0,88 | 0,04 |
| | kernel polinomial (E=4) | 91,41 | 2,91 | 0,89 | 0,04 |
| | kernel polinomial (E=5) | 85,38 | 4,26 | 0,81 | 0,06 |
| | kernel RBF ($\gamma=0,01$) | 53,63 | 4,55 | 0,38 | 0,06 |
| | kernel RBF ($\gamma=0,25$) | 78,30 | 4,26 | 0,71 | 0,06 |
| | kernel RBF ($\gamma=0,50$) | 81,47 | 4,01 | 0,75 | 0,05 |
| | J48 | - | 57,58 | 5,01 | 0,43 |
| Random Tree | - | 51,01 | 5,00 | 0,35 | 0,07 |
| Random Forest | 10 árvores | 63,70 | 4,77 | 0,52 | 0,06 |
| | 50 árvores | 70,10 | 4,48 | 0,60 | 0,06 |
| | 100 árvores | 71,11 | 4,17 | 0,61 | 0,06 |
| ELM | kernel sigmoidal | 78,56 | 4,32 | 0,77 | 0,05 |
| | kernel dilatação | 88,49 | 3,25 | 0,88 | 0,03 |
| | kernel erosão | 88,46 | 3,29 | 0,88 | 0,04 |

Fonte: A Autora (2019).

Tabela A2 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Termografia

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|-------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 73,63 | 3,93 | 0,65 | 0,05 | |
| | Naive Bayes | - | 67,72 | 4,62 | 0,57 | 0,06 | |
| | MLP | 10 neurônios | | 68,32 | 16,54 | 0,58 | 0,22 |
| | | 50 neurônios | | 55,49 | 12,93 | 0,41 | 0,17 |
| | | 100 neurônios | | 48,16 | 11,62 | 0,31 | 0,15 |
| | SVM | kernel linear | | 96,82 | 1,66 | 0,96 | 0,02 |
| | | kernel poli (E=2) | | 96,89 | 1,66 | 0,96 | 0,02 |
| | | kernel poli (E=3) | | 96,49 | 1,78 | 0,95 | 0,02 |
| | | kernel poli (E=4) | | 94,62 | 2,15 | 0,93 | 0,03 |
| | | kernel poli (E=5) | | 94,87 | 2,11 | 0,93 | 0,03 |
| | | kernel RBF ($\gamma=0,01$) | | 86,11 | 3,44 | 0,81 | 0,05 |
| | | kernel RBF ($\gamma=0,25$) | | 78,75 | 3,92 | 0,72 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,50$) | | 74,42 | 4,01 | 0,66 | 0,05 |
| | | - | | 65,44 | 4,75 | 0,54 | 0,06 |
| | | - | | 49,40 | 4,92 | 0,33 | 0,06 |
| | Random Tree | 10 árvores | | 67,12 | 4,91 | 0,56 | 0,06 |
| | | 50 árvores | | 83,12 | 3,88 | 0,77 | 0,05 |
| 100 árvores | | | 86,58 | 3,31 | 0,82 | 0,04 | |
| ELM | kernel sigmoidal | | 49,39 | 5,35 | 0,45 | 0,06 | |
| | kernel dilatação | | 74,64 | 4,53 | 0,73 | 0,05 | |
| | kernel erosão | | 74,65 | 4,74 | 0,73 | 0,05 | |
| Bayes Net | - | 49,77 | 4,62 | 0,33 | 0,06 | | |

Tabela A2 – Desempenho dos classificadores utilizando DWIN para extração de atributos e imagens de Termografia

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|--------------|------------------|------------------------------|--------------|-------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 49,30 | 4,52 | 0,32 | 0,06 |
| | MLP | 10 neurônios | 94,99 | 2,06 | 0,93 | 0,03 |
| | | 50 neurônios | 95,78 | 1,96 | 0,94 | 0,03 |
| | | 100 neurônios | 95,88 | 1,94 | 0,95 | 0,02 |
| | SVM | kernel linear | 99,13 | 0,92 | 0,99 | 0,01 |
| | | kernel poli (E=2) | 98,75 | 1,09 | 0,98 | 0,01 |
| | | kernel poli (E=3) | 97,84 | 1,55 | 0,97 | 0,02 |
| | | kernel poli (E=4) | 88,72 | 5,71 | 0,85 | 0,08 |
| | | kernel poli (E=5) | 88,79 | 5,78 | 0,85 | 0,08 |
| | | kernel RBF ($\gamma=0,01$) | 74,94 | 3,98 | 0,67 | 0,05 |
| | | kernel RBF ($\gamma=0,25$) | 81,98 | 4,15 | 0,76 | 0,06 |
| | | kernel RBF ($\gamma=0,50$) | 76,98 | 4,22 | 0,69 | 0,06 |
| | J48 | - | 51,63 | 4,91 | 0,36 | 0,06 |
| | Random Tree | - | 46,24 | 4,74 | 0,28 | 0,06 |
| | Random Forest | 10 árvores | 62,64 | 4,87 | 0,50 | 0,06 |
| 50 árvores | | 79,92 | 3,77 | 0,73 | 0,05 | |
| 100 árvores | | 84,69 | 3,53 | 0,80 | 0,05 | |
| ELM | kernel sigmoidal | 53,73 | 5,01 | 0,50 | 0,06 | |
| | kernel dilatação | 74,04 | 4,70 | 0,72 | 0,05 | |
| | kernel erosão | 74,15 | 4,94 | 0,72 | 0,05 | |
| | Bayes Net | - | 4,00 | 0,29 | 0,05 | |
| | Naive Bayes | - | 3,98 | 0,18 | 0,05 | |

Tabela A2 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Termografia

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------------------|-------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 47,79 | 4,53 | 0,30 | 0,06 |
| | | 50 neurônios | 47,06 | 5,03 | 0,29 | 0,07 |
| | SVM | 100 neurônios | 46,33 | 5,21 | 0,28 | 0,07 |
| | | kernel linear | 47,73 | 3,92 | 0,30 | 0,05 |
| | | kernel poli (E=2) | 46,09 | 3,85 | 0,28 | 0,05 |
| | kernel poli (E=3) | 43,76 | 3,96 | 0,25 | 0,05 | |
| | kernel poli (E=4) | 43,01 | 3,82 | 0,24 | 0,05 | |
| | kernel poli (E=5) | 42,54 | 3,81 | 0,23 | 0,05 | |
| | kernel RBF ($\gamma=0,01$) | 30,66 | 3,06 | 0,08 | 0,04 | |
| | kernel RBF ($\gamma=0,25$) | 45,68 | 3,82 | 0,28 | 0,05 | |
| | kernel RBF ($\gamma=0,50$) | 46,24 | 3,85 | 0,28 | 0,05 | |
| | J48 | - | 52,17 | 4,25 | 0,36 | 0,06 |
| | Random Tree | - | 53,11 | 4,26 | 0,37 | 0,06 |
| | Random Forest | 10 árvores | 54,89 | 4,26 | 0,40 | 0,06 |
| | | 50 árvores | 55,27 | 4,23 | 0,40 | 0,06 |
| 100 árvores | | 55,31 | 4,22 | 0,40 | 0,06 | |
| ELM | kernel sigmoidal | 53,81 | 5,02 | 0,52 | 0,05 | |
| | kernel dilatação | 54,86 | 5,04 | 0,53 | 0,05 | |
| | kernel erosão | 54,84 | 4,67 | 0,53 | 0,05 | |
| Bayes Net | - | 69,26 | 3,90 | 0,59 | 0,05 | |
| Naive Bayes | - | 66,61 | 4,35 | 0,55 | 0,06 | |
| MLP | 10 neurônios | 68,72 | 16,08 | 0,58 | 0,21 | |

Tabela A2 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Termografia

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------|------------------------------|--------------|-------|--------------|------|
| | | | Média | DP | Média | DP |
| Mediana | SVM | 50 neurônios | 54,87 | 14,90 | 0,40 | 0,20 |
| | | 100 neurônios | 44,78 | 11,08 | 0,26 | 0,15 |
| | | kernel linear | 96,38 | 1,85 | 0,95 | 0,02 |
| | | kernel poli (E=2) | 96,74 | 1,76 | 0,96 | 0,02 |
| | | kernel poli (E=3) | 96,47 | 1,90 | 0,95 | 0,02 |
| | | kernel poli (E=4) | 93,43 | 2,49 | 0,91 | 0,03 |
| | | kernel poli (E=5) | 93,98 | 2,32 | 0,92 | 0,03 |
| | | kernel RBF ($\gamma=0,01$) | 83,91 | 3,60 | 0,79 | 0,05 |
| | | kernel RBF ($\gamma=0,25$) | 79,52 | 3,93 | 0,73 | 0,05 |
| | | kernel RBF ($\gamma=0,50$) | 76,11 | 4,26 | 0,68 | 0,06 |
| J48 | - | 67,19 | 4,46 | 0,56 | 0,06 | |
| Random Tree | - | 52,79 | 5,16 | 0,37 | 0,07 | |
| Random Forest | 10 árvores | 70,11 | 4,42 | 0,60 | 0,06 | |
| | 50 árvores | 84,15 | 3,86 | 0,79 | 0,05 | |
| | 100 árvores | 86,83 | 3,57 | 0,82 | 0,05 | |
| ELM | kernel sigmoidal | 51,04 | 5,43 | 0,47 | 0,06 | |
| | kernel dilatação | 75,83 | 4,36 | 0,74 | 0,05 | |
| | kernel erosão | 75,55 | 4,60 | 0,74 | 0,05 | |
| Bayes Net | - | 50,37 | 4,26 | 0,34 | 0,06 | |
| Naive Bayes | - | 51,16 | 5,69 | 0,35 | 0,08 | |
| MLP | 10 neurônios | 89,64 | 3,39 | 0,86 | 0,04 | |
| | 50 neurônios | 87,34 | 4,27 | 0,83 | 0,06 | |

Tabela A2 – Desempenho dos classificadores utilizando DWIN para extração de atributos e imagens de Termografia

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 85,47 | 4,97 | 0,81 | 0,07 |
| | | kernel linear | 91,66 | 2,54 | 0,89 | 0,03 |
| | | kernel poli (E=2) | 87,23 | 3,40 | 0,83 | 0,04 |
| | | kernel poli (E=3) | 80,86 | 4,12 | 0,74 | 0,05 |
| | | kernel poli (E=4) | 56,30 | 7,69 | 0,42 | 0,10 |
| | kernel poli (E=5) | 51,14 | 6,84 | 0,35 | 0,09 | |
| | kernel RBF ($\gamma=0,01$) | 88,83 | 3,05 | 0,85 | 0,04 | |
| | kernel RBF ($\gamma=0,25$) | 42,47 | 5,03 | 0,23 | 0,07 | |
| | kernel RBF ($\gamma=0,50$) | 31,57 | 2,70 | 0,09 | 0,04 | |
| | J48 | - | 55,88 | 4,76 | 0,41 | 0,06 |
| Random Tree | - | 46,83 | 5,25 | 0,29 | 0,07 | |
| Random Forest | 10 árvores | 61,57 | 4,97 | 0,49 | 0,07 | |
| | 50 árvores | 77,03 | 4,10 | 0,69 | 0,05 | |
| | 100 árvores | 80,85 | 4,07 | 0,74 | 0,05 | |
| ELM | kernel sigmoidal | 62,02 | 5,26 | 0,59 | 0,06 | |
| | kernel dilatação | 73,67 | 4,41 | 0,72 | 0,05 | |
| | kernel erosão | 73,63 | 4,91 | 0,72 | 0,05 | |

Fonte: A Autora (2019).

Tabela A3 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido I

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|---------------|---------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 73,19 | 3,56 | 0,60 | 0,05 | |
| | Naive Bayes | - | 72,53 | 3,63 | 0,59 | 0,05 | |
| | MLP | 10 neurônios | | 50,14 | 11,48 | 0,25 | 0,17 |
| | | 50 neurônios | | 38,53 | 9,51 | 0,08 | 0,14 |
| | | 100 neurônios | | 33,81 | 2,67 | 0,01 | 0,04 |
| | SVM | kernel linear | | 93,07 | 2,09 | 0,90 | 0,03 |
| | | kernel poli (E=2) | | 93,30 | 2,10 | 0,90 | 0,03 |
| | | kernel poli (E=3) | | 88,09 | 3,08 | 0,82 | 0,05 |
| | | kernel poli (E=4) | | 86,65 | 2,86 | 0,80 | 0,04 |
| | | kernel poli (E=5) | | 87,16 | 3,05 | 0,81 | 0,04 |
| | | kernel RBF ($\gamma=0,01$) | | 76,10 | 3,53 | 0,64 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,25$) | | 90,89 | 4,10 | 0,86 | 0,06 |
| | | kernel RBF ($\gamma=0,50$) | | 68,83 | 4,68 | 0,53 | 0,07 |
| | | - | | 65,52 | 4,18 | 0,48 | 0,06 |
| | | - | | 55,72 | 4,34 | 0,34 | 0,06 |
| | | Random Tree | | 68,81 | 3,98 | 0,53 | 0,06 |
| Random Forest | | 10 árvores | 79,26 | 3,37 | 0,69 | 0,05 | |
| | | 50 árvores | 81,41 | 3,17 | 0,72 | 0,05 | |
| | | 100 árvores | 48,51 | 4,58 | 0,41 | 0,05 | |
| ELM | | kernel sigmoidal | | 63,21 | 4,20 | 0,58 | 0,05 |
| | | kernel dilatação | | 61,95 | 4,58 | 0,57 | 0,05 |
| | kernel erosão | | 69,26 | 3,60 | 0,54 | 0,05 | |
| | Bayes Net | - | 69,26 | 3,60 | 0,54 | 0,05 | |

Tabela A3 – Desempenho dos classificadores utilizando DWIN para extração de atributos e imagens de Mamografia do Tecido I

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 60,46 | 4,35 | 0,41 | 0,06 |
| | MLP | 10 neurônios | 86,86 | 2,70 | 0,80 | 0,04 |
| | | 50 neurônios | 87,31 | 2,74 | 0,81 | 0,04 |
| | | 100 neurônios | 87,39 | 2,64 | 0,81 | 0,04 |
| | SVM | kernel linear | 95,10 | 1,80 | 0,93 | 0,03 |
| | | kernel poli (E=2) | 95,33 | 1,75 | 0,93 | 0,03 |
| | | kernel poli (E=3) | 94,91 | 1,79 | 0,92 | 0,03 |
| | | kernel poli (E=4) | 91,38 | 2,31 | 0,87 | 0,03 |
| | | kernel poli (E=5) | 91,85 | 2,37 | 0,88 | 0,04 |
| | | kernel RBF ($\gamma=0,01$) | 80,76 | 3,03 | 0,71 | 0,04 |
| | | kernel RBF ($\gamma=0,25$) | 95,58 | 2,34 | 0,93 | 0,04 |
| | J48 | kernel RBF ($\gamma=0,50$) | 66,92 | 4,16 | 0,50 | 0,06 |
| | | - | 55,48 | 3,92 | 0,33 | 0,06 |
| | | - | 47,57 | 4,45 | 0,21 | 0,07 |
| Random Tree | 10 árvores | 59,76 | 3,84 | 0,40 | 0,06 | |
| | 50 árvores | 74,62 | 3,44 | 0,62 | 0,05 | |
| | 100 árvores | 79,16 | 3,31 | 0,69 | 0,05 | |
| ELM | kernel sigmoidal | 50,60 | 4,41 | 0,45 | 0,05 | |
| | kernel dilatação | 63,23 | 4,25 | 0,59 | 0,05 | |
| | kernel erosão | 62,82 | 4,36 | 0,58 | 0,05 | |
| | Bayes Net | - | 70,37 | 3,57 | 0,56 | 0,05 |
| | Naive Bayes | - | 72,73 | 3,79 | 0,59 | 0,06 |

Tabela A3 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido I

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|------------------|---------------|-------------------|--------------|--------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 48,00 | 12,85 | 0,22 | 0,19 |
| | | 50 neurônios | 39,81 | 10,11 | 0,10 | 0,15 |
| | SVM | 100 neurônios | 33,96 | 3,33 | 0,01 | 0,05 |
| | | kernel linear | 94,57 | 1,77 | 0,92 | 0,03 |
| | | kernel poli (E=2) | 96,63 | 1,42 | 0,95 | 0,02 |
| | | kernel poli (E=3) | 95,98 | 1,55 | 0,94 | 0,02 |
| | | kernel poli (E=4) | 93,13 | 2,13 | 0,90 | 0,03 |
| | | kernel poli (E=5) | 87,60 | 3,90 | 0,81 | 0,06 |
| | J48 | - | 80,70 | 3,37 | 0,71 | 0,05 |
| | Random Tree | - | 89,80 | 3,89 | 0,85 | 0,06 |
| | | 10 árvores | 66,81 | 3,68 | 0,50 | 0,06 |
| | Random Forest | 50 árvores | 59,75 | 4,35 | 0,40 | 0,06 |
| | | 100 árvores | 48,33 | 4,25 | 0,22 | 0,06 |
| | ELM | kernel sigmoidal | 61,73 | 4,04 | 0,43 | 0,06 |
| kernel dilatação | | 77,66 | 3,34 | 0,66 | 0,05 | |
| kernel erosão | | 82,19 | 3,07 | 0,73 | 0,05 | |
| - | | 61,47 | 4,33 | 0,56 | 0,05 | |
| Bayes Net | - | 63,40 | 3,98 | 0,58 | 0,04 | |
| Naive Bayes | - | 63,07 | 4,38 | 0,58 | 0,05 | |
| MLP | 10 neurônios | 63,73 | 2,89 | 0,46 | 0,04 | |
| | | 64,04 | 2,92 | 0,46 | 0,04 | |
| | | 88,08 | 2,85 | 0,82 | 0,04 | |

Tabela A3 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido I

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Mediana | SVM | 50 neurônios | 88,32 | 2,75 | 0,82 | 0,04 |
| | | 100 neurônios | 88,35 | 2,77 | 0,83 | 0,04 |
| | | kernel linear | 92,88 | 2,26 | 0,89 | 0,03 |
| | | kernel poli (E=2) | 92,87 | 2,32 | 0,89 | 0,03 |
| | | kernel poli (E=3) | 92,63 | 2,29 | 0,89 | 0,03 |
| | | kernel poli (E=4) | 87,59 | 3,27 | 0,81 | 0,05 |
| | | kernel poli (E=5) | 85,96 | 4,40 | 0,79 | 0,06 |
| | | kernel RBF ($\gamma=0,01$) | 74,50 | 3,26 | 0,62 | 0,05 |
| | | kernel RBF ($\gamma=0,25$) | 82,39 | 5,64 | 0,74 | 0,08 |
| | | kernel RBF ($\gamma=0,50$) | 60,71 | 4,87 | 0,41 | 0,07 |
| J48 | - | 62,63 | 3,98 | 0,44 | 0,06 | |
| Random Tree | - | 58,07 | 4,23 | 0,37 | 0,06 | |
| Random Forest | 10 árvores | 67,88 | 3,74 | 0,52 | 0,06 | |
| | 50 árvores | 73,02 | 3,39 | 0,60 | 0,05 | |
| | 100 árvores | 73,99 | 3,54 | 0,61 | 0,05 | |
| ELM | kernel sigmoidal | 59,85 | 4,48 | 0,55 | 0,05 | |
| | kernel dilatação | 68,82 | 3,99 | 0,65 | 0,05 | |
| | kernel erosão | 69,75 | 3,94 | 0,66 | 0,04 | |
| Bayes Net | - | 67,08 | 3,78 | 0,51 | 0,06 | |
| Naive Bayes | - | 73,89 | 6,18 | 0,61 | 0,09 | |
| MLP | 10 neurônios | 83,79 | 2,84 | 0,76 | 0,04 | |
| | 50 neurônios | 85,69 | 2,70 | 0,79 | 0,04 | |

Tabela A3 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido I

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 86,16 | 2,56 | 0,79 | 0,04 |
| | | kernel linear | 95,27 | 1,63 | 0,93 | 0,02 |
| | | kernel poli (E=2) | 96,28 | 1,45 | 0,94 | 0,02 |
| | | kernel poli (E=3) | 95,95 | 1,58 | 0,94 | 0,02 |
| | | kernel poli (E=4) | 95,42 | 1,67 | 0,93 | 0,02 |
| | kernel poli (E=5) | 95,68 | 1,62 | 0,94 | 0,02 | |
| | kernel RBF ($\gamma=0,01$) | 93,37 | 1,77 | 0,90 | 0,03 | |
| | kernel RBF ($\gamma=0,25$) | 38,49 | 6,32 | 0,08 | 0,09 | |
| | kernel RBF ($\gamma=0,50$) | 33,17 | 0,72 | 0,00 | 0,01 | |
| | J48 | - | 51,22 | 4,37 | 0,27 | 0,06 |
| Random Tree | - | 43,88 | 4,59 | 0,16 | 0,07 | |
| Random Forest | 10 árvores | 52,94 | 4,32 | 0,29 | 0,06 | |
| | 50 árvores | 70,73 | 3,77 | 0,56 | 0,06 | |
| | 100 árvores | 78,08 | 3,44 | 0,67 | 0,05 | |
| ELM | kernel sigmoidal | 47,20 | 4,50 | 0,41 | 0,05 | |
| | kernel dilatação | 56,35 | 4,19 | 0,51 | 0,05 | |
| | kernel erosão | 55,41 | 4,65 | 0,50 | 0,05 | |

Fonte: A Autora (2019).

Tabela A4 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido II

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|---------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 83,38 | 2,89 | 0,75 | 0,04 | |
| | Naive Bayes | - | 78,12 | 3,55 | 0,67 | 0,05 | |
| | MLP | 10 neurônios | | 33,79 | 3,62 | 0,01 | 0,05 |
| | | 50 neurônios | | 33,68 | 2,97 | 0,01 | 0,04 |
| | | 100 neurônios | | 33,53 | 1,67 | 0,00 | 0,02 |
| | SVM | kernel linear | | 94,72 | 1,88 | 0,92 | 0,03 |
| | | kernel poli (E=2) | | 95,07 | 1,84 | 0,93 | 0,03 |
| | | kernel poli (E=3) | | 91,13 | 2,62 | 0,87 | 0,04 |
| | | kernel poli (E=4) | | 90,11 | 2,52 | 0,85 | 0,04 |
| | | kernel poli (E=5) | | 90,47 | 2,39 | 0,86 | 0,04 |
| | | kernel RBF ($\gamma=0,01$) | | 84,17 | 2,98 | 0,76 | 0,04 |
| | J48 | kernel RBF ($\gamma=0,25$) | | 73,97 | 5,05 | 0,61 | 0,08 |
| | | kernel RBF ($\gamma=0,50$) | | 65,95 | 3,65 | 0,49 | 0,05 |
| | | - | | 74,63 | 3,44 | 0,62 | 0,05 |
| | Random Tree | - | 61,30 | 4,74 | 0,42 | 0,07 | |
| Random Forest | 10 árvores | | 74,39 | 3,55 | 0,62 | 0,05 | |
| | 50 árvores | | 85,05 | 2,83 | 0,78 | 0,04 | |
| | 100 árvores | | 88,16 | 2,56 | 0,82 | 0,04 | |
| ELM | kernel sigmoidal | | 55,82 | 4,48 | 0,50 | 0,05 | |
| | kernel dilatação | | 71,57 | 3,92 | 0,68 | 0,04 | |
| | kernel erosão | | 70,43 | 4,14 | 0,67 | 0,05 | |
| Bayes Net | - | 81,92 | 2,71 | 0,73 | 0,04 | | |

Tabela A4 – Desempenho dos classificadores utilizando DWWN para extração de atributos e imagens de Mamografia do Tecido II

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 73,52 | 2,57 | 0,60 | 0,04 |
| | MLP | 10 neurônios | 92,81 | 1,98 | 0,89 | 0,03 |
| | | 50 neurônios | 92,92 | 1,97 | 0,89 | 0,03 |
| | | 100 neurônios | 92,89 | 2,02 | 0,89 | 0,03 |
| | SVM | kernel linear | 97,27 | 1,38 | 0,96 | 0,02 |
| | | kernel poli (E=2) | 97,39 | 1,37 | 0,96 | 0,02 |
| | | kernel poli (E=3) | 97,36 | 1,42 | 0,96 | 0,02 |
| | | kernel poli (E=4) | 95,39 | 1,73 | 0,93 | 0,02 |
| | | kernel poli (E=5) | 95,58 | 1,65 | 0,93 | 0,02 |
| | | kernel RBF ($\gamma=0,01$) | 91,20 | 2,15 | 0,87 | 0,03 |
| | J48 | kernel RBF ($\gamma=0,25$) | 97,01 | 2,24 | 0,96 | 0,03 |
| | | kernel RBF ($\gamma=0,50$) | 69,01 | 4,88 | 0,54 | 0,07 |
| | | - | 73,18 | 3,73 | 0,60 | 0,06 |
| | Random Tree | - | 61,41 | 4,67 | 0,42 | 0,07 |
| | | 10 árvores | 76,02 | 3,51 | 0,64 | 0,05 |
| Random Forest | 50 árvores | 85,61 | 2,77 | 0,78 | 0,04 | |
| | 100 árvores | 88,72 | 2,66 | 0,83 | 0,04 | |
| | kernel sigmoidal | 60,81 | 4,57 | 0,57 | 0,05 | |
| ELM | kernel dilatação | 75,20 | 3,74 | 0,72 | 0,04 | |
| | kernel erosão | 75,36 | 3,70 | 0,72 | 0,04 | |
| | Bayes Net | - | 80,57 | 3,37 | 0,71 | 0,05 |
| | Naive Bayes | - | 75,40 | 3,64 | 0,63 | 0,05 |

Tabela A4 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido II

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|------------------|------------------|------------------------------|--------------|-------|--------------|------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 42,83 | 13,77 | 0,14 | 0,21 |
| | | 50 neurônios | 35,46 | 7,38 | 0,03 | 0,11 |
| | SVM | 100 neurônios | 33,45 | 1,68 | 0,00 | 0,02 |
| | | kernel linear | 95,18 | 1,63 | 0,93 | 0,02 |
| | | kernel poli (E=2) | 96,36 | 1,60 | 0,95 | 0,02 |
| | | kernel poli (E=3) | 95,21 | 1,84 | 0,93 | 0,03 |
| | | kernel poli (E=4) | 92,17 | 2,40 | 0,88 | 0,04 |
| | | kernel poli (E=5) | 87,28 | 4,44 | 0,81 | 0,07 |
| | | kernel RBF ($\gamma=0,01$) | 85,21 | 2,72 | 0,78 | 0,04 |
| | J48 | kernel RBF ($\gamma=0,25$) | 92,93 | 3,31 | 0,89 | 0,05 |
| | | kernel RBF ($\gamma=0,50$) | 72,24 | 5,10 | 0,58 | 0,08 |
| | | - | 67,63 | 4,26 | 0,51 | 0,06 |
| | Random Tree | - | 56,75 | 4,66 | 0,35 | 0,07 |
| | | 10 árvores | 71,59 | 3,95 | 0,57 | 0,06 |
| | Random Forest | 50 árvores | 84,05 | 2,88 | 0,76 | 0,04 |
| 100 árvores | | 87,34 | 2,60 | 0,81 | 0,04 | |
| kernel sigmoidal | | 69,16 | 3,90 | 0,65 | 0,04 | |
| ELM | kernel dilatação | 71,07 | 3,96 | 0,67 | 0,04 | |
| | kernel erosão | 70,77 | 3,92 | 0,67 | 0,04 | |
| Mínimo | Bayes Net | - | 85,85 | 3,10 | 0,79 | 0,05 |
| | Naive Bayes | - | 88,91 | 3,05 | 0,83 | 0,04 |
| | MLP | 10 neurônios | 93,18 | 1,94 | 0,90 | 0,03 |

Tabela A4 – Desempenho dos classificadores utilizando DWWN para extração de atributos e imagens de Mamografia do Tecido II

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|----------------|------------------|------------------------------|--------------|-------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Mediana | SVM | 50 neurônios | 93,36 | 1,99 | 0,90 | 0,03 |
| | | 100 neurônios | 93,42 | 1,89 | 0,90 | 0,03 |
| | | kernel linear | 98,04 | 1,07 | 0,97 | 0,02 |
| | | kernel poli (E=2) | 98,19 | 1,04 | 0,97 | 0,02 |
| | | kernel poli (E=3) | 98,31 | 1,01 | 0,97 | 0,02 |
| | | kernel poli (E=4) | 97,18 | 1,30 | 0,96 | 0,02 |
| | | kernel poli (E=5) | 97,41 | 1,27 | 0,96 | 0,02 |
| | | kernel RBF ($\gamma=0,01$) | 91,14 | 2,53 | 0,87 | 0,04 |
| | | kernel RBF ($\gamma=0,25$) | 98,80 | 0,92 | 0,98 | 0,01 |
| | | kernel RBF ($\gamma=0,50$) | 67,89 | 5,18 | 0,52 | 0,08 |
| J48 | - | 72,23 | 3,62 | 0,58 | 0,05 | |
| Random Tree | - | 71,03 | 3,27 | 0,57 | 0,05 | |
| Random Forest | 10 árvores | 77,26 | 3,03 | 0,66 | 0,04 | |
| | 50 árvores | 85,85 | 2,78 | 0,79 | 0,04 | |
| | 100 árvores | 89,23 | 2,51 | 0,84 | 0,04 | |
| ELM | kernel sigmoidal | 73,34 | 3,71 | 0,70 | 0,04 | |
| | kernel dilatação | 79,31 | 3,14 | 0,77 | 0,04 | |
| | kernel erosão | 79,73 | 3,69 | 0,77 | 0,04 | |
| Bayes Net | - | 77,09 | 3,47 | 0,66 | 0,05 | |
| Naive Bayes | - | 79,53 | 5,46 | 0,69 | 0,08 | |
| MLP | 10 neurônios | 85,20 | 2,96 | 0,78 | 0,04 | |
| | 50 neurônios | 87,49 | 2,59 | 0,81 | 0,04 | |

Tabela A4 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia do Tecido II

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 88,37 | 2,73 | 0,83 | 0,04 |
| | | kernel linear | 96,66 | 1,39 | 0,95 | 0,02 |
| | | kernel poli (E=2) | 97,40 | 1,21 | 0,96 | 0,02 |
| | | kernel poli (E=3) | 96,89 | 1,34 | 0,95 | 0,02 |
| | | kernel poli (E=4) | 96,31 | 1,44 | 0,94 | 0,02 |
| | kernel poli (E=5) | 96,54 | 1,40 | 0,95 | 0,02 | |
| | kernel RBF ($\gamma=0,01$) | 94,75 | 1,84 | 0,92 | 0,03 | |
| | kernel RBF ($\gamma=0,25$) | 38,40 | 6,33 | 0,08 | 0,09 | |
| | kernel RBF ($\gamma=0,50$) | 33,21 | 1,09 | 0,00 | 0,01 | |
| | J48 | - | 58,98 | 4,11 | 0,38 | 0,06 |
| Random Tree | - | 45,83 | 3,98 | 0,19 | 0,06 | |
| Random Forest | 10 árvores | 57,85 | 4,27 | 0,37 | 0,06 | |
| | 50 árvores | 75,95 | 3,31 | 0,64 | 0,05 | |
| | 100 árvores | 82,80 | 3,17 | 0,74 | 0,05 | |
| ELM | kernel sigmoidal | 48,43 | 4,80 | 0,42 | 0,06 | |
| | kernel dilatação | 57,50 | 4,42 | 0,52 | 0,05 | |
| | kernel erosão | 56,93 | 4,40 | 0,52 | 0,05 | |

Fonte: A Autora (2019).

Tabela A5 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia do Tecido III

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|---------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 81,81 | 3,09 | 0,73 | 0,05 | |
| | Naive Bayes | - | 78,26 | 3,38 | 0,67 | 0,05 | |
| | MLP | 10 neurônios | | 35,45 | 7,55 | 0,03 | 0,11 |
| | | 50 neurônios | | 34,18 | 4,58 | 0,01 | 0,07 |
| | | 100 neurônios | | 33,55 | 2,12 | 0,00 | 0,03 |
| | SVM | kernel linear | | 93,34 | 2,02 | 0,90 | 0,03 |
| | | kernel poli (E=2) | | 93,79 | 1,98 | 0,91 | 0,03 |
| | | kernel poli (E=3) | | 89,85 | 2,70 | 0,85 | 0,04 |
| | | kernel poli (E=4) | | 88,72 | 2,57 | 0,83 | 0,04 |
| | | kernel poli (E=5) | | 88,98 | 2,58 | 0,83 | 0,04 |
| | | kernel RBF ($\gamma=0,01$) | | 82,93 | 3,17 | 0,74 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,25$) | | 74,34 | 4,65 | 0,62 | 0,07 |
| | | kernel RBF ($\gamma=0,50$) | | 66,14 | 3,62 | 0,49 | 0,05 |
| | | - | | 72,46 | 3,98 | 0,59 | 0,06 |
| | | - | | 59,82 | 4,77 | 0,40 | 0,07 |
| Random Tree | | | 73,10 | 3,61 | 0,60 | 0,05 | |
| Random Forest | | 10 árvores | | 83,94 | 3,02 | 0,76 | 0,04 |
| | | 50 árvores | | 87,23 | 2,71 | 0,81 | 0,04 |
| | | 100 árvores | | 54,51 | 4,62 | 0,49 | 0,05 |
| ELM | | kernel sigmoidal | | 69,71 | 3,85 | 0,66 | 0,04 |
| | kernel dilatação | | 69,94 | 4,04 | 0,66 | 0,05 | |
| | kernel erosão | | 84,93 | 2,80 | 0,77 | 0,04 | |
| | Bayes Net | - | | | | | |

Tabela A5 – Desempenho dos classificadores utilizando DWIN para extração de atributos e imagens de Mamografia do Tecido III

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 88,26 | 3,39 | 0,82 | 0,05 |
| | MLP | 10 neurônios | 93,44 | 1,94 | 0,90 | 0,03 |
| | | 50 neurônios | 93,80 | 1,88 | 0,91 | 0,03 |
| | | 100 neurônios | 94,04 | 1,77 | 0,91 | 0,03 |
| | SVM | kernel linear | 98,05 | 1,07 | 0,97 | 0,02 |
| | | kernel poli (E=2) | 98,17 | 1,05 | 0,97 | 0,02 |
| | | kernel poli (E=3) | 98,14 | 1,08 | 0,97 | 0,02 |
| | | kernel poli (E=4) | 96,46 | 1,51 | 0,95 | 0,02 |
| | | kernel poli (E=5) | 96,68 | 1,45 | 0,95 | 0,02 |
| | J48 | kernel RBF ($\gamma=0,01$) | 91,72 | 2,22 | 0,88 | 0,03 |
| | | kernel RBF ($\gamma=0,25$) | 97,95 | 1,77 | 0,97 | 0,03 |
| | | kernel RBF ($\gamma=0,50$) | 77,50 | 4,57 | 0,66 | 0,07 |
| | | - | 73,73 | 3,33 | 0,61 | 0,05 |
| | | - | 61,48 | 4,28 | 0,42 | 0,06 |
| | Random Tree | 10 árvores | 74,82 | 3,51 | 0,62 | 0,05 |
| 50 árvores | | 85,16 | 2,65 | 0,78 | 0,04 | |
| 100 árvores | | 88,99 | 2,44 | 0,83 | 0,04 | |
| ELM | kernel sigmoidal | 62,49 | 4,69 | 0,58 | 0,05 | |
| | kernel dilatação | 75,56 | 3,57 | 0,72 | 0,04 | |
| | kernel erosão | 75,52 | 3,65 | 0,72 | 0,04 | |
| | Bayes Net | - | 75,10 | 3,67 | 0,63 | 0,06 |
| | Naive Bayes | - | 72,30 | 3,88 | 0,58 | 0,06 |

Tabela A5 – Desempenho dos classificadores utilizando DWIN para extração de atributos e imagens de Mamografia do Tecido III

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|------------------|------------------|------------------------------|--------------|-------|--------------|------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 43,33 | 12,31 | 0,15 | 0,18 |
| | | 50 neurônios | 36,80 | 7,73 | 0,05 | 0,12 |
| | SVM | 100 neurônios | 33,63 | 2,50 | 0,00 | 0,04 |
| | | kernel linear | 94,93 | 1,86 | 0,92 | 0,03 |
| | | kernel poli (E=2) | 95,60 | 1,66 | 0,93 | 0,02 |
| | | kernel poli (E=3) | 94,57 | 1,94 | 0,92 | 0,03 |
| | | kernel poli (E=4) | 92,28 | 2,69 | 0,88 | 0,04 |
| | | kernel poli (E=5) | 88,11 | 4,48 | 0,82 | 0,07 |
| | | kernel RBF ($\gamma=0,01$) | 82,30 | 3,27 | 0,73 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,25$) | 94,92 | 3,11 | 0,92 | 0,05 |
| | | kernel RBF ($\gamma=0,50$) | 68,89 | 4,31 | 0,53 | 0,06 |
| | | - | 61,23 | 3,90 | 0,42 | 0,06 |
| | Random Tree | - | 50,72 | 4,51 | 0,26 | 0,07 |
| | | 10 árvores | 64,15 | 4,11 | 0,46 | 0,06 |
| | Random Forest | 50 árvores | 79,40 | 3,43 | 0,69 | 0,05 |
| 100 árvores | | 84,11 | 3,17 | 0,76 | 0,05 | |
| kernel sigmoidal | | 62,41 | 4,06 | 0,58 | 0,05 | |
| ELM | kernel dilatação | 64,09 | 4,42 | 0,60 | 0,05 | |
| | kernel erosão | 64,06 | 4,46 | 0,60 | 0,05 | |
| Mínimo | Bayes Net | - | 86,81 | 3,64 | 0,80 | 0,04 |
| | Naive Bayes | - | 88,79 | 3,43 | 0,83 | 0,05 |
| | MLP | 10 neurônios | 93,05 | 1,96 | 0,90 | 0,03 |

Tabela A5 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia do Tecido III

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|----------------|------------------|------------------------------|--------------|-------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Mediana | SVM | 50 neurônios | 93,39 | 1,97 | 0,90 | 0,03 |
| | | 100 neurônios | 93,33 | 1,99 | 0,90 | 0,03 |
| | | kernel linear | 97,74 | 1,04 | 0,97 | 0,02 |
| | | kernel poli (E=2) | 98,02 | 1,01 | 0,97 | 0,02 |
| | | kernel poli (E=3) | 98,24 | 0,99 | 0,97 | 0,01 |
| | | kernel poli (E=4) | 96,99 | 1,42 | 0,95 | 0,02 |
| | | kernel poli (E=5) | 97,29 | 1,28 | 0,96 | 0,02 |
| | | kernel RBF ($\gamma=0,01$) | 91,69 | 2,31 | 0,88 | 0,03 |
| | | kernel RBF ($\gamma=0,25$) | 98,77 | 0,93 | 0,98 | 0,01 |
| | | kernel RBF ($\gamma=0,50$) | 66,67 | 3,64 | 0,50 | 0,05 |
| J48 | - | 71,72 | 3,44 | 0,58 | 0,05 | |
| Random Tree | - | 71,22 | 3,60 | 0,57 | 0,05 | |
| Random Forest | 10 árvores | 77,46 | 3,42 | 0,66 | 0,05 | |
| | 50 árvores | 86,43 | 2,83 | 0,80 | 0,04 | |
| | 100 árvores | 89,71 | 2,46 | 0,85 | 0,04 | |
| ELM | kernel sigmoidal | 74,50 | 3,91 | 0,71 | 0,04 | |
| | kernel dilatação | 79,67 | 3,61 | 0,77 | 0,04 | |
| | kernel erosão | 79,74 | 3,67 | 0,77 | 0,04 | |
| Bayes Net | - | 75,80 | 3,18 | 0,64 | 0,05 | |
| Naive Bayes | - | 81,82 | 4,96 | 0,73 | 0,07 | |
| MLP | 10 neurônios | 84,97 | 2,94 | 0,77 | 0,04 | |
| | 50 neurônios | 87,51 | 2,62 | 0,81 | 0,04 | |

Tabela A5 – Desempenho dos classificadores utilizando DWWN para extração de atributos e imagens de Mamografia do Tecido III

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 88,46 | 2,36 | 0,83 | 0,04 |
| | | kernel linear | 97,43 | 1,26 | 0,96 | 0,02 |
| | | kernel poli (E=2) | 97,99 | 1,10 | 0,97 | 0,02 |
| | | kernel poli (E=3) | 97,73 | 1,19 | 0,97 | 0,02 |
| | | kernel poli (E=4) | 97,26 | 1,33 | 0,96 | 0,02 |
| | kernel poli (E=5) | 97,34 | 1,36 | 0,96 | 0,02 | |
| | kernel RBF ($\gamma=0,01$) | 95,35 | 1,62 | 0,93 | 0,02 | |
| | kernel RBF ($\gamma=0,25$) | 37,83 | 6,45 | 0,07 | 0,10 | |
| | kernel RBF ($\gamma=0,50$) | 33,06 | 1,16 | 0,00 | 0,02 | |
| | J48 | - | 62,78 | 4,04 | 0,44 | 0,06 |
| Random Tree | - | 47,38 | 4,91 | 0,21 | 0,07 | |
| Random Forest | 10 árvores | 59,56 | 4,58 | 0,39 | 0,07 | |
| | 50 árvores | 77,41 | 3,48 | 0,66 | 0,05 | |
| | 100 árvores | 83,66 | 2,88 | 0,75 | 0,04 | |
| ELM | kernel sigmoidal | 48,35 | 4,46 | 0,42 | 0,05 | |
| | kernel dilatação | 57,96 | 4,32 | 0,53 | 0,05 | |
| | kernel erosão | 57,45 | 4,14 | 0,52 | 0,05 | |

Fonte: A Autora (2019).

Tabela A6 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia do Tecido IV

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|---------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 74,05 | 3,83 | 0,61 | 0,06 | |
| | Naive Bayes | - | 71,88 | 3,61 | 0,58 | 0,05 | |
| | MLP | 10 neurônios | | 50,58 | 12,80 | 0,26 | 0,19 |
| | | 50 neurônios | | 39,00 | 10,22 | 0,09 | 0,15 |
| | | 100 neurônios | | 34,02 | 3,79 | 0,01 | 0,06 |
| | SVM | kernel linear | | 93,07 | 2,16 | 0,90 | 0,03 |
| | | kernel poli (E=2) | | 93,53 | 2,10 | 0,90 | 0,03 |
| | | kernel poli (E=3) | | 88,61 | 2,75 | 0,83 | 0,04 |
| | | kernel poli (E=4) | | 88,22 | 2,58 | 0,82 | 0,04 |
| | | kernel poli (E=5) | | 88,54 | 2,77 | 0,83 | 0,04 |
| | | kernel RBF ($\gamma=0,01$) | | 82,11 | 3,24 | 0,73 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,25$) | | 85,16 | 4,50 | 0,78 | 0,07 |
| | | kernel RBF ($\gamma=0,50$) | | 65,85 | 3,70 | 0,49 | 0,06 |
| | | - | | 64,82 | 3,97 | 0,47 | 0,06 |
| | Random Tree | - | 52,12 | 4,59 | 0,28 | 0,07 | |
| Random Forest | 10 árvores | | 66,87 | 3,65 | 0,50 | 0,05 | |
| | 50 árvores | | 80,74 | 3,26 | 0,71 | 0,05 | |
| | 100 árvores | | 84,16 | 3,06 | 0,76 | 0,04 | |
| ELM | kernel sigmoidal | | 50,51 | 4,66 | 0,44 | 0,05 | |
| | kernel dilatação | | 66,95 | 3,99 | 0,63 | 0,05 | |
| | kernel erosão | | 66,88 | 4,09 | 0,63 | 0,04 | |
| Bayes Net | - | 65,04 | 3,74 | 0,48 | 0,06 | | |

Tabela A6 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia do Tecido IV

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 64,42 | 4,48 | 0,47 | 0,07 |
| | MLP | 10 neurônios | 86,23 | 2,70 | 0,79 | 0,04 |
| | | 50 neurônios | 86,80 | 2,69 | 0,80 | 0,04 |
| | | 100 neurônios | 87,04 | 2,72 | 0,81 | 0,04 |
| | SVM | kernel linear | 94,74 | 1,82 | 0,92 | 0,03 |
| | | kernel poli (E=2) | 95,11 | 1,79 | 0,93 | 0,03 |
| | | kernel poli (E=3) | 94,87 | 1,83 | 0,92 | 0,03 |
| | | kernel poli (E=4) | 91,20 | 2,41 | 0,87 | 0,04 |
| | | kernel poli (E=5) | 91,54 | 2,38 | 0,87 | 0,04 |
| | | kernel RBF ($\gamma=0,01$) | 79,07 | 3,36 | 0,69 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,25$) | 95,69 | 2,28 | 0,94 | 0,03 |
| | | kernel RBF ($\gamma=0,50$) | 71,96 | 5,74 | 0,58 | 0,08 |
| | | - | 56,15 | 4,27 | 0,34 | 0,06 |
| | Random Tree | - | 45,59 | 4,42 | 0,18 | 0,07 |
| | Random Forest | 10 árvores | 56,38 | 4,38 | 0,35 | 0,06 |
| 50 árvores | | 71,09 | 3,73 | 0,57 | 0,06 | |
| 100 árvores | | 76,39 | 3,42 | 0,65 | 0,05 | |
| ELM | kernel sigmoidal | 48,44 | 4,63 | 0,43 | 0,05 | |
| | kernel dilatação | 60,01 | 4,28 | 0,55 | 0,05 | |
| | kernel erosão | 59,53 | 4,05 | 0,55 | 0,05 | |
| Bayes Net | - | 56,16 | 4,11 | 0,34 | 0,06 | |
| Naive Bayes | - | 69,17 | 4,26 | 0,54 | 0,06 | |

Tabela A6 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia do Tecido IV

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|------------------|------------------|------------------------------|--------------|-------|--------------|------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 48,78 | 10,71 | 0,23 | 0,16 |
| | | 50 neurônios | 40,67 | 7,99 | 0,11 | 0,12 |
| | SVM | 100 neurônios | 33,92 | 1,94 | 0,01 | 0,03 |
| | | kernel linear | 93,95 | 1,99 | 0,91 | 0,03 |
| | | kernel poli (E=2) | 95,55 | 1,67 | 0,93 | 0,02 |
| | | kernel poli (E=3) | 94,72 | 1,88 | 0,92 | 0,03 |
| | | kernel poli (E=4) | 91,32 | 2,30 | 0,87 | 0,03 |
| | | kernel poli (E=5) | 84,62 | 4,31 | 0,77 | 0,06 |
| | | kernel RBF ($\gamma=0,01$) | 76,28 | 3,47 | 0,64 | 0,05 |
| | J48 | kernel RBF ($\gamma=0,25$) | 93,18 | 3,18 | 0,90 | 0,05 |
| | | kernel RBF ($\gamma=0,50$) | 70,99 | 5,12 | 0,56 | 0,08 |
| | | - | 55,76 | 4,11 | 0,34 | 0,06 |
| | Random Tree | - | 47,04 | 3,94 | 0,21 | 0,06 |
| | | 10 árvores | 57,59 | 4,54 | 0,36 | 0,07 |
| | Random Forest | 50 árvores | 74,13 | 3,83 | 0,61 | 0,06 |
| 100 árvores | | 79,42 | 3,29 | 0,69 | 0,05 | |
| kernel sigmoidal | | 55,83 | 4,62 | 0,50 | 0,05 | |
| ELM | kernel dilatação | 57,44 | 4,57 | 0,52 | 0,05 | |
| | kernel erosão | 57,93 | 4,46 | 0,53 | 0,05 | |
| Mínimo | Bayes Net | - | 53,36 | 3,39 | 0,30 | 0,05 |
| | Naive Bayes | - | 52,01 | 3,19 | 0,28 | 0,05 |
| | MLP | 10 neurônios | 85,59 | 2,74 | 0,78 | 0,04 |

Tabela A6 – Desempenho dos classificadores utilizando DWWN para extração de atributos e imagens de Mamografia do Tecido IV

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|---------|---------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Mediana | SVM | 50 neurônios | 86,02 | 2,64 | 0,79 | 0,04 | |
| | | 100 neurônios | 86,26 | 2,66 | 0,79 | 0,04 | |
| | | kernel linear | 93,46 | 2,12 | 0,90 | 0,03 | |
| | | kernel poli (E=2) | 93,65 | 2,07 | 0,90 | 0,03 | |
| | | kernel poli (E=3) | 93,17 | 2,27 | 0,90 | 0,03 | |
| | | kernel poli (E=4) | 86,69 | 2,80 | 0,80 | 0,04 | |
| | | kernel poli (E=5) | 85,46 | 3,21 | 0,78 | 0,05 | |
| | | kernel RBF ($\gamma=0,01$) | 62,11 | 3,20 | 0,43 | 0,05 | |
| | | kernel RBF ($\gamma=0,25$) | 87,01 | 4,42 | 0,81 | 0,07 | |
| | | kernel RBF ($\gamma=0,50$) | 60,18 | 5,92 | 0,40 | 0,09 | |
| ELM | J48 | - | 55,16 | 3,77 | 0,33 | 0,06 | |
| | | - | 48,63 | 4,29 | 0,23 | 0,06 | |
| | | 10 árvores | 57,21 | 3,80 | 0,36 | 0,06 | |
| | | 50 árvores | 63,70 | 3,72 | 0,46 | 0,06 | |
| | | 100 árvores | 65,47 | 3,58 | 0,48 | 0,05 | |
| | | kernel sigmoidal | 51,12 | 4,35 | 0,46 | 0,05 | |
| | | kernel dilatação | 61,51 | 4,46 | 0,57 | 0,05 | |
| | | kernel erosão | 62,57 | 4,12 | 0,58 | 0,05 | |
| | | Bayes Net | - | 59,18 | 3,86 | 0,39 | 0,06 |
| | | Naive Bayes | - | 64,24 | 9,15 | 0,46 | 0,14 |
| MLP | 10 neurônios | 82,62 | 3,12 | 0,74 | 0,05 | | |
| | | 50 neurônios | 84,34 | 2,87 | 0,77 | 0,04 | |

Tabela A6 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia do Tecido IV

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|-------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 84,81 | 2,86 | 0,77 | 0,04 |
| | | kernel linear | 95,92 | 1,58 | 0,94 | 0,02 |
| | | kernel poli (E=2) | 96,58 | 1,50 | 0,95 | 0,02 |
| | | kernel poli (E=3) | 95,86 | 2,14 | 0,94 | 0,03 |
| | | kernel poli (E=4) | 93,47 | 3,86 | 0,90 | 0,06 |
| | kernel poli (E=5) | 92,49 | 5,06 | 0,89 | 0,08 | |
| | kernel RBF ($\gamma=0,01$) | 93,50 | 2,04 | 0,90 | 0,03 | |
| | kernel RBF ($\gamma=0,25$) | 37,97 | 6,42 | 0,08 | 0,09 | |
| | kernel RBF ($\gamma=0,50$) | 33,02 | 0,57 | 0,00 | 0,01 | |
| | J48 | - | 47,60 | 4,27 | 0,21 | 0,06 |
| Random Tree | - | 42,53 | 4,20 | 0,14 | 0,06 | |
| Random Forest | 10 árvores | 50,95 | 4,27 | 0,26 | 0,06 | |
| | 50 árvores | 68,52 | 4,05 | 0,53 | 0,06 | |
| | 100 árvores | 76,14 | 3,82 | 0,64 | 0,06 | |
| ELM | kernel sigmoidal | 47,08 | 4,07 | 0,41 | 0,05 | |
| | kernel dilatação | 54,89 | 4,40 | 0,49 | 0,05 | |
| | kernel erosão | 55,20 | 4,55 | 0,49 | 0,05 | |

Fonte: A Autora (2019).

Tabela A7 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia com todos os tecidos e 3 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|-------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 72,41 | 1,92 | 0,59 | 0,03 | |
| | Naive Bayes | - | 61,50 | 1,97 | 0,42 | 0,03 | |
| | MLP | 10 neurônios | | 34,22 | 4,28 | 0,01 | 0,06 |
| | | 50 neurônios | | 33,40 | 1,16 | 0,00 | 0,02 |
| | | 100 neurônios | | 33,33 | 0,08 | 0,00 | 0,00 |
| | SVM | kernel linear | | 80,86 | 1,51 | 0,71 | 0,02 |
| | | kernel poli (E=2) | | 84,06 | 1,62 | 0,76 | 0,02 |
| | | kernel poli (E=3) | | 82,14 | 2,44 | 0,73 | 0,04 |
| | | kernel poli (E=4) | | 78,13 | 1,91 | 0,67 | 0,03 |
| | | kernel poli (E=5) | | 78,78 | 1,94 | 0,68 | 0,03 |
| | | kernel RBF ($\gamma=0,01$) | | 72,77 | 1,91 | 0,59 | 0,03 |
| | J48 | kernel RBF ($\gamma=0,25$) | | 90,91 | 1,45 | 0,86 | 0,02 |
| | | kernel RBF ($\gamma=0,50$) | | 63,09 | 2,25 | 0,45 | 0,03 |
| | | - | | 60,73 | 2,25 | 0,41 | 0,03 |
| | | - | | 52,00 | 2,42 | 0,28 | 0,04 |
| | Random Tree | 10 árvores | | 63,30 | 1,98 | 0,45 | 0,03 |
| 50 árvores | | | 72,90 | 1,80 | 0,59 | 0,03 | |
| 100 árvores | | | 76,33 | 1,70 | 0,64 | 0,02 | |
| ELM | kernel sigmoidal | | 49,12 | 2,50 | 0,43 | 0,03 | |
| | kernel dilatação | | 61,81 | 2,12 | 0,57 | 0,02 | |
| | kernel erosão | | 60,81 | 2,25 | 0,57 | 0,02 | |
| | Bayes Net | - | 68,47 | 1,56 | 0,53 | 0,02 | |

Tabela A7 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia com todos os tecidos e 3 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 63,09 | 1,31 | 0,45 | 0,02 |
| | MLP | 10 neurônios | 80,63 | 1,55 | 0,71 | 0,02 |
| | | 50 neurônios | 80,82 | 1,87 | 0,71 | 0,03 |
| | SVM | 100 neurônios | 79,70 | 3,29 | 0,70 | 0,05 |
| | | kernel linear | 81,98 | 1,51 | 0,73 | 0,02 |
| | | kernel poli (E=2) | 83,72 | 1,50 | 0,76 | 0,02 |
| | | kernel poli (E=3) | 84,40 | 1,61 | 0,77 | 0,02 |
| | | kernel poli (E=4) | 81,54 | 1,66 | 0,72 | 0,02 |
| | | kernel poli (E=5) | 82,02 | 1,56 | 0,73 | 0,02 |
| | J48 | kernel RBF ($\gamma=0,01$) | 78,71 | 1,49 | 0,68 | 0,02 |
| | | kernel RBF ($\gamma=0,25$) | 91,90 | 1,16 | 0,88 | 0,02 |
| | | kernel RBF ($\gamma=0,50$) | 81,27 | 6,18 | 0,72 | 0,09 |
| | | - | 61,91 | 2,03 | 0,43 | 0,03 |
| | Random Tree | - | 54,11 | 2,36 | 0,31 | 0,04 |
| | Random Forest | 10 árvores | 65,28 | 1,85 | 0,48 | 0,03 |
| | | 50 árvores | 72,76 | 1,77 | 0,59 | 0,03 |
| 100 árvores | | 75,25 | 1,67 | 0,63 | 0,02 | |
| ELM | kernel sigmoidal | 54,08 | 2,67 | 0,49 | 0,03 | |
| | kernel dilatação | 63,88 | 2,04 | 0,60 | 0,02 | |
| | kernel erosão | 63,88 | 2,12 | 0,60 | 0,02 | |
| Bayes Net | - | 75,81 | 2,04 | 0,64 | 0,03 | |
| Naive Bayes | - | 67,77 | 2,10 | 0,52 | 0,03 | |

Tabela A7 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia com todos os tecidos e 3 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------|------------------------------|--------------|-------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 61,50 | 9,56 | 0,42 | 0,14 |
| | | 50 neurônios | 52,66 | 11,54 | 0,29 | 0,17 |
| | SVM | 100 neurônios | 33,76 | 2,74 | 0,01 | 0,04 |
| | | kernel linear | 84,52 | 1,45 | 0,77 | 0,02 |
| | | kernel poli (E=2) | 94,02 | 1,05 | 0,91 | 0,02 |
| | | kernel poli (E=3) | 91,99 | 1,20 | 0,88 | 0,02 |
| | | kernel poli (E=4) | 88,59 | 1,40 | 0,83 | 0,02 |
| | | kernel poli (E=5) | 84,16 | 1,95 | 0,76 | 0,03 |
| | | kernel RBF ($\gamma=0,01$) | 80,29 | 1,51 | 0,70 | 0,02 |
| | J48 | kernel RBF ($\gamma=0,25$) | 91,88 | 1,27 | 0,88 | 0,02 |
| | | kernel RBF ($\gamma=0,50$) | 72,91 | 2,82 | 0,59 | 0,04 |
| | | - | 65,65 | 2,15 | 0,48 | 0,03 |
| | Random Tree | - | 53,35 | 2,43 | 0,30 | 0,04 |
| | | 10 árvores | 67,11 | 2,03 | 0,51 | 0,03 |
| | Random Forest | 50 árvores | 78,06 | 1,66 | 0,67 | 0,02 |
| 100 árvores | | 80,81 | 1,63 | 0,71 | 0,02 | |
| ELM | kernel sigmoidal | 65,68 | 2,10 | 0,61 | 0,02 | |
| | kernel dilatação | 66,90 | 2,12 | 0,62 | 0,02 | |
| | kernel erosão | 67,01 | 2,06 | 0,63 | 0,02 | |
| Bayes Net | - | 64,59 | 3,16 | 0,47 | 0,05 | |
| | Naive Bayes | 63,47 | 3,48 | 0,45 | 0,05 | |
| | MLP | 79,02 | 1,70 | 0,69 | 0,02 | |

Tabela A7 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia com todos os tecidos e 3 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Mediana | SVM | 50 neurônios | 77,77 | 2,43 | 0,67 | 0,04 |
| | | 100 neurônios | 75,55 | 3,45 | 0,63 | 0,05 |
| | | kernel linear | 81,20 | 1,48 | 0,72 | 0,02 |
| | | kernel poli (E=2) | 85,41 | 1,44 | 0,78 | 0,02 |
| | | kernel poli (E=3) | 86,41 | 1,47 | 0,80 | 0,02 |
| | | kernel poli (E=4) | 74,56 | 5,31 | 0,62 | 0,08 |
| | | kernel poli (E=5) | 72,84 | 5,97 | 0,59 | 0,09 |
| | | kernel RBF ($\gamma=0,01$) | 77,54 | 1,59 | 0,66 | 0,02 |
| | | kernel RBF ($\gamma=0,25$) | 87,58 | 1,33 | 0,81 | 0,02 |
| | | kernel RBF ($\gamma=0,50$) | 72,13 | 4,34 | 0,58 | 0,06 |
| J48 | - | 59,57 | 1,98 | 0,39 | 0,03 | |
| Random Tree | - | 58,12 | 2,08 | 0,37 | 0,03 | |
| Random Forest | 10 árvores | 65,28 | 1,73 | 0,48 | 0,02 | |
| | 50 árvores | 70,83 | 1,75 | 0,56 | 0,03 | |
| | 100 árvores | 73,77 | 1,63 | 0,61 | 0,02 | |
| ELM | kernel sigmoidal | 61,47 | 2,19 | 0,58 | 0,02 | |
| | kernel dilatação | 65,19 | 2,09 | 0,62 | 0,02 | |
| | kernel erosão | 65,21 | 1,94 | 0,62 | 0,02 | |
| Bayes Net | - | 63,07 | 1,87 | 0,45 | 0,03 | |
| Naive Bayes | - | 52,43 | 5,01 | 0,29 | 0,08 | |
| MLP | 10 neurônios | 72,84 | 1,94 | 0,59 | 0,03 | |
| | 50 neurônios | 81,57 | 1,58 | 0,72 | 0,02 | |

Tabela A7 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia com todos os tecidos e 3 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 82,79 | 1,57 | 0,74 | 0,02 |
| | | kernel linear | 75,84 | 1,87 | 0,64 | 0,03 |
| | | kernel poli (E=2) | 88,21 | 1,37 | 0,82 | 0,02 |
| | | kernel poli (E=3) | 87,55 | 1,84 | 0,81 | 0,03 |
| | | kernel poli (E=4) | 86,17 | 2,93 | 0,79 | 0,04 |
| | kernel poli (E=5) | 87,21 | 3,51 | 0,81 | 0,05 | |
| | kernel RBF ($\gamma=0,01$) | 85,81 | 1,36 | 0,79 | 0,02 | |
| | kernel RBF ($\gamma=0,25$) | 63,73 | 2,68 | 0,46 | 0,04 | |
| | kernel RBF ($\gamma=0,50$) | 34,70 | 4,04 | 0,02 | 0,06 | |
| | J48 | - | 46,60 | 2,15 | 0,20 | 0,03 |
| Random Tree | - | 39,94 | 2,20 | 0,10 | 0,03 | |
| Random Forest | 10 árvores | 47,09 | 2,03 | 0,21 | 0,03 | |
| | 50 árvores | 59,44 | 2,02 | 0,39 | 0,03 | |
| | 100 árvores | 66,05 | 2,02 | 0,49 | 0,03 | |
| ELM | kernel sigmoidal | 42,24 | 2,20 | 0,35 | 0,02 | |
| | kernel dilatação | 47,59 | 2,22 | 0,41 | 0,03 | |
| | kernel erosão | 47,26 | 2,21 | 0,41 | 0,02 | |

Fonte: A. Autora (2019).

Tabela A8 – Desempenho dos classificadores utilizando DWNN para extração de atributos e imagens de Mamografia com todos os tecidos e 12 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|-------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Máximo | Bayes Net | - | 47,68 | 2,01 | 0,43 | 0,02 | |
| | Naive Bayes | - | 56,84 | 1,99 | 0,53 | 0,02 | |
| | MLP | 10 neurônios | | 14,76 | 3,69 | 0,07 | 0,04 |
| | | 50 neurônios | | 9,49 | 2,25 | 0,01 | 0,02 |
| | | 100 neurônios | | 36,23 | 38,98 | 0,00 | 0,01 |
| | SVM | kernel linear | | 83,49 | 1,43 | 0,82 | 0,02 |
| | | kernel poli (E=2) | | 84,72 | 1,42 | 0,83 | 0,02 |
| | | kernel poli (E=3) | | 76,37 | 1,75 | 0,74 | 0,02 |
| | | kernel poli (E=4) | | 73,75 | 1,66 | 0,71 | 0,02 |
| | | kernel poli (E=5) | | 74,13 | 1,67 | 0,72 | 0,02 |
| | | kernel RBF ($\gamma=0,01$) | | 58,77 | 1,86 | 0,55 | 0,02 |
| | | kernel RBF ($\gamma=0,25$) | | 84,32 | 2,12 | 0,83 | 0,02 |
| | | kernel RBF ($\gamma=0,50$) | | 52,44 | 2,22 | 0,48 | 0,02 |
| | J48 | - | | 36,26 | 2,09 | 0,30 | 0,02 |
| | Random Tree | - | | 21,62 | 1,88 | 0,14 | 0,02 |
| | Random Forest | 10 árvores | | 32,49 | 1,93 | 0,26 | 0,02 |
| | | 50 árvores | | 53,04 | 2,10 | 0,49 | 0,02 |
| 100 árvores | | | 61,33 | 1,82 | 0,58 | 0,02 | |
| ELM | kernel sigmoidal | | 20,85 | 2,32 | 0,20 | 0,02 | |
| | kernel dilatação | | 38,56 | 2,10 | 0,38 | 0,02 | |
| | kernel erosão | | 37,82 | 2,18 | 0,37 | 0,02 | |
| Bayes Net | - | | 41,27 | 2,08 | 0,36 | 0,02 | |

Tabela A8 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia com todos os tecidos e 12 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|-------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Média | Naive Bayes | - | 34,07 | 3,45 | 0,28 | 0,04 |
| | MLP | 10 neurônios | 62,68 | 3,79 | 0,59 | 0,04 |
| | | 50 neurônios | 72,25 | 1,84 | 0,70 | 0,02 |
| | | 100 neurônios | 72,58 | 1,56 | 0,70 | 0,02 |
| | SVM | kernel linear | 90,50 | 1,17 | 0,90 | 0,01 |
| | | kernel poli (E=2) | 90,78 | 1,18 | 0,90 | 0,01 |
| | | kernel poli (E=3) | 90,37 | 1,21 | 0,89 | 0,01 |
| | | kernel poli (E=4) | 82,55 | 1,55 | 0,81 | 0,02 |
| | | kernel poli (E=5) | 83,06 | 1,50 | 0,82 | 0,02 |
| | | kernel RBF ($\gamma=0,01$) | 60,98 | 2,02 | 0,57 | 0,02 |
| | | kernel RBF ($\gamma=0,25$) | 95,03 | 0,97 | 0,95 | 0,01 |
| | | kernel RBF ($\gamma=0,50$) | 85,82 | 4,03 | 0,85 | 0,04 |
| | J48 | - | 22,03 | 1,70 | 0,15 | 0,02 |
| | Random Tree | - | 16,92 | 1,67 | 0,09 | 0,02 |
| | Random Forest | 10 árvores | 23,73 | 1,75 | 0,17 | 0,02 |
| | | 50 árvores | 40,53 | 2,01 | 0,35 | 0,02 |
| | | 100 árvores | 50,31 | 2,04 | 0,46 | 0,02 |
| ELM | kernel sigmoidal | 20,38 | 1,94 | 0,20 | 0,02 | |
| | kernel dilatação | 31,79 | 1,93 | 0,31 | 0,02 | |
| | kernel erosão | 31,76 | 1,96 | 0,31 | 0,02 | |
| Bayes Net | - | 35,70 | 1,88 | 0,30 | 0,02 | |
| Naive Bayes | - | 48,63 | 2,14 | 0,44 | 0,02 | |

Tabela A8 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia com todos os tecidos e 12 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|------------------|------------------|------------------------------|--------------|------|--------------|------|
| | | | Média | DP | Média | DP |
| Mínimo | MLP | 10 neurônios | 13,32 | 4,08 | 0,05 | 0,04 |
| | | 50 neurônios | 8,68 | 1,33 | 0,00 | 0,01 |
| | SVM | 100 neurônios | 8,53 | 0,86 | 0,00 | 0,01 |
| | | kernel linear | 85,98 | 1,39 | 0,85 | 0,01 |
| | | kernel poli (E=2) | 90,34 | 1,19 | 0,89 | 0,01 |
| | | kernel poli (E=3) | 87,20 | 1,35 | 0,86 | 0,01 |
| | | kernel poli (E=4) | 81,03 | 1,65 | 0,79 | 0,02 |
| | | kernel poli (E=5) | 73,65 | 2,00 | 0,71 | 0,02 |
| | | kernel RBF ($\gamma=0,01$) | 51,79 | 1,92 | 0,47 | 0,02 |
| | J48 | kernel RBF ($\gamma=0,25$) | 89,91 | 1,45 | 0,89 | 0,02 |
| | | kernel RBF ($\gamma=0,50$) | 61,08 | 3,11 | 0,58 | 0,03 |
| | | - | 34,99 | 2,10 | 0,29 | 0,02 |
| | Random Tree | - | 19,53 | 1,92 | 0,12 | 0,02 |
| | | 10 árvores | 28,37 | 1,92 | 0,22 | 0,02 |
| | Random Forest | 50 árvores | 48,66 | 2,16 | 0,44 | 0,02 |
| 100 árvores | | 58,26 | 1,89 | 0,54 | 0,02 | |
| kernel sigmoidal | | 31,22 | 2,01 | 0,31 | 0,02 | |
| ELM | kernel dilatação | 32,76 | 2,12 | 0,32 | 0,02 | |
| | kernel erosão | 32,83 | 2,08 | 0,32 | 0,02 | |
| Mínimo | Bayes Net | - | 49,36 | 1,81 | 0,45 | 0,02 |
| | Naive Bayes | - | 44,14 | 2,28 | 0,39 | 0,02 |
| | MLP | 10 neurônios | 63,80 | 2,97 | 0,61 | 0,03 |

Tabela A8 – Desempenho dos classificadores utilizando DWWN para extração de atributos e imagens de Mamografia com todos os tecidos e 12 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | | |
|---------------|------------------|------------------------------|--------------|-------|--------------|------|------|
| | | | Média | DP | Média | DP | |
| Mediana | SVM | 50 neurônios | 67,28 | 3,96 | 0,64 | 0,04 | |
| | | 100 neurônios | 71,67 | 6,18 | 0,69 | 0,07 | |
| | | kernel linear | 88,55 | 1,21 | 0,88 | 0,01 | |
| | | kernel poli (E=2) | 88,77 | 1,21 | 0,88 | 0,01 | |
| | | kernel poli (E=3) | 88,75 | 1,19 | 0,88 | 0,01 | |
| | | kernel poli (E=4) | 81,91 | 1,51 | 0,80 | 0,02 | |
| | | kernel poli (E=5) | 81,55 | 1,57 | 0,80 | 0,02 | |
| | | kernel RBF ($\gamma=0,01$) | 58,12 | 1,88 | 0,54 | 0,02 | |
| | | kernel RBF ($\gamma=0,25$) | 88,21 | 1,61 | 0,87 | 0,02 | |
| | | kernel RBF ($\gamma=0,50$) | 50,10 | 2,75 | 0,46 | 0,03 | |
| | | J48 | - | 27,31 | 1,82 | 0,21 | 0,02 |
| | | Random Tree | - | 22,65 | 1,68 | 0,16 | 0,02 |
| Random Forest | 10 árvores | 30,19 | 1,89 | 0,24 | 0,02 | | |
| | 50 árvores | 44,34 | 1,99 | 0,39 | 0,02 | | |
| | 100 árvores | 51,48 | 2,04 | 0,47 | 0,02 | | |
| ELM | kernel sigmoidal | 26,60 | 2,10 | 0,26 | 0,02 | | |
| | kernel dilatação | 35,48 | 2,19 | 0,35 | 0,02 | | |
| | kernel erosão | 35,44 | 2,19 | 0,35 | 0,02 | | |
| Bayes Net | - | 19,97 | 1,57 | 0,13 | 0,02 | | |
| Naive Bayes | - | 42,49 | 4,16 | 0,37 | 0,04 | | |
| MLP | 10 neurônios | 54,17 | 1,97 | 0,50 | 0,02 | | |
| | 50 neurônios | 69,29 | 1,72 | 0,67 | 0,02 | | |

Tabela A8 – Desempenho dos classificadores utilizando DWNIN para extração de atributos e imagens de Mamografia com todos os tecidos e 12 classes

| Função | Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|-------------------|--------------|-------------|--------------|-------------|
| | | | Média | DP | Média | DP |
| Moda | SVM | 100 neurônios | 70,62 | 1,62 | 0,68 | 0,02 |
| | | kernel linear | 92,53 | 1,04 | 0,92 | 0,01 |
| | | kernel poli (E=2) | 94,12 | 0,89 | 0,94 | 0,01 |
| | | kernel poli (E=3) | 92,99 | 1,04 | 0,92 | 0,01 |
| | | kernel poli (E=4) | 90,97 | 1,61 | 0,90 | 0,02 |
| | kernel poli (E=5) | 91,10 | 1,85 | 0,90 | 0,02 | |
| | kernel RBF ($\gamma=0,01$) | 86,08 | 1,34 | 0,85 | 0,01 | |
| | kernel RBF ($\gamma=0,25$) | 25,60 | 1,99 | 0,19 | 0,02 | |
| | kernel RBF ($\gamma=0,50$) | 9,17 | 0,54 | 0,01 | 0,01 | |
| | J48 | - | 17,60 | 1,66 | 0,10 | 0,02 |
| Random Tree | - | 14,30 | 1,45 | 0,07 | 0,02 | |
| Random Forest | 10 árvores | 18,98 | 1,71 | 0,12 | 0,02 | |
| | 50 árvores | 33,73 | 2,19 | 0,28 | 0,02 | |
| | 100 árvores | 43,67 | 2,25 | 0,39 | 0,02 | |
| ELM | kernel sigmoidal | 19,18 | 1,86 | 0,19 | 0,02 | |
| | kernel dilatação | 26,88 | 2,06 | 0,26 | 0,02 | |
| | kernel erosão | 26,66 | 2,08 | 0,26 | 0,02 | |

Fonte: A Autora (2019).

Tabela A9 – Desempenho dos classificadores utilizando Haralick e Zernike para extração de atributos e imagens de Mamografia do Tecido I

| Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|--------------|-------------|--------------|-------------|
| | | Média | DP | Média | DP |
| Bayes Net | - | 67,91 | 3,71 | 0,52 | 0,06 |
| Naive Bayes | - | 68,79 | 3,70 | 0,53 | 0,06 |
| MLP | 10 neurônios | 74,36 | 3,80 | 0,62 | 0,06 |
| | 50 neurônios | 72,74 | 3,95 | 0,59 | 0,06 |
| | 100 neurônios | 71,61 | 4,39 | 0,57 | 0,06 |
| SVM | kernel linear | 76,06 | 3,66 | 0,64 | 0,05 |
| | kernel polinomial (E=2) | 81,27 | 3,14 | 0,72 | 0,05 |
| | kernel polinomial (E=3) | 80,86 | 3,11 | 0,71 | 0,05 |
| | kernel polinomial (E=4) | 81,03 | 3,18 | 0,72 | 0,05 |
| | kernel polinomial (E=5) | 80,25 | 3,51 | 0,70 | 0,05 |
| | kernel RBF ($\gamma=0,01$) | 68,44 | 3,31 | 0,53 | 0,05 |
| | kernel RBF ($\gamma=0,25$) | 76,69 | 3,29 | 0,65 | 0,05 |
| | kernel RBF ($\gamma=0,50$) | 77,33 | 3,56 | 0,66 | 0,05 |
| J48 | - | 67,93 | 3,93 | 0,52 | 0,06 |
| Random Tree | - | 65,34 | 3,54 | 0,48 | 0,05 |
| Random Forest | 10 árvores | 72,62 | 3,24 | 0,59 | 0,05 |
| | 50 árvores | 75,00 | 3,31 | 0,62 | 0,05 |
| | 100 árvores | 75,40 | 3,37 | 0,63 | 0,05 |
| ELM | kernel sigmoidal | 77,02 | 3,43 | 0,74 | 0,04 |
| | kernel dilatação | 80,95 | 3,21 | 0,79 | 0,04 |
| | kernel erosão | 81,07 | 3,20 | 0,79 | 0,04 |

Fonte: A Autora (2019).

Tabela A10 – Desempenho dos classificadores utilizando Haralick e Zernike para extração de atributos e imagens de Mamografia de todos os tecidos e 3 classes

| Classificador | Parâmetro | Acurácia (%) | | Índice Kappa | |
|---------------|------------------------------|--------------|-------------|--------------|-------------|
| | | Média | DP | Média | DP |
| Bayes Net | - | 69,40 | 1,67 | 0,54 | 0,02 |
| Naive Bayes | - | 58,06 | 1,72 | 0,37 | 0,02 |
| MLP | 10 neurônios | 72,27 | 2,31 | 0,58 | 0,03 |
| | 50 neurônios | 70,33 | 2,93 | 0,55 | 0,04 |
| | 100 neurônios | 70,01 | 2,85 | 0,55 | 0,04 |
| SVM | kernel linear | 74,66 | 1,65 | 0,62 | 0,02 |
| | kernel polinomial (E=2) | 77,90 | 1,67 | 0,67 | 0,02 |
| | kernel polinomial (E=3) | 79,01 | 1,73 | 0,69 | 0,02 |
| | kernel polinomial (E=4) | 78,68 | 1,87 | 0,68 | 0,03 |
| | kernel polinomial (E=5) | 77,96 | 2,42 | 0,67 | 0,04 |
| | kernel RBF ($\gamma=0,01$) | 71,95 | 1,68 | 0,58 | 0,02 |
| | kernel RBF ($\gamma=0,25$) | 74,55 | 1,59 | 0,62 | 0,02 |
| | kernel RBF ($\gamma=0,50$) | 75,28 | 1,54 | 0,63 | 0,02 |
| J48 | - | 67,49 | 1,86 | 0,51 | 0,03 |
| Random Tree | - | 65,40 | 1,84 | 0,48 | 0,03 |
| Random Forest | 10 árvores | 71,70 | 1,66 | 0,58 | 0,02 |
| | 50 árvores | 73,90 | 1,65 | 0,61 | 0,02 |
| | 100 árvores | 74,29 | 1,62 | 0,61 | 0,02 |
| ELM | kernel sigmoidal | 75,02 | 1,88 | 0,72 | 0,02 |
| | kernel dilatação | 75,38 | 1,70 | 0,73 | 0,02 |
| | kernel erosão | 75,44 | 1,89 | 0,73 | 0,02 |

Fonte: A Autora (2019).