



**UNIVERSIDADE  
FEDERAL  
DE PERNAMBUCO**



Universidade Federal de Pernambuco  
Centro de Tecnologia e Geociências  
Departamento de Eletrônica e Sistemas



**Graduação em Engenharia Eletrônica**

**GABRIEL LUIZ LIMEIRA BARRETO**

**DETECÇÃO E CLASSIFICAÇÃO DE LESÕES  
MAMÁRIAS EM IMAGENS BIOMÉDICAS DE  
FORMA EXPLICÁVEL**

Recife

2024

GABRIEL LUIZ LIMEIRA BARRETO

**DETECÇÃO E CLASSIFICAÇÃO DE LESÕES  
MAMÁRIAS EM IMAGENS BIOMÉDICAS DE  
FORMA EXPLICÁVEL**

Trabalho de Conclusão apresentado ao Curso de Graduação em Engenharia Eletrônica, do Departamento de Eletrônica e Sistemas, da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Bacharel em Engenharia Eletrônica.

**Orientador(a):** Prof. SIDNEY MARLON LOPES DE LIMA, Dr.

Recife  
2024

Ficha de identificação da obra elaborada pelo autor,  
através do programa de geração automática do SIB/UFPE

Limeira Barreto, Gabriel Luiz.

Detecção e classificação de lesões mamárias em imagens biomédicas de forma explicável / Gabriel Luiz Limeira Barreto. - Recife, 2024.

96p : il., tab.

Orientador(a): Sidney Marlon Lopes de Lima

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Eletrônica - Bacharelado, 2024.

Inclui referências, apêndices.

1. Lesões mamárias. 2. Câncer de mama. 3. Imagens biomédicas. 4. Aprendizado de máquina. I. Lopes de Lima, Sidney Marlon. (Orientação). II. Título.

620 CDD (22.ed.)



Universidade Federal de Pernambuco - UFPE  
Centro de Tecnologia e Geociências - CTG  
Departamento de Eletrônica e Sistemas-DES



## ATA DE SESSÃO DE DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO

No dia 27 de março do ano de 2024, às 10:03 horas, reuniu-se a banca examinadora para a sessão pública de defesa do Trabalho de Conclusão de Curso em Engenharia Eletrônica da Universidade Federal de Pernambuco, intitulado: “**Deteção e Classificação de Lesões Mamárias em Imagens Biomédicas de Forma Explicável**”, elaborado pelo aluno **Gabriel Luiz Limeira Barreto**, matrícula 05158172447, composta pelos professores **Sidney Marlon Lopes de Lima** (Orientador), **Patrícia Silva Lessa** (membro titular), **Maíra Araújo de Santana** (membro titular) e **Wellington Pinheiro dos Santos** (membro titular). Após a exposição oral, o candidato foi arguido pelos componentes da banca que em seguida reuniram-se reservadamente e deliberaram pela aprovação do candidato, atribuindo-lhe a média nove vírgula sete (9,7), julgando-o apto à conclusão da disciplina de TCC. Para constar, redigi a presente ata aprovada por todos os presentes, que vai assinada por mim e pelos demais membros da banca.

Recife, 28 de março de 2024.

Documento assinado digitalmente  
**gov.br** SIDNEY MARLON LOPES DE LIMA  
Data: 28/03/2024 20:03:37-0300  
Verifique em <https://validar.iti.gov.br>

Nota:

9,5

Prof. **Sidney Marlon Lopes de Lima** (Orientador)  
Universidade Federal de Pernambuco - UFPE

Documento assinado digitalmente  
**gov.br** PATRICIA SILVA LESSA  
Data: 24/05/2024 10:31:44-0300  
Verifique em <https://validar.iti.gov.br>

Nota:

9,0

Profa. **Patrícia Silva Lessa** (membro titular)  
Universidade Federal de Pernambuco - UFPE

Documento assinado digitalmente  
**gov.br** MAIRA ARAUJO DE SANTANA  
Data: 01/04/2024 10:42:57-0300  
Verifique em <https://validar.iti.gov.br>

Nota:

10,0

Profa. **Maíra Araújo de Santana** (membro titular)  
Universidade Federal de Pernambuco – UFPE

Documento assinado digitalmente  
**gov.br** WELLINGTON PINHEIRO DOS SANTOS  
Data: 29/03/2024 16:21:47-0300  
Verifique em <https://validar.iti.gov.br>

Nota:

10,0

Profa. **Wellington Pinheiro dos Santos** (membro titular)  
Universidade Federal de Pernambuco – UFPE

Documento assinado digitalmente  
**gov.br** GUILHERME NUNES MELO  
Data: 01/04/2024 10:57:19-0300  
Verifique em <https://validar.iti.gov.br>

Guilherme Nunes Melo  
Coordenador do curso de Engenharia Eletrônica

Resumo do Trabalho de Conclusão de Curso apresentado ao Departamento de Eletrônica e Sistemas, como parte dos requisitos necessários para a obtenção do grau de Bacharel em Engenharia Eletrônica(Eng.)

## **DETECÇÃO E CLASSIFICAÇÃO DE LESÕES MAMÁRIAS EM IMAGENS BIOMÉDICAS DE FORMA EXPLICÁVEL**

GABRIEL LUIZ LIMEIRA BARRETO

O câncer de mama é principal causa de morte por câncer em mulheres adultas no Brasil. O diagnóstico tardio resulta em altas taxas de mortalidade, e pode levar a cirurgias mutilantes. O acesso limitado a exames de imagem contribui para diagnósticos em estágios avançados, ressaltando a importância da identificação precoce para aumentar as chances de cura e evitar procedimentos agressivos. Tecnologias de imagens médicas, incluindo avanços como o aprendizado profundo e extremo, são essenciais, melhorando a acurácia e eficiência diagnóstica. O estudo tem como objetivo aprimorar o diagnóstico do câncer de mama, especialmente em países onde os diagnósticos tardios são prevalentes. Foram utilizadas técnicas avançadas de inteligência artificial e aprendizado extremo em imagens termográficas, buscando desenvolver um sistema computacional que não apenas opere corretamente, mas também seja capaz de explicar seus diagnósticos de maneira compreensível para os profissionais de saúde. Os resultados indicam que a abordagem proposta apresenta eficiência na detecção e classificação de lesões mamárias em imagens termográficas, representando um avanço na área e potencialmente contribuindo para uma melhoria nas perspectivas de recuperação para pacientes com câncer de mama. A inteligência artificial autoral foi capaz de distinguir lesões malignas dos demais diagnósticos em 89,70% , em seu melhor cenário.

Palavras-chave: Lesões mamárias; Câncer de mama; Imagens biomédicas; Aprendizado de máquina.

Abstract of Course Conclusion Work, presented to Department of Electronic and Systems, as a partial fulfillment of the requirements for the degree of Bachelor of Electronic Engineering(Eng.)

## **DETECTION AND CLASSIFICATION OF BREAST LESIONS IN BIOMEDICAL IMAGES IN AN EXPLAINABLE WAY**

GABRIEL LUIZ LIMEIRA BARRETO

Breast cancer is a significant public health concern, being the leading cause of cancer death in adult women in Brazil. Late diagnosis results in high mortality rates and can lead to invasive surgery. Limited access to imaging tests contributes to diagnoses at alarming stages, highlighting the importance of early identification to increase the chances of cure and avoid aggressive procedures. Medical imaging technologies, including advances such as deep and extreme learning, are essential, improving diagnostic accuracy and efficiency. This study aims to improve breast cancer diagnosis, especially in countries where late diagnosis is prevalent. It applies advanced artificial intelligence and extreme learning techniques to thermographic images, seeking to develop a computer system that not only operates correctly, but is also capable of explaining its diagnoses in a way that is understandable to healthcare professionals. The results indicate that the proposed approach is efficient in detecting and classifying breast lesions in thermographic images, representing a significant advancement in the field and potentially contributing to improved recovery prospects for breast cancer patients. The author's artificial intelligence is able to distinguish malignant lesions from other diagnoses by 89.70% in its best scenario.

**Keywords:** Breast lesions; Breast cancer; Biomedical imaging; Machine learning.

# Lista de Ilustrações

1.1	Paciente pós-cirurgia de mastectomia. . . . .	14
1.2	Fotos dos métodos de reconstrução da mama . . . . .	14
1.3	Exame de mamografia. . . . .	17
1.4	Classificação da lesão quanto ao contorno de acordo com o BI-RADS	17
1.5	Segmentações manuais, feitas por radiologistas. . . . .	20
2.1	Magnitude das funções base dos momentos de Zernike em unidades de disco. . . . .	27
2.2	Descrição da forma da lesão através do momento de Zernike $Z_2^0$ . . . .	44
2.3	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. . . . .	44
4.1	Detalhamento do desenvolvimento. . . . .	50
4.2	Triagem da Base de Dados. . . . .	50
4.3	Remoção dos elementos externos a paciente . . . . .	55
4.4	Decomposição multinível . . . . .	57
4.5	Decomposição multinível reversa . . . . .	57
4.6	Campos receptivos, uma faixa. . . . .	58
4.7	Campos receptivos, duas faixas. . . . .	58
4.8	Campos receptivos mascaras. . . . .	64

4.9	Atuação de um campo receptivo autoral. . . . .	64
4.10	<i>QR code</i> para vídeo mostrando o funcionamento da IA autoral. . . . .	67
5.1	Grau de acurácia quanto a cistos. . . . .	70
5.2	Grau de acurácia quanto à lesões benignas. . . . .	70
5.3	Grau de acurácia quanto à lesões malignas. . . . .	71

# Lista de Tabelas

3.1	Resumo das principais técnicas inteligentes em termogramas de última geração. . . . .	45
5.1	A acurácia dos campos receptivos em função da classe. . . . .	71
5.2	Matriz de confusão dos campos receptivos em função da classe. . . . .	72
5.3	A acurácia dos campos receptivos em função da classe, com pesos ponderados. . . . .	77
5.4	Matriz de confusão dos campos receptivos em função da classe, com pesos ponderados. . . . .	77
A.1	Descrição de Características de Formas e de Texturas . . . . .	91

# Lista de Abreviações

bpp	.....	<i>Bits per Pixel</i> - Bits por Pixel
DFT	.....	<i>Discrete Fourier transform</i> - Transformada Discreta de Fourier
ACR	.....	<i>American College of Radiology</i> - Colégio Americano de Radiologia
DWNM	<i>Dense Wavelength-Division Multiplexing</i>	-Redes Neurais Profundas de Wavelet
ELM	.....	<i>Extreme Learning Machine</i>
IA	.....	Inteligência Artificial
IARC	.....	<i>International Agency for Research on Cancer</i>
INCA	.....	Instituto Nacional de Câncer José de Alencar Gomes da Silva

# Sumário

<b>1</b>	<b>Introdução</b>	<b>12</b>
1.1	Câncer de Mama . . . . .	12
1.2	Processamento Digital de Imagens Biomédicas . . . . .	13
1.3	Justificativa . . . . .	21
1.4	Objetivo Geral . . . . .	23
1.5	Objetivos Específicos . . . . .	23
1.6	Organização do TCC . . . . .	24
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>25</b>
2.1	Estudos Preliminares: Extração de Características em Imagens Biomédicas . . . . .	25
2.1.1	Momentos de Zernike . . . . .	25
2.2	Estudos Preliminares: Redes Neurais . . . . .	30
2.3	Aprendizado Profundo ( <i>Deep Learning</i> ) versus Redes Rasas . . . . .	33
2.4	Estudos Preliminares: Redes Neurais Extremas . . . . .	39
2.5	Termografia . . . . .	43
<b>3</b>	<b>Estado da Arte</b>	<b>45</b>
<b>4</b>	<b>Desenvolvimento</b>	<b>48</b>
4.1	Processamento das Imagens de Termografia . . . . .	48
4.1.1	Triagem da Base de Dados . . . . .	48
4.1.2	Escolha das Orientações e filtragem de elementos externos . . . . .	49
4.1.3	Filtragem por Faixa de Cor . . . . .	51

4.1.4	Decomposição Multinível da Imagem . . . . .	52
4.1.5	Harmonização dos campos receptivos (máscaras) . . . . .	56
4.2	Desenvolvimento de Inteligência Artificial Extrema Auto-Explicável .	56
4.3	Discussão . . . . .	63
<b>5</b>	<b>Resultados</b>	<b>68</b>
5.1	Reconhecimento de Padrão com Pesos Ponderados . . . . .	74
5.2	Discussão . . . . .	79
<b>6</b>	<b>Conclusão</b>	<b>80</b>
6.1	Dificuldades Encontradas . . . . .	81
6.2	Trabalhos Futuros . . . . .	82
	<b>Referências</b>	<b>84</b>
<b>A</b>	<b>Descrição de Características de Formas e de Texturas</b>	<b>90</b>

# Capítulo 1

## Introdução

### 1.1 Câncer de Mama

O câncer de mama é uma preocupação significativa de saúde pública, sendo a primeira causa de morte por câncer em mulheres adultas no Brasil (INCA,2023). Embora se manifeste sem distinção entre países com diferentes níveis de desenvolvimento social e econômico, houve um aumento nas taxas de incidência do câncer de mama em países economicamente desenvolvidos como os Estados Unidos, Canadá e Reino Unido a partir do século XXI, associado ao aumento da obesidade e do sedentarismo nestes países (INCA,2004) .

Apesar da alta incidência do câncer de mama nos países desenvolvidos, os índices de mortalidade são relativamente baixos quando comparados a países subdesenvolvidos. Apesar da incidência de câncer de mama na Europa em 2022 tenha sido maior que a da África (563.431 versus 198.831 novos casos/ano), a taxa de mortalidade por câncer de mama foi semelhante (14,7% versus 19,2%) (IARC, 2022). Este fato pode ser explicado pela dificuldade no acesso aos exames de imagem da mama na África, levando a um diagnóstico do câncer em estágios mais avançados, o que tem profundo impacto nos índices de sobrevivência de câncer de mama naquele continente. Esse fato pode gerar, além de mortes, uma cirurgia mutilante chamada tecnicamente de mastectomia. A Figura 1.1 exibe uma mulher mastectomizada.

Nas nações subdesenvolvidas e emergentes, as taxas de mortalidade podem ser

atribuídas ao diagnóstico tardio do câncer (INCA,2004). É relevante salientar que a manifestação inicial dos sintomas pode levar até uma década para se tornar discernível através da palpação. Estima-se que o período entre o início da lesão e o seu crescimento até que se torne palpável, atingindo cerca de 1 cm, seja de aproximadamente 10 anos (INCA,2011). Cerca de 12,7% dos óbitos por câncer em mulheres em 2022 foram devido ao câncer de mama (IARC,2022). A disponibilidade de procedimentos de imagem especializados para a mama, combinada a uma interpretação precisa, exerce uma função fundamental na identificação precoce da doença, promovendo, por conseguinte, maiores chances de recuperação da paciente.

Cirurgias como a mastectomia vêm sendo preteridas porque a perda do seio causa, em geral, um sério dano a auto-estima da mulher, podendo levá-la a um estado de depressão crônica. No entanto já existem métodos para recuperação do formato da mama, como a cirurgia de reconstrução através do TRAM (*Transverse Abdominal Myocutencous Flap* – Reto Transversal Abdominal) exemplificada nas figuras 1.2 (a), (b) e (c), além da prótese mamária vista na Figura 1.2 (d).

Apesar da reconstrução mamária, grande parte das pacientes apresenta estado depressivo. Uma das razões é que a sensibilidade de uma mama reconstruída não é a mesma que a de um tecido mamário original. Muitas mulheres, por exemplo, relatam sensações de formigamento na nova mama (INCA,2011). Enfatiza-se que uma paciente submetida à terapia conservadora de mama é capaz de viver, em média, tanto quanto as que realizam a cirurgia de mastectomia (INCA,2011). A identificação precoce do câncer, por meio de exames de imagem, desempenha um papel crucial na decisão pela terapia conservadora da mama (INCA,2004).

## 1.2 Processamento Digital de Imagens Biomédicas

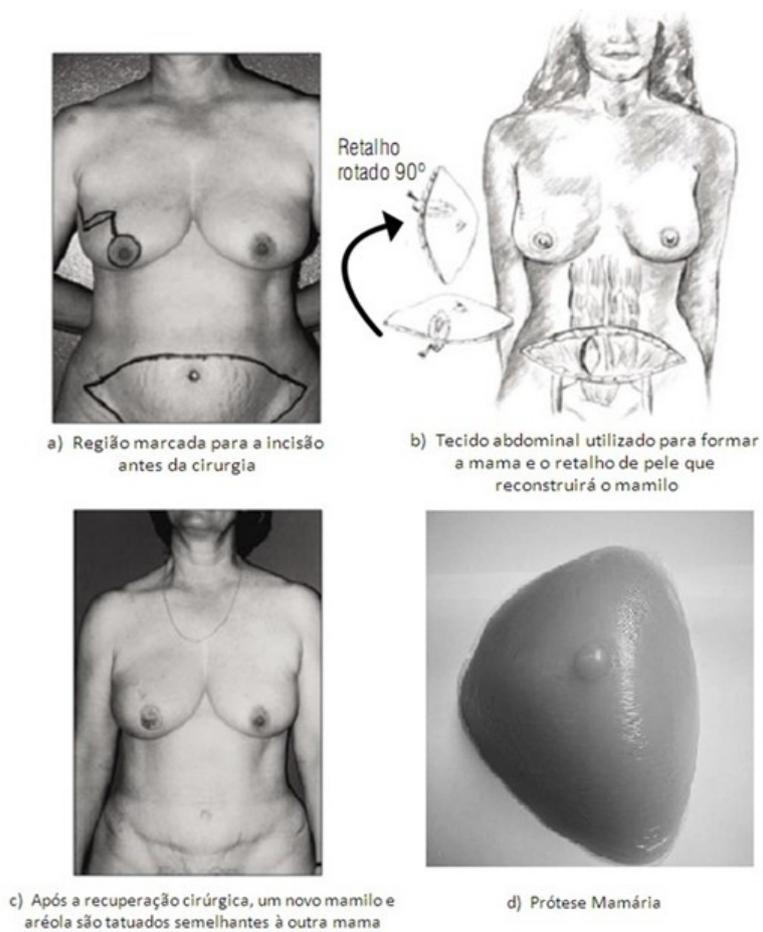
A utilização das tecnologias em imagens médicas tem demonstrado ser uma ferramenta de grande importância para a assistência em procedimentos cirúrgicos e simulações relacionadas, planejamento em tratamentos de radioterapia e acompanhamento da progressão de condições patológicas. A análise detalhada da forma

**Figura 1.1:** Paciente pós-cirurgia de mastectomia.



Fonte: (Manoel,2011)

**Figura 1.2:** Fotos dos métodos de reconstrução da mama



Fonte:(Quimioral,2018).

e das estruturas anatômicas possibilita ao cirurgião conceber uma abordagem altamente eficiente. No âmbito da radioterapia, as imagens médicas permitem a avaliação precisa do local e das doses de radiação entregues à lesão tumoral, minimizando o impacto nos tecidos saudáveis.

Apesar dos dispositivos de imagens proverem excepcional resolução da anatomia humana interna, a análise das patologias por meio de imagens é uma tarefa complexa. Primordialmente devido à extensa variação dos casos. Muitas instâncias encontradas na prática clínica não se alinham de maneira precisa com as imagens e descrições tradicionais (Juhl et al.,2014). Adicionalmente, surge uma notável dificuldade em interpretar a configuração da lesão em imagens afetadas por interferências, como as provenientes de equipamentos de ultrassom ou mamógrafos. Diversos estudos indicam que mais de 70% dos casos suspeitos de câncer de mama que vão para biópsia são lesões benignas (Leucht e Leucht,1996; Taylor et al.,2002; Gefen et al.,2003).

A mamografia continua a ser considerada a tecnologia mais eficaz para o diagnóstico do câncer de mama, devido à sua ampla utilização e interpretação das imagens obtidas. Neste exame a compressão entre duas placas de plástico especialmente projetadas para proporcionar uma compressão uniforme e controlada, garante uma imagem nítida e precisa. O principal objetivo é detectar lesões malignas incipientes na mama, e é indicado principalmente para avaliar achados mamários suspeitos em qualquer idade, em homens e mulheres (INCA,2023). A Figura 1.3 mostra a compressão mamária durante o exame de mamografia.

De acordo com as diretrizes do Ministério da Saúde, recomenda-se que mulheres com mais de 40 anos façam esse exame anualmente, enquanto aquelas com fatores de risco devem fazê-lo a cada 6 meses a partir dos 35 anos. Para mulheres entre 50 e 69 anos, a mamografia é recomendada a cada dois anos (INCA,2004).

Considerando a classificação do *American College of Radiology* (ACR) , é possível observar uma escala que divide as lesões em cinco grupos: regular, lobular, microlobular, irregular e espiculado, conforme ilustrado na Figura 1.4 (D'Orsi CJ,2013). Uma lesão classificada como regular frequentemente abrange achados benignos, como

cistos simples, nódulos de tecido adiposo ou calcificações benignas. As bordas dessas lesões tendem a ser suaves e bem definidas, com poucas irregularidades perceptíveis. Elas geralmente exibem uma aparência uniforme e simétrica nas imagens de mamografia (D'Orsi CJ,2013).

Lesões classificadas como lobular geralmente são caracterizadas por contornos curvilíneos e ondulados, essas lesões podem indicar condições como fibroadenomas, que são achados benignos comuns do tecido glandular da mama, ou hiperplasia ductal, uma proliferação benigna das células dos ductos mamários. A textura dessas lesões pode parecer mais densa e compacta em comparação a lesões regulares. Lesões microlobuladas apresentam pequenas protuberâncias ou saliências na borda e podem sugerir a presença de microcalcificações benignas, como aquelas associadas à fibrose ou adenose, ou lesões adenomatosas, que são massas benignas formadas por tecido glandular. Podem também mostrar áreas granulares ou granuladas nas imagens mamográficas (D'Orsi CJ,2013).

Lesões espiculadas exibem projeções ou linhas radiantes nas margens, o que pode ser um indicador de tumores malignos, como carcinomas invasivos de mama. A presença de espículos irregulares e afiados ao redor da lesão aumenta a suspeita de malignidade. Os espículos podem parecer irregulares e desiguais, com bordas serrilhadas ou ramificadas. O grupo de lesões irregulares é altamente diversificado e engloba uma ampla gama de achados, desde anomalias congênicas até tumores malignos avançados. Lesões irregulares podem apresentar formas e bordas altamente variáveis, tornando sua caracterização mais desafiadora. Elas podem parecer distorcidas, assimétricas ou sem um padrão definido nas imagens mamográficas (D'Orsi CJ,2013).

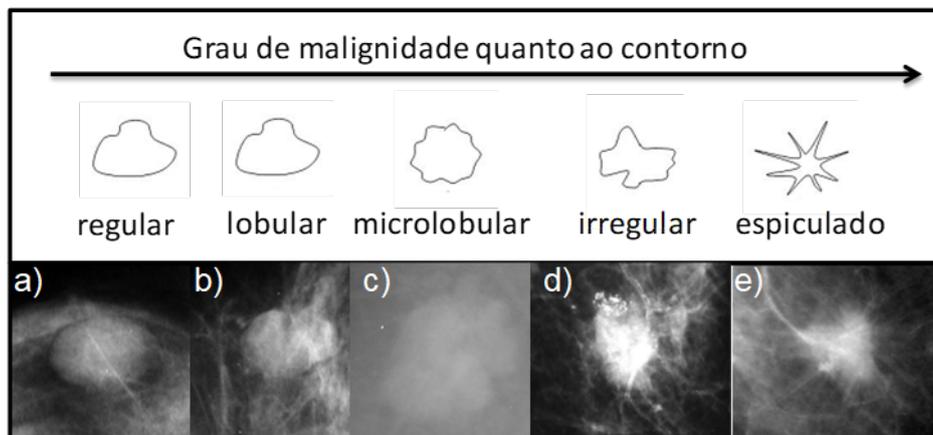
O ACR BI-RADS© também estabelece padrões em relação à densidade da lesão. Teoricamente, lesões malignas tendem a apresentar uma densidade superior à da mama, enquanto lesões com densidade inferior à mama são geralmente benignas. Como exemplo lesões com densidade de gordura são benignas na grande maioria dos casos (D'Orsi CJ,2013).

**Figura 1.3:** Exame de mamografia.



Fonte: (Martins,2013)

**Figura 1.4:** Classificação da lesão quanto ao contorno de acordo com o BI-RADS



Fonte : (de Lima et al.,2014)

Na era da tecnologia digital, surgiram diversas ferramentas de "segunda análise" com o intuito de aprimorar e complementar o processo de diagnóstico realizado por especialistas. Essas ferramentas, muitas vezes baseadas em algoritmos avançados e inteligência artificial, oferecem uma segunda camada de análise e interpretação de dados, proporcionando aos profissionais de saúde uma valiosa assistência na tomada de decisões diagnósticas. Ao fornecer *insights* adicionais, comparativos ou complementares aos resultados obtidos pelos especialistas, essas ferramentas digitais não apenas ampliam o arsenal de recursos disponíveis, mas também podem aumentar a acurácia e confiança dos diagnósticos, resultando em melhores prognósticos e tratamentos para os pacientes.

A identificação e classificação de lesões mamárias por meio de exame de imagens podem ser grandemente influenciadas pela etapa de extração de características. Entre as abordagens comumente utilizadas, a segmentação desempenha um papel proeminente. Essa técnica visa separar a lesão dos demais componentes presentes na imagem, possibilitando uma análise mais detalhada e acurada. Como resultado, métricas estatísticas e geométricas são derivadas da área ocupada pela anomalia celular e comparadas com a sua região de vizinhança. Para alcançar esse objetivo, as técnicas de segmentação, adotadas em abordagens avançadas, geralmente operam na área correspondente ao plano da própria imagem, onde os métodos são baseados na manipulação direta dos *pixels*. Ferramentas de "segunda análise" resultam em uma melhor caracterização das lesões mamárias e, por conseguinte, em uma avaliação mais acurada dos resultados da mamografia.

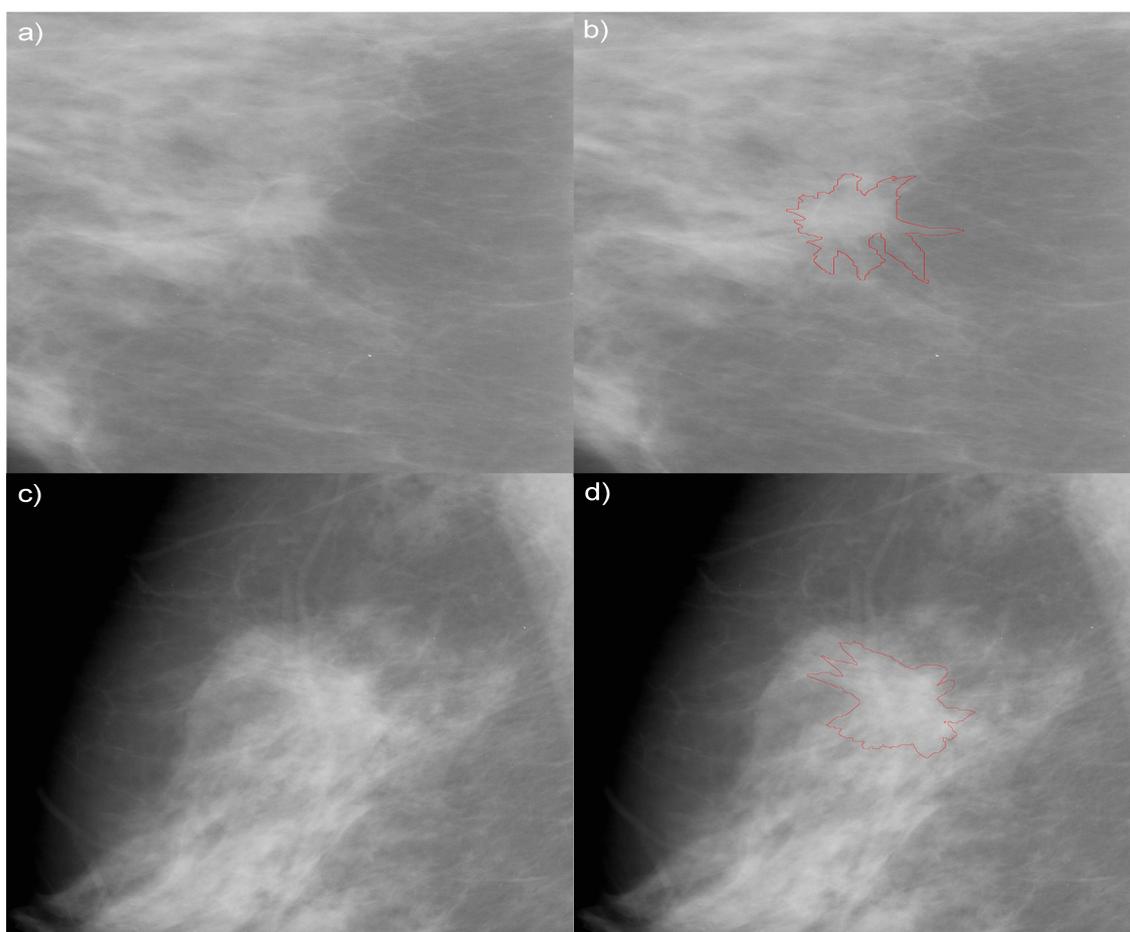
A Figura 1.5 apresenta as segmentações manuais feitas por radiologistas, oriundas do banco de dados DDSM (Digital Database for Screening Mammography) (Heath e Bowyer, 2000), amplamente utilizado pelo estado da arte. Adicionalmente aos dados fornecidos pelo DDSM, o estado da arte frequentemente emprega radiologistas privados para segmentar a mamografia original e/ou aprimorar a performance das técnicas de processamento de imagem propostas durante suas execuções. Observe-se que os traçados livres, apresentados na Figura 1.5b e Figura 1.5d, realizados

pelos especialistas, geraram padrões que não correspondiam aos gradientes das imagens em estudo. Especialistas também elaboraram espículos que não foram devidamente delineadas nas imagens originais, como ilustrado na Figura 1.5a e Figura 1.5c. Uma lesão com características espiculadas exibe linhas radiantes que se originam de seu interior e se estendem em direção às suas extremidades, frequentemente indicando características malignas (D’Orsi CJ,2013). Portanto fica claro que essas segmentações manuais não apenas isolaram as lesões, mas também realizaram implicitamente a etapa subsequente de classificação de nódulos benignos e malignos. Com base nessas abordagens, torna-se evidente que a parte mais desafiadora do processo de interpretação e execução é atribuída aos especialistas que desempenham a detecção e classificação da lesão. Enquanto isso, a técnica computacional se beneficia do trabalho meticuloso do especialista tanto na fase de aplicação quanto na fase de teste.

Adicionalmente à segmentação, os avanços atuais no campo exigem que os especialistas façam ajustes no desempenho da técnica proposta de processamento de imagens. Esse tipo de envolvimento humano pode ser bastante demorado. A complexidade surge porque imagens de mamografia geralmente exibem diferentes graus de intensidade em escala de cinza. Assim, um único limiar raramente é suficiente para separar com precisão toda a fronteira da lesão. Adicionar ou remover manualmente partes desses segmentos possibilita interferência na etapa de extração de características. Conseqüentemente, ao derivar medidas estatísticas e geométricas entre a área identificada manualmente que retrata a deturpação tecidual e a sua região adjacente, o resultado pode divergir consideravelmente do conteúdo da imagem, impactando a classificação da lesão. O estado atual da arte não oferece detalhes sobre como seus especialistas corrigem o desempenho das técnicas de processamento de imagens.

É inferido que um *software* de edição de imagens e/ou um *software* personalizado podem ser essenciais para estabelecer limiares locais ou ajustar parâmetros de processamento para cada micro-região da lesão. Ademais, profissionais da área de saúde

**Figura 1.5:** Segmentações manuais, feitas por radiologistas.



Fonte: Adaptada da base de dados DDSM (*Digital Database for Screening Mammography* - Banco de Dados Digital de Mamogramas Digitalizados.) (Heath e Bowyer,2000).

podem enfrentar desafios ao manusear *softwares* de edição de imagens, especialmente durante turnos movimentados quando os radiologistas podem ter dificuldade em realizar tarefas que consomem muito tempo. Porém abordagens computacionais mais avançadas estão sendo utilizadas para ampliar o alcance das aplicações de detecção de lesões em mamografias. Conforme as tendências mais recentes, as metodologias de aprendizado profundo (*deep learning*) demonstram desempenho superior, em comparação às técnicas inteligentes rasas, em termos de taxas de classificação e detecção de lesões mamárias. Por aprendizado profundo e raso, denotam-se técnicas de grande e baixa complexidade computacional, respectivamente. Aprendizado Profundo pode manipular diretamente a imagem original e não está limitada a trabalhar apenas com os resultados da segmentação manual, como é comum atualmente na realização do exame.

### 1.3 Justificativa

Apesar de representar o estado da arte na engenharia biomédica, o *Deep Learning* apresenta várias limitações. As técnicas de aprendizado profundo exigem computadores com alta capacidade de processamento e armazenamento, além de que o treinamento pode levar meses, ou até anos, mesmo em um computador (servidor) potente.

As limitações de modelos de redes profundas podem ser supridas por técnicas de inteligência artificial baseadas em aprendizado extremo. As redes neurais extremas representam uma classe de modelos de inteligência computacional que, por meio de seu aprendizado, viabilizam a construção de mapeamentos não-lineares dos dados. São técnicas de baixíssima complexidade computacional, mas são capazes de dispor excelentes acurácias (Azevedo et al., 2015a; Azevedo et al., 2015b; Azevedo da Silva et al., 2021; de Lima et al., 2016; Pereira, 2020). Como vantagem, é viável explicar o funcionamento do aprendizado extremo a um humano devido a baixa quantidade de cálculos.

A pesquisa visa empregar o aprendizado extremo na identificação e classificação

de lesões de mama em imagens termográficas. A utilização da termografia na detecção de câncer de mama tem mais de dez anos de aplicação. (Pereira et al.,2021; Araújo et al.,2014; Borchardt et al.,2013; Ekici e Jawzal,2020; Karim et al.,2018; Morales-Cervantes et al.,2018). Este método busca um emprego de técnicas com mínimos efeitos colaterais, tanto à paciente quanto ao profissional especialista. A termografia da mama, por não envolver radiação ionizante, pode ser considerada uma alternativa promissora para avaliações funcionais e metabólicas da mama, complementando técnicas de imagem convencionais. Ao contrário da mamografia, a termografia é adequada para mulheres de todas as idades, incluindo grávidas, lactantes, aquelas com implantes mamários, com densidade mamária elevada ou com fibrocistos, bem como para mulheres submetidas à terapia de reposição hormonal. Pode ser realizado tanto a mulheres na pré-menopausa quanto na pós-menopausa (Pereira et al.,2021). O exame envolve a captura de uma imagem que reflete a distribuição de temperatura na superfície da pele da paciente, especificamente a temperatura superficial da mama.

Pórem não basta que a técnica computacional opere corretamente em imagens termográficas. Os mecanismos de engenharia biomédica devem ser aptos a explicar seu próprio funcionamento. Faz-se necessário que o profissional conhecedor esteja completamente convencido de que a ferramenta de “segunda opinião” é útil. Através da computação auto-explicável, a ferramenta de inteligência artificial se torna capaz de explicar seus diagnósticos de forma criativa e inteligente.

Com base nos postulados de Alan Turing, uma máquina capaz de se auto explicar a um humano é o que mais se aproximaria de uma máquina com capacidade de pensar (Turing,1950). Nota-se as limitações dos mecanismos de detecção de doenças anatômicas comparativamente aos postulados de Alan Turing. Os diagnósticos providos por ferramentas computacionais, convencionalmente, ocorrem através de rótulos sem maiores esclarecimentos. Simplesmente, a ferramenta computacional de aprendizado profundo identifica se a paciente tem câncer mas não oferece nenhum suporte ao profissional especialista para embasar sua decisão.

Ao considerar as imagens de termografia, a meta é estabelecer descrições e padrões aos moldes do trabalho realizado pela *American College of Radiology* no BI-RADS. A motivação decorre do fato de que as lesões encontradas na termografia ainda não apresentam um padrão técnico auto descritivo. A inteligência artificial auto-explicável se torna uma boa alternativa, pois, durante sua etapa de treinamento, consegue analisar milhares de arquivos e extrair características deles. Após o aprendizado, a inteligência artificial auto-explicável seria capaz de estabelecer padrões acerca do formato, densidade e área circundante da lesão. Dessa maneira, a técnica ganharia subsídios para embasar a sua decisão a um humano. A ferramenta proveria recursos de modo que o profissional qualificado pudesse se defender perante o conselho de classe, por exemplo.

## 1.4 Objetivo Geral

Propor um método inteligente para detecção e classificação de lesões mamárias em imagens biomédicas, com o uso de redes neurais extremas na termografia. O método autoral será projetado com a capacidade intrínseca de explicar seu próprio funcionamento de maneira compreensível para os seres humanos. Isso viabilizará a persuasão de profissionais especializados, demonstrando que a ferramenta pode oferecer uma "segunda opinião" acurada e valiosa. A técnica biomédica inteligente autoral desenvolverá a habilidade de apresentar seus diagnósticos de forma criativa e inteligível.

## 1.5 Objetivos Específicos

- Estudo de técnicas e algoritmos de processamento digital em imagens biomédicas.
- Adequar as técnicas computacionais escolhidas em relação aos problemas encontrados na prática clínica, distintos das imagens e descrições clássicas.
- Definição do ambiente experimental.

- Análise dos resultados.
- Validação do modelo de sistema autoral inteligente pela comunidade acadêmica.

## 1.6 Organização do TCC

O conteúdo deste TCC está dividido em seis capítulos. As referências encontram-se nas páginas finais. A seguir, um resumo dos capítulos seguintes do TCC.

**Capítulo 2:** apresenta a fundamentação teórica relacionada ao processamento de imagem biomédica..

**Capítulo 3:** aborda o estado da arte quanto ao emprego de inteligência artificial no ramo da engenharia biomédica, em específico, em termogramas e mamogramas.

**Capítulo 4:** é detalhada a metodologia que envolve a implementação de uma inteligência artificial auto-explicável.

**Capítulo 5:** os resultados obtidos são discutidos. São apresentados distintos cenários tanto em relação à acurácia quanto em relação á precisão da IA auto-explicável autoral.

**Capítulo 6:** apresenta as conclusões gerais e as perspectivas para o futuro.

## Capítulo 2

# FUNDAMENTAÇÃO TEÓRICA

### 2.1 Estudos Preliminares: Extração de Características em Imagens Biomédicas

A obtenção de características em imagens biomédicas apresenta desafios significativos. Encontrar um extrator apropriado para uma aplicação biomédica não garante o sucesso desse mesmo extrator em outra aplicação. A variabilidade da anatomia e do metabolismo humano é extensa. Portanto técnicas computacionais podem sofrer problemas operacionais quando utilizadas em imagens biomédicas. Em face do exposto, os momentos de Zernike correspondem a extractores de características capazes de obter resultados promissores em uma variedade de cenários biomédicos, tais como em mamograma e termograma (Pereira,2020; Lima et al.,2014; Lima et al.,2020; de Lima et al.,2016; Azevedo et al.,2015a; Azevedo et al.,2015b; Azevedo da Silva et al.,2021).

#### 2.1.1 Momentos de Zernike

Os Momentos de Zernike são uma série de coeficientes matemáticos que descrevem a forma de uma superfície bidimensional, como uma lente, uma lâmina ou uma abertura circular. Esses momentos são frequentemente usados em óptica, visão computacional e outras áreas relacionadas, para caracterizar a aberração e a qualidade

da imagem de sistemas ópticos. Eles são nomeados em homenagem ao matemático holandês Frits Zernike, que desenvolveu essa técnica em 1934 e foi premiado com o Prêmio Nobel de Física em 1953 por seu trabalho (Niu e Tian, 2022).

Os momentos de Zernike são calculados a partir das coordenadas polares de uma superfície em torno de um ponto central de referência. Cada momento de Zernike corresponde a um polinômio de Zernike específico e representa uma característica particular do formato da superfície. Eles podem ser usados para quantificar as irregularidades ou desvios de uma superfície em comparação a uma forma ideal, como uma superfície esférica perfeita (Niu e Tian, 2022).

A forma geral do polinômio de Zernike é:

$$Z_{n,m}(r, \theta) = R_{n,m}(r) \cdot e^{im\theta} \quad (2.1)$$

Onde:

- $n$  é um número não negativo inteiro que controla o número de lóbulos radiais no polinômio.
- $m$  é um número inteiro que determina o número de vezes que a função enrola ao redor do centro.
- $r$  é a distância radial da coordenada polar ao centro.
- $\theta$  é o ângulo polar.

Os polinômios de Radial Zernike,  $R_n^m(r)$ , são obtidos por uma relação recursiva baseada nos polinômios de Legendre. Podendo ser expressos como:

$$R_n^m(r)(r) = \sum_{k=0}^{\frac{n-m}{2}} \frac{(-1)^k \cdot (n-k)!}{k! \cdot \left(\frac{n+m}{2} - k\right)! \cdot \left(\frac{n-m}{2} - k\right)!} \cdot r^{n-2k} \quad (2.2)$$

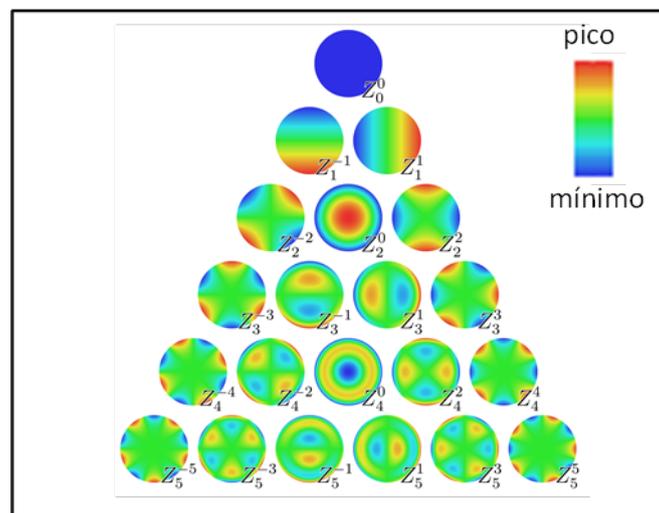
Algumas situações onde os momentos de Zernike podem ser utilizados são::

- Caracterização de distorções ópticas: são usados para quantificar e descrever as distorções em sistemas ópticos, permitindo que se compreenda melhor como

as imperfeições afetam a qualidade da imagem formada.

- Astronomia Adaptativa: na correção em tempo real das distorções atmosféricas em observações astronômicas, melhorando a clareza das imagens.
- Na análise de imagens microscópicas, permitindo a detecção e caracterização de distorções ópticas em sistemas microscópicos.
- Usados para avaliar as distorções visuais do olho humano, auxiliando na prescrição de lentes corretivas personalizadas.

**Figura 2.1:** Magnitude das funções base dos momentos de Zernike em unidades de disco.



Fonte: (Tahmasbi et al.,2011).

Os Momentos de Zernike desempenham um papel crucial na óptica moderna, permitindo uma análise quantitativa das distorções ópticas e proporcionando uma base matemática sólida para a correção dessas distorções. Sua ampla gama de aplicações em diversos campos da óptica os torna uma ferramenta essencial para a captura de imagens de ótima qualidade e acurácia.

Os momentos de Zernike têm sido amplamente utilizados para extrair características quanto a forma da lesão de mama (Azevedo et al., 2015a; Azevedo et al., 2015b; Azevedo da Silva et al., 2021). As redes neurais rasas dependem dos extratores de características dos dados brutos. Por ser de baixa complexidade computa-

cional, as redes rasas carecem de mecanismos visando converter os dados brutos em repositório de aprendizado estatístico. Ao empregar redes neurais rasas, a responsabilidade de detectar e categorizar lesões mamárias usando mamogramas é fortemente influenciada pela fase de extração de características (de Lima et al.,2016).

Os momentos de Zernike conseguem detalhar a lesão avaliada conforme os critérios estabelecidos pela *American College of Radiology*. A configuração da lesão é essencial para a definição do nível de malignidade das lesões mamárias (D’Orsi CJ,2013). A análise da morfologia da lesão é crucial para selecionar o tratamento mais adequado. A lesão é classificada em cinco grupos: regular, lobular, microlobular, irregular e espiculado, observados na Figura 1.4. Os polinômios de Zernike constituem uma base radial. A função de base de Zernike é aplicada à lesão potencial identificada na imagem biomédica. As magnitudes do gradiente, correspondem à intensidade onde a região de relevância abrangida (sobrepota) ao disco será ponderada.

Considerando o momento de Zernike  $Z_2^0$ . Na situação em questão, a porção da imagem sob investigação que coincide com a área central do disco será examinada com a mais alta intensidade, devido ao seu pico de escala, visualizado na Figura 2.1 pela cor vermelha. Intensidade máxima é equivalente à média dos valores dos pixels na região, sem observar nenhum decréscimo.

Conforme a análise se expande para a área circundante da imagem, projetada sobre o disco, a intensidade do gradiente diminui gradualmente até alcançar a área correspondente à borda do disco na imagem, indicada na Figura 2.1 pela cor azul. Então nos arredores da área da imagem que se sobrepõe ao disco, ocorre uma diminuição graduada na média ponderada dos valores dos pixels. O momento de Zernike  $Z_2^0$  é adequado em relação a lesões regulares, de forma arredondada, como os cistos.

A Figura 2.2 ilustra um exemplo de um achado anatômico sendo descrito pelo momento de Zernike  $Z_0^0$ . Em contrapartida, o momento de Zernike  $Z_5^5$  consegue descrever lesões espiculadas. As referidas lesões apresentam linhas irradiando para fora do centro em direção à borda, conforme visto na Figura 2.1. O *American College of Radiology* estabelece que lesões espiculadas indicam uma probabilidade mais ele-

vada de malignidade com característica de ser um câncer maligno. (D'Orsi CJ,2013). Enfatiza-se que muitos casos observados na prática clínica não se enquadram com precisão nos padrões e descrições clássicas das imagens (de Lima et al.,2016).

Uma lesão espiculada, embora improvável, pode ser benigna. Cabe ao profissional especialista solicitar a biópsia da lesão suspeita. Os momentos de Zernike desempenham uma função crucial na análise de lesões em mamografias, no entanto, suas aplicações apresentam algumas limitações. Os momentos de Zernike são sensíveis a diversos fatores como:

- O ângulo de inclinação da descrição anatômica. Dada a natureza heterogênea das lesões mamárias, essas podem estar posicionadas em diferentes ângulos em relação aos discos dos momentos de Zernike. Isso compromete a eficiência na descrição da lesão de mama.
- A extensão da área abrangida pela região de interesse na imagem inicial. A Figura 2.2 destaca que os momentos de Zernike não incorporam mecanismos para desconsiderar regiões que não englobam zonas de interesse do mamograma. Essa limitação pode impactar negativamente a caracterização da lesão mamária.
- A forma não-geométrica do achado anatômico também influencia a eficácia dos momentos de Zernike. Uma forma não-geométrica refere-se a uma configuração ou padrão que não é precisamente definido ou descrito por meio de elementos geométricos tradicionais, como linhas, pontos ou figuras regulares. Como demonstrado na Figura 1.4, lesões mamárias podem apresentar formatos irregulares e assimétricos. Nestes casos, os momentos de Zernike não se mostram como descritores ideais das particularidades das lesões, revelando uma inadequação quando confrontados com essa falta de padrão geométrico.

Diante dessas considerações, é evidente que, embora os momentos de Zernike sejam valiosos para a descrição de lesões em mamogramas, a sensibilidade a condições como inclinação, área e forma não-geométrica limita sua eficácia em certas cir-

cunstâncias. Essas limitações instigam a busca por abordagens complementares e mais robustas na análise de mamografias para garantir resultados acurados e confiáveis.

## 2.2 Estudos Preliminares: Redes Neurais

Os momentos de Zernike têm sido amplamente utilizados para extrair características quanto a lesões mamárias. Após a etapa de extração de características, há o reconhecimento de padrão da amostra. Cabe ao algoritmo inteligente estimar um diagnóstico através da comparação entre as características da imagem biomédica auditada e àquelas captadas durante a sua etapa de treinamento.

Os algoritmos de inteligência artificial se especializam em tarefas específicas ao explorar um vasto repositório de dados estatísticos. A habilidade de generalização é adquirida ao analisar cuidadosamente uma seleção representativa de amostras reservadas exclusivamente para a fase de treinamento. No contexto do reconhecimento de padrões, a escolha criteriosa das amostras que compõem o conjunto de dados estatísticos desempenha um papel crucial na eficácia do sistema. Essas amostras são atribuídas a classes ou rótulos por um profissional especializado ou por meio de um processo automatizado conduzido por um instrumento devidamente configurado. A qualidade e a representatividade dessas atribuições têm um impacto direto na capacidade da inteligência artificial de identificar e classificar corretamente padrões em novos conjuntos de dados. Portanto uma abordagem cuidadosa e criteriosa na seleção e rotulagem das amostras é fundamental para o sucesso da aplicação de técnicas de inteligência artificial no reconhecimento de padrões e em outras tarefas similares.

A partir de um conjunto de amostras designado como conjunto de treinamento, é viável formular uma conjectura acerca das diversas categorias associadas à aplicação em foco. Tradicionalmente, essas amostras são submetidas a uma análise de suas características, as quais são derivadas de descritores que capturam informações de frequência, textura e forma. Após o processo de treinamento, é obrigação da inte-

ligência artificial inferir a classe de uma nova amostra. Esse processo ocorre através da comparação entre os atributos observados em tempo real e os padrões armazenados no banco de dados estatístico. Durante a etapa de treinamento, atributos aparentemente conflitantes podem coexistir simultaneamente no modelo de inteligência artificial, sendo ajustados e refinados para melhorar seu desempenho.

Os avanços em inteligência artificial são profundamente influenciados pela biologia, destacando-se as redes neurais artificiais como uma das técnicas mais bem-sucedidas. Inspiradas no funcionamento do cérebro humano, essas redes são modeladas para simular o processamento de informações biológicas. Da mesma forma, o desenvolvimento inicial do cérebro humano, especialmente nos primeiros dois anos de vida, é marcado por uma rápida expansão das capacidades perceptivas, cognitivas e motoras, refletindo um período crítico de aprendizado e desenvolvimento (Papalia et al.,2008).

Esse paradigma de aprendizado serve como um estímulo para inúmeros pesquisadores que buscam reproduzir o intrincado funcionamento do cérebro humano, especialmente o processo de aprendizado por experiência. As redes neurais artificiais são uma manifestação desse esforço, baseando-se na compreensão biológica do cérebro humano (Shalev-Shwartz e Shai Ben-David,2014). Contudo, diferentemente de um cérebro biológico, onde qualquer neurônio pode estabelecer conexões com qualquer outro neurônio dentro de uma determinada distância física, as redes neurais artificiais são estruturadas em camadas discretas, com conexões específicas e direcionamento definido para a propagação de dados (Shalev-Shwartz e Shai Ben-David,2014).

Quanto à classificação (categorização), a camada de saída polariza as informações oriundas da camada entre as classes da aplicação (ex.: paciente com câncer, paciente sem câncer). As redes de neurais conseguem detectar câncer de mama em imagens de mamografia com acurácia média acima de 98% (Azevedo et al.,2015a; Azevedo et al.,2015b; Azevedo da Silva et al.,2021; de Lima et al.,2016; Pereira,2020).

Quando utilizamos redes neurais, é crucial reunir uma quantidade estatística-

mente significativa de amostras tanto da classe alvo quanto da classe oposta. Durante a etapa de treinamento, as conexões entre os neurônios são ajustadas de modo que as características observadas na aplicação alvo sejam representadas por uma série de pesos ajustados.

Por meio do ajuste das conexões entre os neurônios, a rede neural é capaz de reconhecer amostras pré-rotuladas pelo profissional especialista, distinguindo entre classe e contra-classe. O período de aprendizado é crucial pelo fato de que características (neurônios de entrada) aparentemente improváveis podem ocorrer. Por exemplo, torna-se possível detectar um câncer minúsculo no mamograma. Um profissional especialista apoiado por uma máquina de aprendizado estatístico, a exemplo de uma rede neural, consegue prover diagnósticos mais ajustados.

Após o treinamento, a rede neural avalia se a amostra suspeita exhibe características mais semelhantes à classe alvo em comparação com a(s) contra-classe(s). Em linguagem técnica, a rede neural reconhece que uma amostra inédita de mamografia indica câncer porque exhibe um padrão mais distinto do que uma mamografia sem câncer previamente analisada. De forma mais simples, imagine uma rede neural treinada para reconhecer frutas em imagens. Se apresentarmos uma imagem de uma maçã, ela será identificada corretamente como uma maçã, porque não possui características semelhantes às da classe laranja.

Redes neurais clássicas, também conhecidas como redes neurais rasas, adquirem essa denominação devido à sua baixa complexidade computacional. Por essa razão, são capazes de operar eficientemente em qualquer computador convencional, tanto durante o treinamento (aprendizado) quanto durante o uso.

O processo de treinamento é finalizado em apenas alguns minutos devido à reduzida quantidade de neurônios artificiais envolvidos. Como resultado, a adaptação das conexões entre esses neurônios ocorre rapidamente, mesmo quando inicializadas de forma aleatória. Durante a fase de aplicação, o intervalo de resposta da rede rasa se dá em segundos. Desde que bem parametrizada, as redes neurais rasas tem potencial de obter acurácias estatisticamente equivalentes à qualquer modelo de rede

profunda (*Deep Learning*) (Ba e Caruana,2014; Lima et al.,2023).

## 2.3 Aprendizado Profundo (*Deep Learning*) versus Redes Rasas

O emprego de métodos computacionais em imagens biomédicas tem se destacado como uma estratégia essencial para aprimorar a credibilidade do diagnóstico, reduzindo a susceptibilidade a erros. Essas abordagens visam à identificação automática de estruturas anatômicas relacionadas à anatomia humana. Inspiradas no entendimento biológico do cérebro humano, as redes neurais profundas emergem como protagonistas nesse cenário. Essas redes, frequentemente utilizadas no reconhecimento de padrões em imagens digitais, têm alcançado notável acurácia, impulsionando sua aplicação em diversas tarefas.

A nomenclatura "aprendizado profundo" é atribuída a essas redes devido à sua elevada complexidade computacional. Em contraste, as redes neurais clássicas, também conhecidas como redes neurais rasas, destacam-se pela sua menor complexidade computacional. O *Deep Learning*, como uma alternativa robusta, solidificou sua posição como estado-da-arte para suprir as deficiências das redes rasas.

Técnicas de *Deep Learning* (Aprendizado Profundo), embora avançadas, impõem desafios significativos devido à complexidade computacional. A implementação efetiva desses modelos requer a utilização de supercomputadores com considerável capacidade de processamento e armazenamento. Esses recursos robustos são indispensáveis para a automação da análise de todo o espaço de exploração, visando identificar as configurações ótimas. De tal maneira, a busca por acurácia no diagnóstico utilizando abordagens computacionais não apenas exige tecnologia avançada, mas também há a necessidade de explorar eficientemente o vasto espectro de parâmetros passíveis de ajuste oferecido por essas técnicas.

O desenvolvimento de uma inteligência artificial especializada em detectar lesões mamárias em termogramas demanda uma abordagem estratégica na escolha das

técnicas de aprendizado. Nesse contexto, a aplicação de *Deep Learning* pode não ser a solução mais viável. Para ilustrar essa questão, podemos considerar o exemplo da rede neural profunda *Inception-V3*, que apresenta uma complexidade significativa, contendo aproximadamente 23,6 milhões de parâmetros ajustáveis (Chollet,2017).

Essa magnitude de parâmetros demanda um conjunto de dados igualmente vasto para o treinamento eficaz do modelo. É relevante notar que a *Inception-V3* é tradicionalmente treinada utilizando a vasta base de dados *ImageNet*. Essa base de dados, composta por uma variedade de imagens genéricas, engloba objetos como teclados, mouses, lápis, além de uma diversidade de animais, tais como leões, elefantes e girafas, entre outros. No total, a *ImageNet* contém cerca de 1,3 milhões de imagens de treinamento. Portanto há uma quantidade de dados de treinamento, em ordem de milhões, compatível com os milhões de parâmetros ajustáveis.

Em termos simples, podemos dizer que o *Deep Learning* é ávido por dados - uma grande quantidade de parâmetros ajustáveis precisa ser alimentada com uma quantidade proporcionalmente extensa de dados de entrada. No contexto da engenharia biomédica, é essencial considerar que a disponibilidade de termogramas pode ser limitada. É importante ressaltar que o *Deep Learning* demonstra seu potencial máximo em situações onde há disponibilidade de um grande volume de dados de treinamento, permitindo que a estrutura da rede adquira a capacidade de generalização necessária para lidar com uma variedade de cenários. No entanto, quando confrontado com um conjunto de dados limitado, composto por centenas, e não milhões de amostras, a capacidade de generalização da *Deep Learning* pode ser comprometida.

No caso de um inteligência artificial visando a detecção de lesões mamárias em termogramas, o uso do *Deep Learning* pode parecer uma escolha tentadora à primeira vista, mas há alguns pontos que faz-se necessário considerar. Imagine que o *Deep Learning* é como um carro de corrida potente, que precisa de uma estrada ampla e sem obstáculos para mostrar todo o seu potencial. No entanto, se a estrada estiver cheia de curvas fechadas e obstáculos, esse carro pode não ser a melhor opção. No contexto da engenharia biomédica, o *Deep Learning* é como esse carro de corrida.

Ele precisa de uma grande quantidade de dados para funcionar corretamente - é como se ele tivesse uma fome insaciável por dados. Se não tivermos uma quantidade enorme de dados disponíveis, o desempenho do *Deep Learning* pode ser prejudicado.

Dessa forma, enquanto o *Deep Learning* se mostra altamente eficaz em contextos onde há abundância de dados, para uma inteligência artificial especializada em termogramas, outras abordagens, como técnicas de aprendizado supervisionado com conjuntos de dados menores e mais focalizados, podem ser mais adequadas e eficientes. Essas abordagens podem oferecer uma alternativa mais prática e eficaz para o desenvolvimento de soluções adaptadas a lesões mamárias em termogramas.

Uma desvantagem das redes profundas é o longo tempo de capacitação. Ajustar os pesos sinápticos com métodos iterativos baseados gradientes descendentes é computacionalmente custoso. Até se fosse utilizado um computador com altíssima velocidade de processamento e grande capacidade de memória, um treinamento básico de rede profunda poderia demorar meses ou até anos. Os métodos de redes neurais da mais nova geração demandam a utilização de grandes *datacenters*, em vez de dependerem de computadores de mesa convencionais. Esses métodos podem depender de milhões de parâmetros ajustáveis (treináveis).

Além disso, as redes profundas apresentam limitada capacidade de processamento paralelo devido à natureza sequencial das camadas convolucionais. Cada camada é processada somente com a conclusão do processamento da camada anterior. Em uma situação em que todas as camadas fossem executadas simultaneamente, o paradigma produtor-consumidor ocorreria. A camada consumidora poderia tentar ler dados enquanto a camada produtora ainda os estivesse processando, resultando na possível obtenção de dados prematuros e incorretos (Patterson,2013).

Existem modelos de redes profundas que buscam realizar o processamento de dados de forma simultânea, porém estão em estágio inicial de desenvolvimento e ainda não demonstram altos níveis de acurácia em diversas aplicações (Pinheiro et al.,Pinheiro et al.; dos Santos et al.,2019). A rede profunda proposta por dos Santos et al.,2019 é paralelizável e possui 30 mil filtros convolucionais ativados si-

multaneamente. Quando executada em um servidor potente, a rede desenvolvida demonstra um tempo de capacitação comparável ao das redes rasas. Desde que esteja em um servidor esse modelo mostra um período de treinamento não discrepante das redes rasas.

A mencionada rede profunda demonstra excelentes resultados quando aplicada ao processamento de imagem, especialmente no reconhecimento óptico de caracteres (dos Santos et al.,2019). Entretanto a rede profunda paralelizável proposta por SANTOS *et al.* em 2019 não alcançou sucesso ao ser aplicada ao reconhecimento de padrões de *malware*<sup>1</sup>. Seus resultados foram estatisticamente inferiores tanto às redes rasas quanto às redes profundas baseadas em camadas sequenciais (grafos em cascata)<sup>2</sup> (Pinheiro et al.,2022). Portanto não há evidências de que uma rede profunda paralelizável obtenha bons resultados no campo da engenharia biomédica.

Uma técnica computacional baseada em aprendizado profundo poderá sofrer da maldição da dimensionalidade. Tal como, a rede profunda *Inception-V3* tem 23,6 milhões de parâmetros ajustáveis (Chollet,2017). É impraticável inferir quais desses milhões de parâmetros ajustáveis são capazes de otimizar a acurácia da rede. Também se torna inviável tentar formular uma explicação de como uma rede profunda funciona. Por exemplo, não há como saber quais parâmetros controlam o limite de decisão em função das classes alvos da aplicação. Em síntese, algumas redes profundas funcionam como caixas pretas sem muito controle e/ou explicação de suas ações.

A transferência de aprendizado emerge como uma estratégia engenhosa para contornar as extensas demandas temporais associadas ao treinamento de redes profundas. Ao invés de iniciar com uma tela em branco, sem conhecimento ou habilidade, a abordagem da transferência de aprendizado introduz um ponto de partida mais avançado. A rede profunda, anteriormente treinada para tarefas diversas, é reaproveitada, funcionando como uma espécie de precursora, trazendo consigo uma riqueza

---

<sup>1</sup>*malware*: malicioso + *software*.

<sup>2</sup>Exemplo de arquitetura de rede neural profunda. Disponível em:<https://se.mathworks.com/help/deeplearning/gs/create-simple-image-classification-network-using-deep-network-designer.html>, Acessado em março. 2024

de informações acumuladas durante suas iterações anteriores.

Esse conhecimento prévio, embora destinado a uma aplicação distinta, é adaptado e refinado para a nova tarefa em questão, permitindo uma rápida aceleração do processo de treinamento. Dessa forma, o período necessário para treinar uma rede profunda, que outrora demandaria meses de dedicação, é drasticamente reduzido para apenas alguns dias, graças à herança do aprendizado prévio. Essa transição inteligente impulsiona a eficiência do treinamento, maximizando o potencial da rede e abrindo caminho para uma adaptação mais rápida e precisa às demandas específicas de cada aplicação. No entanto, mesmo com essa redução significativa neste tempo de treinamento, ainda existe certa hesitação em adotar redes profundas, especialmente no campo da engenharia biomédica.

Isso ocorre devido à necessidade de convencer gestores e profissionais da área sobre a eficácia e confiança desses modelos. Conseguir o apoio de gestores para aguardar dias até que a inteligência artificial conclua seu aprendizado e esteja pronta para fazer previsões não é uma tarefa simples. Portanto, apesar dos benefícios da transferência de aprendizado, é importante abordar e superar essas preocupações para promover uma adoção mais ampla e eficaz dessas tecnologias.

Uma nova abordagem de transferência de aprendizado surgiu para enfrentar a necessidade de redução do tempo deste treinamento em redes profundas. Essa alternativa emergente tem se destacado como o estado-da-arte em computação inteligente e encontra aplicação em diversas áreas. Por meio dessa estratégia adicional, um estudo científico pode adquirir o prestígio associado ao *Deep Learning*, ao mesmo tempo em que pode ser concluído em um tempo comparável ao das redes menos complexas.

Uma rede profunda, previamente treinada para propósitos distintos, mantém seus parâmetros treináveis inalterados. Funcionando como uma combinação entre um extrator de características e um minerador de dados, a rede profunda recebe os dados do problema específico e produz seus próprios neurônios de saída, os quais foram treinados para outra aplicação. Por exemplo, a rede profunda *Xception* foi

desenvolvida com especialização na identificação de objetos e organismos em imagens.

A *Inception-V3* é capaz de categorizar imagens em 1.000 classes distintas, incluindo objetos como teclado, mouse, lápis, bem como diversos animais, como leão, elefante e girafa, entre outros. Indiscutivelmente, a *Inception-V3* contribui significativamente para a reputação das redes profundas, demonstrando uma notável capacidade de generalização. Na transferência de aprendizado, os 1.000 neurônios de saída da *Inception-V3*, previamente treinada para outras finalidades, podem ser utilizados como entrada para um classificador raso. Dessa forma, o classificador raso é capaz de reconhecer padrões na aplicação alvo, mesmo sem ter acesso direto aos seus dados.

Em âmbitos jurídicos e biomédicos, a transferência de aprendizado, entre rede profunda e rasa, tem grande resistência em sua adoção. A inteligência artificial recomendaria a condenação de um réu porque seu processo judicial "casaria" padrão; 1,1% com uma imagem de um leão, 1,5% com uma foto de teclado dentre as 1.000 categorias de saída em uma rede profunda de última geração. A rede profunda passa a fazer as vezes de um arbitrário minerador de dados e extrator de características. Também não seria trivial convencer um profissional de saúde que o paciente contém câncer porque a imagem "casaria" padrão 1,3% com uma imagem de girafa dentre as 1.000 categorias de saída de uma rede profunda.

Existem várias conjecturas e teorias que tentam explicar de forma racional as altas taxas de acurácia alcançadas ao aplicar a transferência de aprendizado entre redes profundas e rasas. Uma possibilidade é que durante os extensos períodos de treinamento das redes profundas, sejam desenvolvidos descritores de frequência, textura e forma de excelente qualidade. Esses descritores estariam integrados nos milhões de parâmetros passíveis de ajuste de uma arquitetura de rede profunda. Torna-se praticamente impossível identificar computacionalmente quais são esses descritores espontâneos e onde exatamente estão localizados dentro da estrutura da rede profunda. No entanto é plausível que esses descritores espontâneos de frequência,

textura e forma possam ser úteis em diversas aplicações, independentemente do propósito para o qual a rede profunda foi originalmente treinada.

## 2.4 Estudos Preliminares: Redes Neurais Extremas

Em grande parte das redes neurais, como a MLP (Perceptron de Múltiplas Camadas) (Xiang et al.,2005), é vital compreender os elementos da rede para atingir o melhor rendimento na resolução do problema. Uma preocupação frequente nesse tipo de estrutura é evitar ficar preso em mínimos locais , sendo crucial incorporar mecanismos de controle para escapar dessas situações. Outra característica típica desse tipo de rede é o extenso tempo de treinamento necessário para capacitar a rede a realizar classificações de forma acurada.

Por outro lado, na Máquina de Aprendizado Extremo (ELM) não é necessária incrementar a quantidade de parâmetros ajustáveis, como a taxa de aprendizado comumente utilizada em redes neurais baseadas em retropropagação. Essa técnica se destaca pela sua velocidade de treinamento e predição de dados em comparação com outros classificadores.

A ELM é uma rede de camada oculta única e não iterativa. Seu modelo de aprendizagem se baseia na pseudoinversa de Moore-Penrose, onde os pesos entre a camada oculta e a camada de saída são calculados (Huang et al.,2000; Huang et al.,2012). O treino da ELM é realizado em lote, onde todos os dados são apresentados à rede antes que os pesos referentes às conexões sinápticas entre os neurônios da camada oculta e de saída sejam ajustados. O processo de aprendizagem da ELM consiste em uma única iteração. Em resumo, não há retropropagação de dados, portanto, a ELM não enfrenta problemas de *overfitting* (ajuste excessivo).

Devido à sua única iteração, o treino da ELM é mais rápido se comparado com as metodologias tradicionais. Além disso, por não utilizar o método de gradiente descendente e não requerer a definição de um parâmetro de taxa de aprendizagem, a

rede ELM simplifica o processo de treinamento, eliminando a necessidade de ajustes manuais e tornando-o menos suscetível a erros de configuração.

Matematicamente, na rede ELM os atributos de entrada  $x_{it}$  correspondem ao conjunto  $\{x_{it} \in \mathbb{R}; i = 1, \dots, n; t = 1, \dots, v\}$ . Há  $n$  características extraídas da aplicação e  $v$  vetores de dados de treinamento. A camada escondida  $h_j$ , constituída por  $m$  neurônios, é representada pelo conjunto  $\{h_j \in \mathbb{R}; j \in \mathbb{N}^*; j = 1, \dots, m\}$ . O treinamento da ELM é ágil devido à sua estrutura simplificada, exigindo poucas etapas. Inicialmente, os pesos de entrada  $w_{ji}$  e *bias*  $b_{jt}$  são escolhidos aleatoriamente. Dada uma função de ativação  $f : \mathbb{R} \rightarrow \mathbb{R}$ , A aprendizagem ocorre em três etapas distintas:

- Geração aleatória do peso  $w_{ji}$ , correspondendo aos pesos entre a entrada e as camadas ocultas, e *bias*  $b_{jt}$ .
- Cálculo da matriz  $H$ , que equivale à saída dos neurônios na camada oculta.
- Cálculo da matriz dos pesos de saída  $\beta = H \dagger Y$ , onde  $H \dagger$  é a matriz inversa generalizada de Moore-Penrose da matriz  $H$ , e  $Y$  corresponde à matriz de saídas desejadas, onde  $\{Y_{tc} \in \mathbb{R}; t = 1, \dots, v; c = 1, \dots, \zeta\}$ .  $\zeta$  é a quantidade de classes (ex. benigno, cisto).

O conceito de uma matriz inversa está relacionado à matriz de identidade  $I$ . Uma matriz quadrada original  $H$  multiplicada por seu inverso  $H^{-1}$  é igual à matriz de identidade  $H.H^{-1} = I$ . Entretanto nos casos de uma matriz de dimensão retangular, portanto não quadrada, é gerada uma matriz aproximadamente inversa  $\cong H^{-1}$ . Essa matriz aproximadamente inversa é responsável por polarizar os pesos sinápticos entre os neurônios. A matriz pseudo-inversa  $H^{-1} \cong H \dagger$  repele os pesos sinápticos do limite de decisão em direção aos extremos (polos) da diagonal secundária.

Em termos matemáticos, a matriz pseudo-inversa  $H \dagger$  usa a decomposição de valor singular  $H = U\Sigma V^*$ , onde  $U$  é uma matriz unitária real ou complexa  $n \times n$  e  $n$  é o neurônio de entrada total.  $\Sigma$  é uma matriz diagonal retangular  $n \times \sigma$  com números reais não negativos na diagonal principal,  $n$  é o total neurônio de entrada e  $\sigma$  é o total de vetores de dados de treinamento.  $V^*$  (o conjugado transposto de  $V$ )

é uma matriz unitária real ou complexa  $\sigma \times \sigma$ . As entradas diagonais  $\Sigma_{i,t}$  de  $\Sigma$  são denominadas valores singulares de  $H$ . As colunas  $n$  de  $U$  e as colunas  $\sigma$  de  $V$  são os vetores singulares à esquerda e os vetores singulares à direita de  $H$ , respectivamente. O pseudo-inverso de  $H$  é então igual a  $H^\dagger = V\Sigma^{-1}U^*$ .

A saída dos neurônios da camada escondida, representada pela matriz  $H$ , é obtida utilizando o *kernel*  $\varphi$ , entradas e pesos da camada escondida, conforme demonstrado na Eq. (2.3). O *kernel*  $\varphi$ , as entradas e pesos do conjunto de dados entre a entrada e as camadas ocultas são empregados. Os pesos de saída  $\beta$  e a matriz de saída desejada  $Y$  são descritos na Eq. (2.4) na e Eq. (2.5), respectivamente.

$$H_{tj} = \begin{bmatrix} \varphi_1^1 & \varphi_2^1 & \cdots & \varphi_v^1 \\ \varphi_1^2 & \varphi_2^2 & \cdots & \varphi_v^2 \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_1^m & \varphi_2^m & \cdots & \varphi_v^m \end{bmatrix}_{m \times v} \quad (2.3)$$

$$\beta_{jc} = \begin{bmatrix} \beta_1^1 & \cdots & \beta_\zeta^1 \\ \beta_1^2 & \cdots & \beta_\zeta^2 \\ \vdots & \ddots & \vdots \\ \beta_1^m & \cdots & \beta_\zeta^m \end{bmatrix}_{m \times \zeta} \quad (2.4)$$

$$Y_{tc} = \begin{bmatrix} Y_1^1 & \cdots & Y_\zeta^1 \\ Y_1^2 & \cdots & Y_\zeta^2 \\ \vdots & \ddots & \vdots \\ Y_1^v & \cdots & Y_\zeta^v \end{bmatrix}_{v \times \zeta} \quad (2.5)$$

O modelo de aprendizado das redes ELMs fundamenta-se na utilização de *kernels*, os quais são essencialmente funções matemáticas empregadas como um método fundamental para o desenvolvimento das redes neurais ELMs. Em sua configuração padrão, o *kernel* refere-se à função linear, com o propósito de realizar uma separação linear eficiente dos dados. A Eq. (2.6) descreve o *kernel* Linear  $\varphi$  de uma rede ELM.  $\varphi$  está em função de  $\varpi(x_{t,1..n}, w_{1..m,1..n}, b_{1..m,t})$ .

$$\varphi_t^j(\varpi) = x_{ti} \cdot w_{ji} + b_{jt} \quad (2.6)$$

Uma questão essencial quanto a redes neurais extremas consiste em averiguar a correlação do conjunto de dados em função da geração aleatória dos pesos entre as camadas sinápticas. Alcançar resultados pertinentes em uma aplicação específica, com uma semente geradora de pesos aleatórios, não quer dizer que essa mesma semente, ao ser utilizada em um cenário diferente, irá atingir resultados adequados. Encontrar a semente ótima para a geração de pesos aleatórios é um desafio que pode requerer um extenso período de tempo. Explorar exaustivamente o espaço de busca torna-se computacionalmente inviável.

Uma opção frequentemente utilizada envolve múltiplas execuções de uma única estrutura de rede neural. Em cada execução, são aplicadas diferentes técnicas para gerar pesos sinápticos iniciais aleatórios. Essa abordagem permite avaliar se as variações nos pesos sinápticos iniciais podem impactar significativamente os resultados. Ao término dos experimentos, um alto desvio padrão indicaria uma dispersão nos resultados. Consequentemente, a rede neural estaria sujeita a influências e correlações com as condições iniciais aleatórias.

Nessa situação, as condições de início poderiam, abruptamente, tanto degradar quanto elevar a acurácia da rede neural. Tornar-se-ia temerária a implementação de uma solução com essa característica na prática clínica, por exemplo. Ao longo da etapa de utilização, uma pequena alteração no perfil das pacientes poderia resultar em uma súbita deterioração nos resultados fornecidos pela solução computacional. A rede neural seria eficaz apenas para casos estatisticamente semelhantes aos apresentados durante o treinamento. Destaca-se que numerosos casos observados na prática clínica não se alinham de forma precisa com as imagens e descrições tradicionais (de Lima et al.,2016).

## 2.5 Termografia

A termografia é uma técnica de imagem que utiliza a radiação infravermelha (IR) emitida por objetos para criar representações visuais de variações de temperatura. Essa técnica fundamenta-se na emissão de radiação IR por objetos com temperatura acima do zero absoluto, sendo capturada por um detector especializado e processada para gerar uma imagem termográfica. Nessa imagem, as diferentes cores ou tons representam diferentes temperaturas, seguindo uma escala de cores onde cores mais quentes indicam temperaturas mais altas e cores mais frias indicam temperaturas mais baixas.

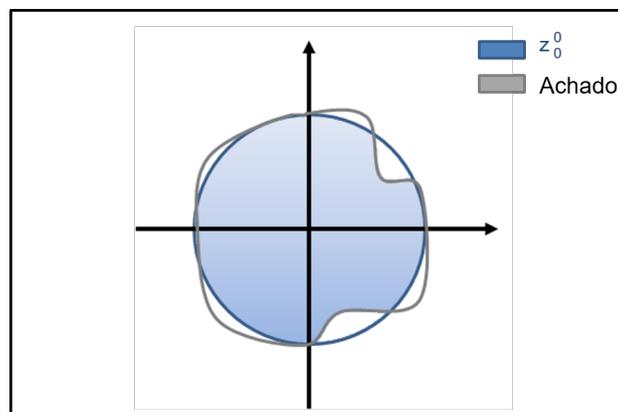
A aquisição de imagens termográficas é realizada por meio de câmeras termográficas, que capturam a radiação IR emitida pelo objeto e a processam para gerar a imagem termográfica. Essa técnica oferece diversas vantagens, como a detecção de anomalias térmicas não visíveis a olho nu, o caráter não destrutivo da medição e a eficiência na análise das variações de temperatura em tempo real.

No entanto, a interpretação das imagens termográficas pode ser complexa e requer treinamento especializado, além do custo relativamente alto das câmeras termográficas. Além disso, existem limitações ambientais que podem afetar a precisão das medições, como condições de iluminação, variações atmosféricas e condições climáticas extremas. Em particular, a presença de vento, chuva, névoa ou iluminação solar direta pode interferir na qualidade das medições termográficas.

Apesar dessas limitações, a termografia continua sendo uma ferramenta valiosa em diversas aplicações, incluindo manutenção preditiva, diagnóstico médico, inspeção de construções e muito mais.

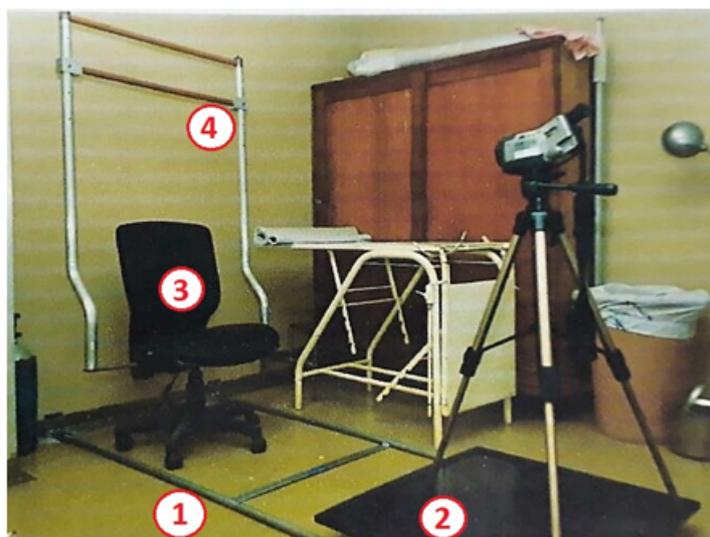
A Figura 2.3 mostra o equipamento que foi utilizado para produzir as imagens termográficas presentes no banco de dados deste trabalho.

**Figura 2.2:** Descrição da forma da lesão através do momento de Zernike  $Z_2^0$ .



Fonte: (de Lima et al.,2016).

**Figura 2.3:** 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:(Santana et al.,2018).

## Capítulo 3

### Estado da Arte

A Tabela 3.1 apresenta uma lista de algumas técnicas inteligentes do estado da arte aplicadas a termogramas e mamogramas. Incluem-se algoritmos de aprendizado de máquina, redes neurais e métodos de poda de atributos de entrada. Técnicas inteligentes têm mostrado resultados promissores na detecção precoce e na classificação de anomalias mamárias.

**Tabela 3.1:** Resumo das principais técnicas inteligentes em termogramas de última geração.

Autores	Tipo de Rede Neural	Objetivo	Acurácia
IA autoral Auto-explicável	Rede rasa	Extrator de características + Reconhecimento de padrão	89,70%
Pereira et al.,2021	Rede rasa	Poda de atributos + Reconhecimento de padrão	84,93%
Macedo et al.,2021	Rede profunda + Rede rasa	Poda de atributos+ Reconhecimento de padrão	87.25%
Santana et al.,2022a	Rede profunda + Rede rasa	Reconhecimento de padrão	$\cong$ 84%
Santana et al.,2022b	Rede profunda + Rede rasa	Reconhecimento de padrão	$\cong$ 85%

Fonte: O autor (2024).

Pereira et al.,2021 propõe a seleção de atributos com base no método dialético de otimização na termografia mamária. O intuito foi simplificar os classificadores e aumentar o potencial de generalização para apoiar o diagnóstico de lesões de mama. Através da técnica de seleção de atributos proposta, foi possível simplificar as arquiteturas dos classificadores, reduzindo a dimensão dos vetores de características

em cerca de 50%, com baixo impacto nas taxas corretas de classificação, apresentando uma redução de aproximadamente 3,72%. A metodologia de PEREIRA, *et. al* 2021 é uma técnica promissora para redução de atributos, obtendo valores de acurácia significativos usando apenas 84 dos 168 atributos originalmente extraídos. Isso demonstra a importância desse passo para a utilização da termografia mamária como uma técnica auxiliar no diagnóstico do câncer de mama. PEREIRA, *et. al* 2021 conseguiu alcançar uma acurácia de 84.93% após restringir a quantidade de atributos na entrada da aplicação (Pereira et al.,2001).

Macedo et al.,2021 implementa uma metodologia para identificação e categorização de lesões usando imagens reais de pacientes brasileiras, combinando modelos característicos, seleção de atributos e classificação com algoritmos de aprendizado de máquina. A pesquisa destaca a importância da termografia mamária, capaz de identificar alterações metabólicas associadas a lesões. A técnica proposta extrai peculiaridades de forma e textura usando momentos de Zernike e Haralick, reduzindo o número de dados em 50%. A seleção de atributos é realizada com algoritmos de otimização baseados em inteligência de enxame, contribuindo para eficiência computacional sem comprometer a precisão. Onze algoritmos de aprendizado de máquina, incluindo redes neurais convolucionais e máquinas de vetor de suporte, são avaliados na categorização das imagens . Os resultados mostram que o procedimento proposto diminui o tempo computacional, mantendo elevadas taxas de classificação correta. Destaca-se a importância da seleção de atributos na eficácia do diagnóstico, especialmente considerando aspectos de forma. A pesquisa contribui para alternativas menos dolorosas e mais eficientes no diagnóstico de câncer de mama, sendo particularmente relevante em regiões com limitações de artificios e acesso a especialistas. No melhor cenário a acurácia alcançada foi de 87.25%(Macedo et al.,2021).

Santana et al.,2022a propõe uma arquitetura híbrida profunda para apoiar o diagnóstico de imagens de termografia mamária com base em Redes Neurais Profundas de *Wavelets* de cinco camadas, para coletar peculiaridades das regiões de interesse de mamogramas, e máquinas de vetores de suporte com *kernel* linear para a classi-

ficação final. Classificadores clássicos, como classificadores bayesianos, perceptrons de camada única, árvores de decisão, *Random Forests* e máquinas de vetores de suporte, foram testados. Utilizando uma rede neural profunda com pesos predefinidos do banco de filtros da Transformada de *Wavelets*, foi possível extrair atributos e trazer o problema para um contexto onde é solucionável com fronteiras de decisão relativamente simples, como as compostas por máquinas de vetores de suporte com *kernel* linear. Isso demonstra que essas novas redes profundas podem ser importantes na construção de soluções completas para melhorar o proveito da termografia mamária e apoiar o diagnóstico clínico. Os achados demonstraram a viabilidade de identificar e categorizar lesões com acurácia acima de 84% ao utilizar a técnica de transferência de aprendizado entre *Deep Wavelet* e a *machine learning random forest* (Santana et al.,2022a).

Santana et al.,2022b estabelece abordagens inovadoras utilizando Redes Neurais Profundas de *Wavelet*, que são convolucionais e podem ter bancos de filtros predefinidos como neurônios. O estudo focou na termografia mamária, uma técnica não invasiva, destacando a importância da seleção de atributos para aprimorar a eficácia diagnóstica. Os resultados mostraram a viabilidade de detectar e classificar lesões. Uma segunda abordagem adotou mamografia digital, propondo uma arquitetura híbrida profunda utilizando Redes Neurais Profundas de *Wavelet* de seis camadas. A pesquisa destaca o potencial das redes neurais profundas que incorporam filtros predefinidos, proporcionando soluções robustas para o suporte ao diagnóstico de câncer de mama. Essas abordagens promissoras demonstram a relevância do método de aprendizado de máquina na melhoria dos resultados de imagem mamográfica, contribuindo significativamente para a identificação precoce e tratamento eficaz do câncer de mama. Santana et al.,2022b atinge uma acurácia próxima de 85% ao utilizar a técnica de transferência de aprendizado entre *Deep Wavelet* e a *machine learning random forest*.

# Capítulo 4

## Desenvolvimento

A Figura 4.1 ilustra o diagrama de blocos, o qual minuciosamente detalha cada uma das etapas do processo de desenvolvimento. O referido diagrama oferece uma visão abrangente e esclarecedora do fluxo de trabalho adotado.

### 4.1 Processamento das Imagens de Termografia

A fim de extrair as informações necessárias das imagens é fundamental o pré-processamento do banco de dados, pois como se trata de um inteligência artificial auto-explicável não se pode utilizar os dados brutos e esperar que o algoritmo irá interpretá-los corretamente. Portanto é necessário essa manipulação prévia dos dados para que o programa assimile apenas os dados de interesse. Para explicar o pré-processamento pode-se dividi-los em etapas.

#### 4.1.1 Triagem da Base de Dados

Realiza-se a avaliação da totalidade do conjunto de dados que engloba 1052 imagens termográficas. Estas imagens são categorizadas com base em seus diagnósticos, que incluem Cisto, Lesão Benigna, Lesão Maligna e Ausência de Lesão. Cada tipo de diagnóstico contém múltiplas imagens, variando em suas orientações. Em outras palavras, as termografias foram adquiridas a partir de várias perspectivas distintas para facilitar a identificação das lesões.

A Figura 4.2 exibe as imagens de termograma oriundas da base de dados empregada. As descrições clássicas descrevem variações abruptas na intensidade de calor entre lesões benignas e malignas. Na literatura acadêmica, uma lesão maligna apresentaria uma intensidade de calor muito superior em comparação à lesão benigna ou um cisto. Esse fato costuma não ocorrer no conjunto de imagens da base de dados extraído da prática clínica. Os casos, como os exibidos na Figura 4.2, apresentam intensidades de calor muito próximas, mesmo tendo distintos diagnósticos. A diferença entre os resultados obtidos na prática clínica e a literatura acadêmica torna o diagnóstico de câncer de mama em termogramas uma tarefa complexa até para profissionais especialistas experientes.

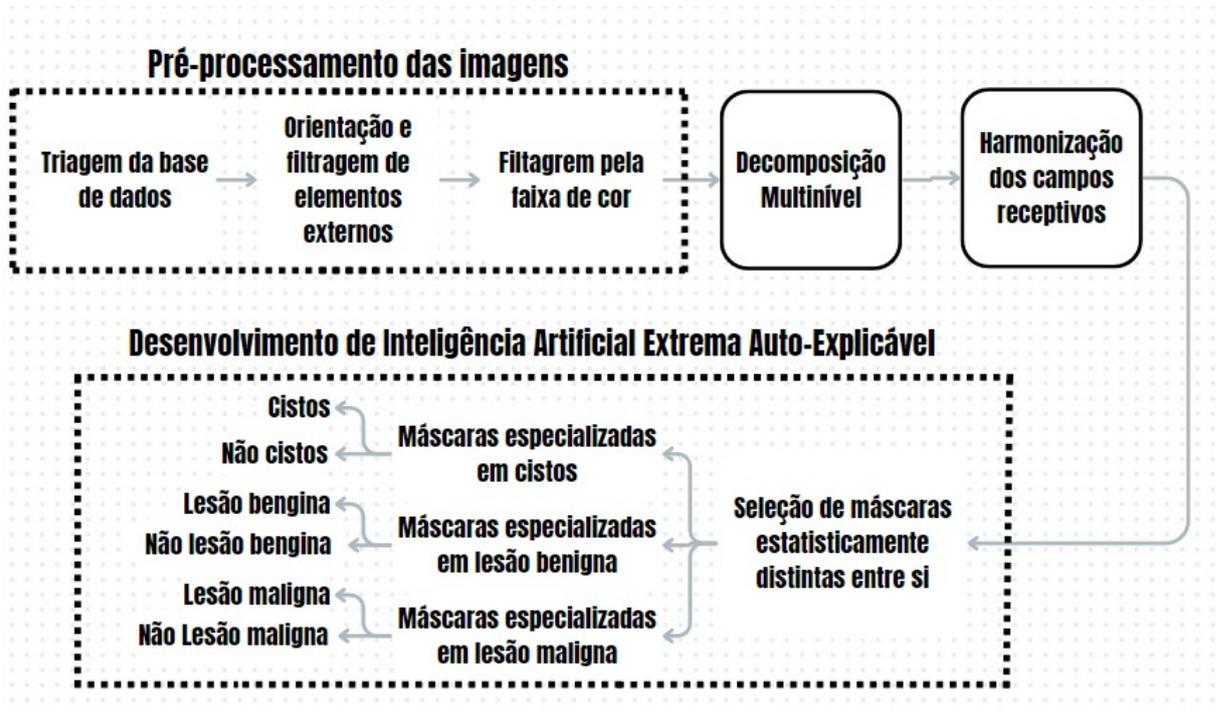
#### **4.1.2 Escolha das Orientações e filtragem de elementos externos**

Na presente etapa, as imagens passam por um novo catálogo. Na etapa anterior, o objetivo foi catalogar as imagens de acordo com seu diagnóstico: lesão maligna, lesão benigna, sem lesão e cisto. Na presente etapa, o objetivo é catalogar as imagens por orientação. Na base de dados, há 8 (oito) orientações sendo elas: LEMD (Lado Esquerdo; Mama Direita), LDME (Lado Direito; Mama Esquerda), LDMD (Lado Direito; Mama Direita), MD (Mama Direita), ME (Mama Esquerda), T1 (Torso) e T2 (Torso).

Devido à variedade da prática clínica, faz-se necessário a escolha de determinadas orientações em detrimento de outras. Isso promove uma abordagem mais coerente e uniforme na categorização das imagens. Na presente base de dados, em uma imagem MD de uma paciente com cisto não há garantias do cisto se encontrar na mama direita. O referido cisto pode estar na mama esquerda, portanto fora da imagem. Em acréscimo, a base de dados não dá garantias da paciente ter realizado todas as 8 (oito) orientações.

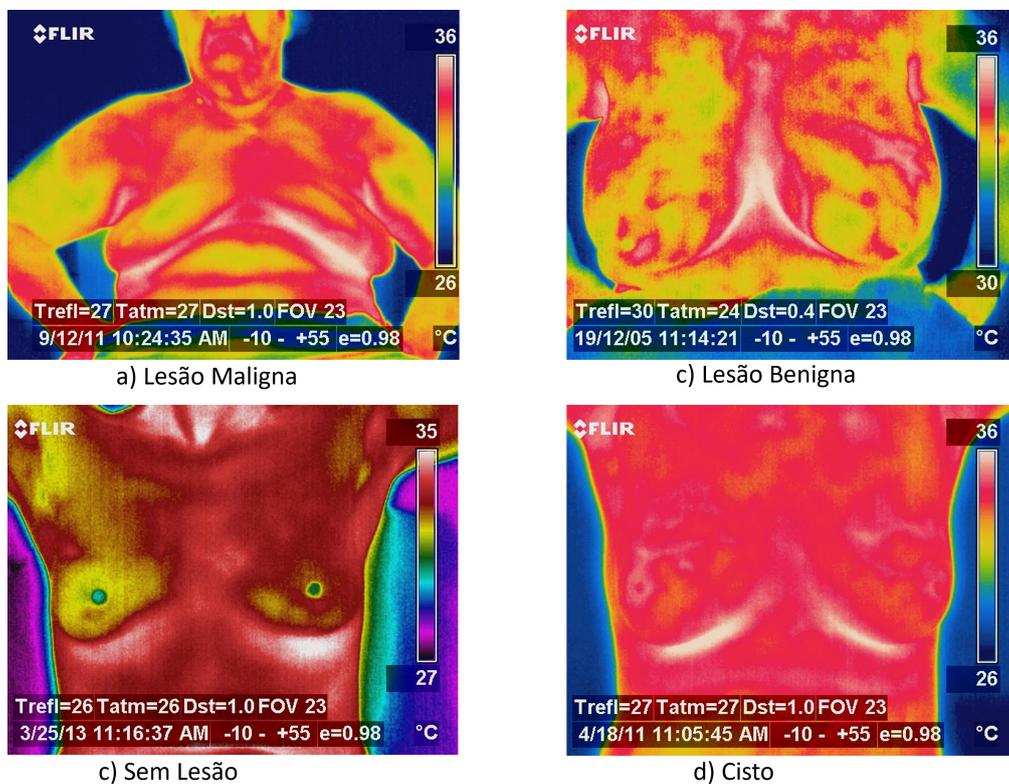
Não há, portanto, como fazer deduções e inferências visto que a lesão, causadora do diagnóstico, pode estar fora da imagem. E também não haveria correspondência

Figura 4.1: Detalhamento do desenvolvimento.



Fonte: O autor(2024).

Figura 4.2: Triagem da Base de Dados.



Fonte: O autor (2023).

em qualquer outra imagem de toda a base de dados. Em face do exposto, é considerada apenas a orientação T1 no presente trabalho. A motivação é que a representação do torso da paciente possibilita maximizar as chances da lesão estar contida na imagem.

Dentro do conjunto de dados em questão, havia imagens que continham elementos sem relevância para a análise. Esses elementos incluíam informações iniciais provenientes diretamente do dispositivo médico, como temperatura ambiente, data, hora, mapa de cores da imagem, entre outros. Tais informações foram inseridas durante a etapa de captura das imagens. Além disso, observou-se a presença de partes do braço, região abdominal e até mesmo objetos do ambiente circundante, que não possuíam correlação com a região de interesse.

Por exemplo, há partes da cadeira e/ou encosto se sobrepondo à mama em várias imagens da base de dados. Com o intuito de aprimorar a qualidade do conjunto de dados, foi crucial realizar um processo meticuloso de recorte, focando especificamente na área de interesse de cada imagem. Esse procedimento foi adotado para eliminar quaisquer componentes que se mostrassem redundantes ou irrelevantes. O objetivo é maximizar as chances de que apenas os elementos essenciais para a análise e diagnóstico se mantivessem presentes nas imagens.

### 4.1.3 Filtragem por Faixa de Cor

A Figura 4.3 exemplifica a filtragem por faixa de cor. É calculada a distância euclidiana entre cada pixel da imagem recortada e o espectro de cor auferido previamente. O espectro autoral de cor é composto por 8 (oito) faixas; roxo escuro, roxo claro, azul escuro, azul claro, verde, amarelo, vermelho e branco. Na filtragem por faixa de cor, apenas permanecem os *pixels* contidas entra a faixa amarela e faixa branca. Os demais *pixels* são incorporados ao fundo (*background*). Interpreta-se que são regiões frias compatíveis com o metabolismo da paciente. Não há, portanto, lesões ou cistos nessas regiões com baixa intensidade de calor. Após a retirada das regiões frias da imagem, é viável determinar a região da imagem atrelada à área

de interesse. A filtragem por faixa de cor é fundamental na técnica proposta. A filtragem é capaz de eliminar regiões de não-interesse tais quais; braços, pescoço e músculo peitoral. Enfatiza-se que os recortes horizontais e ajustes finais foram feitos de forma manual.

#### 4.1.4 Decomposição Multinível da Imagem

No presente trabalho, propõe-se a decomposição de imagens termográficas. O processo de decomposição da imagem ocorre em diferentes níveis (resoluções). Inicialmente há o estudo das lesões e seus tamanhos. Enquanto nos níveis mais avançados apenas sobram os achados de pequeno tamanho. No processo de decomposição, há perda de resolução devido à suavização (embaçamento) da imagem em cada nível. A explicação é que, durante a decomposição, os grandes corpos são suavizados (embaçados) e anexados ao fundo da imagem. A análise do tamanho é fundamental nas lesões de mama, pois o carcinoma mamário pode ser detectado tanto em uma lesão minúscula, como em uma lesão que englobe quase toda totalidade da mama.

Para realizar a adequada decomposição das imagens, recorreu-se a representação em tons de cinza do termograma. Essa transformação resulta na supressão das informações relacionadas à matiz e saturação, mantendo somente a componente de luminosidade. Tal procedimento foi adotado visando simplificar a manipulação das imagens, ao eliminar características que não eram pertinentes para a análise. Há a decomposição da imagem considerando a textura e a iluminação de cada limiar. O contraste da imagem é modificado em cada nível. É usada como inspiração a técnica *fuzzy c-means* que é basicamente um algoritmo de agrupamento que atribui pontos de dados a agrupamentos com base em sua similaridade entre si. A decomposição autoral é usada para agrupar os *pixels* da imagem que estão adjacentes e que possuem valores próximos.

A decomposição proposta também se inspira na série de *wavelets* com o objetivo de representar a imagem em multi-níveis. A detecção de lesões mamárias pode ser alcançada através da decomposição do termograma em múltiplos níveis. O estado

da arte costuma decompor o mamograma em apenas 2 níveis através das *wavelets* de MALLAT (do Nascimento et al.,2013). Por outro lado, na metodologia proposta, há a decomposição da imagem até ocorrer a saturação. Essa escolha é baseada na compreensão de que o câncer de mama não possui um formato ou tamanho predefinido. Portanto é fundamental o estudo de todos os elementos da região de interesse até seu esgarçamento. Considera-se que a decomposição em 2 níveis como propõe o estado-da-arte não é suficiente para segmentar todos os elementos presentes na região de interesse da imagem biomédica. A complexidade das características das lesões mamárias exige uma abordagem mais aprofundada para garantir uma segmentação abrangente e precisa.

Soluções computacionais aplicadas a imagens biomédicas, como na detecção de óvulos de *Aedes Aegypti* (vetor da dengue) e do *Schistosoma* (transmissor da *esquistossomose* - conhecida como barriga d'água), apresentam dimensões não discrepantes entre si. Em tais contextos, a decomposição da imagem original em múltiplos níveis não seria necessária. No entanto, ao lidar com lesões mamárias, a decomposição em vários níveis é fundamental. As lesões mamárias não seguem um padrão de tamanho previsível, variando desde frações de centímetros até ocupar quase toda a mama. Portanto a decomposição de lesões mamárias em termogramas é essencial, uma vez que nos níveis iniciais há o estudo de mapas de calor de uma ampla área, enquanto nos níveis finais há a possibilidade da análise de mapas de calor de pequeno porte.

A Figura 4.4 exemplifica a decomposição do termograma em diversos níveis, culminando em sua saturação. Lesões benignas e malignas, em geral, ocupam a região de maior temperatura na área de interesse, caracterizada pelo espectro de cores vermelhas e brancas. Esse fenômeno, no entanto, pode inadvertidamente destacar elementos não relacionados ao interesse clínico. Um exemplo comum é observado em pacientes com tecido mamário adiposo, onde pode surgir uma área de calor entre a mama e o peitoral, não correspondendo a uma lesão mamária legítima, como visto na Figura 4.2 (a). Assim é fundamental empregar técnicas de reconhecimento de padrões para discernir entre lesões mamárias genuínas e falsos positivos associados

a áreas de aumento de temperatura. Na metodologia proposta, a fase de reconhecimento de padrões das lesões é realizada após o processamento da imagem. Cada elemento na região de interesse contribui para a formação de um campo receptivo capaz de identificar possíveis anomalias teciduais.

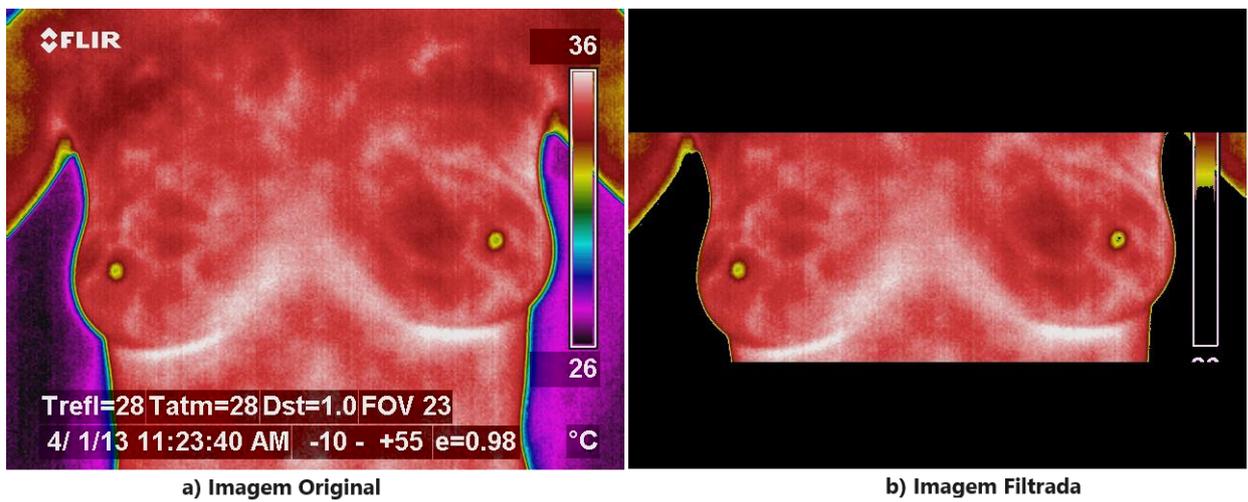
Por sua vez, a Figura 4.5 apresenta a decomposição das regiões frias remanescentes. A decomposição reversa é importante visando o estudo do cisto mamário visto que, em regra geral, ele ocupa uma região fria da área de interesse. Em termos computacionais, a faixa do espectro do cisto mamário varia entre as cores amarela e vermelha. Nas decomposições multiníveis, a legenda apresenta a letra  $n$  é acompanhada de um valor. Quando subtraído um valor direto de uma imagem no *MATLAB*, cada pixel da imagem é afetado pela subtração do valor especificado. Isso pode produzir diferentes efeitos, dependendo do valor escolhido e do tipo de imagem.

Primeiramente, se o valor subtraído for positivo, a imagem geralmente escurece, já que cada *pixel* terá seu valor reduzido pelo valor especificado. Por outro lado, se o valor subtraído for negativo, a imagem tende a clarear, pois cada pixel terá seu valor aumentado pelo valor absoluto do valor especificado.

É importante observar que os valores dos *pixels* da imagem são normalmente representados como inteiros de 8 bits (0 a 255) ou valores de ponto flutuante normalizados entre 0 e 1. Se o resultado da subtração for menor que 0 para uma imagem de 8 bits, por exemplo, os valores negativos serão truncados para 0, o que pode resultar em uma perda de detalhes nas áreas mais escuras da imagem.

Além disso, dependendo do valor escolhido para subtrair e da faixa dinâmica da imagem, pode haver perda de informações ou detalhes após a operação. Se o valor subtraído for muito grande em comparação com os valores dos *pixels* na imagem, detalhes nas regiões mais escuras podem ser perdidos. Assim como na subtração, se o valor adicionado for muito grande em comparação com os valores dos *pixels* na imagem, detalhes nas regiões mais escuras podem ser perdidos, devido à compressão dos valores dos *pixels* em direção ao branco.

**Figura 4.3:** Remoção dos elementos externos a paciente



Fonte: O autor (2023).

### 4.1.5 Harmonização dos campos receptivos (máscaras)

O resultado da imagem decomposta são imagens rugosas, defeituosas, com cortes abruptos e ininteligíveis. A anatomia da natureza humana não se manifesta de forma idealizada. As pacientes, por exemplo, podem ter seios retorcidos e abstrusos. Caso essas imagens fossem apresentadas ao médico, é muito provável que ele acreditaria que a inteligência artificial falhou em detectar qualquer informação revelante na imagem. É imprescindível a harmonização das "máscaras" com a finalidade de preencher os ruídos internos e suavizar as bordas para aproximar os agrupamentos já feitos das imagens clássicas idealizadas nos livros de radiologia.

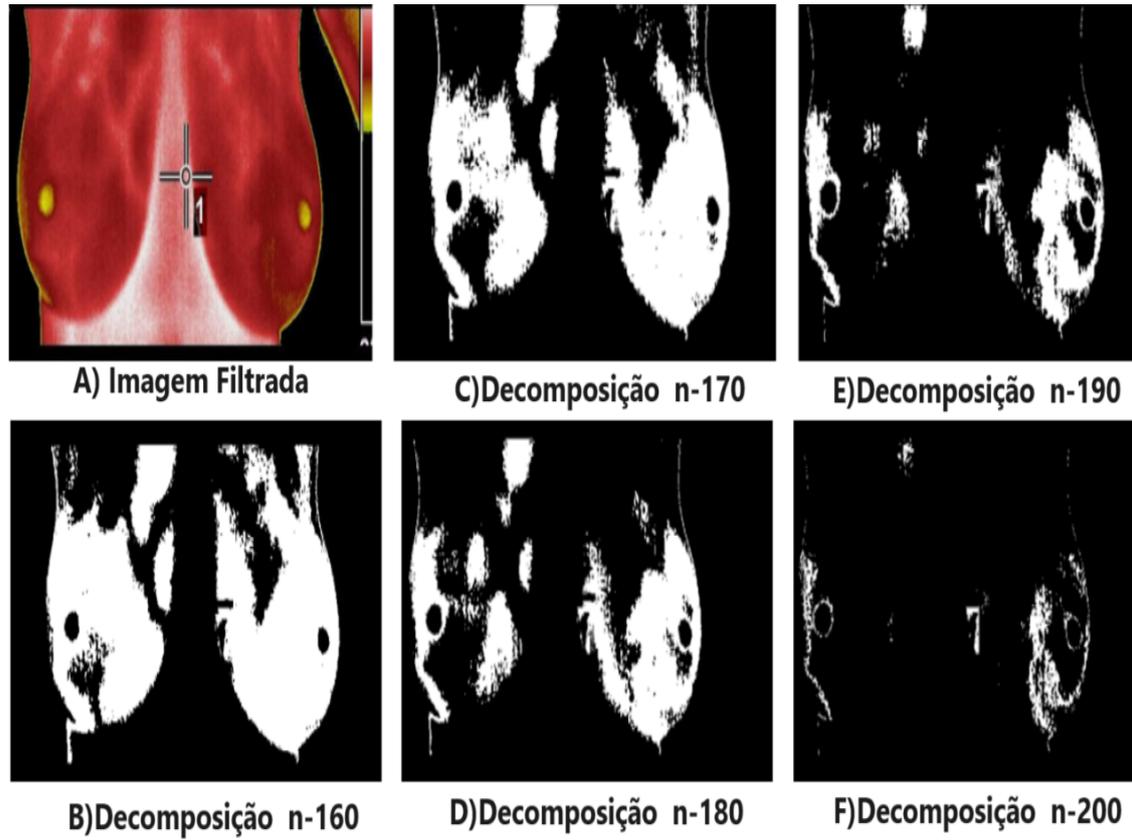
Após decompor as imagens, várias imagens contendo os elementos extraídos foram geradas. Para distinguir esses elementos, foram empregadas funções de programação, que permitiram agrupar os *pixels* adjacentes em uma figura, enquanto outros grupos foram separados em diferentes figuras. Esses elementos foram posteriormente utilizados para a criação das "máscaras".

As Figuras 4.6 e 4.7 exibem as "máscaras", que são resultados da harmonização das decomposições derivadas do gradiente da imagem. Isso implica que, após a decomposição, a escala de cores é reajustada para tornar as transições abruptas mais compreensíveis e aceitáveis visualmente. Com o objetivo de extrair o máximo de informação dessa harmonização, as figuras são progressivamente ampliadas, gerando assim novas "máscaras".

## 4.2 Desenvolvimento de Inteligência Artificial Extrema Auto-Explicável

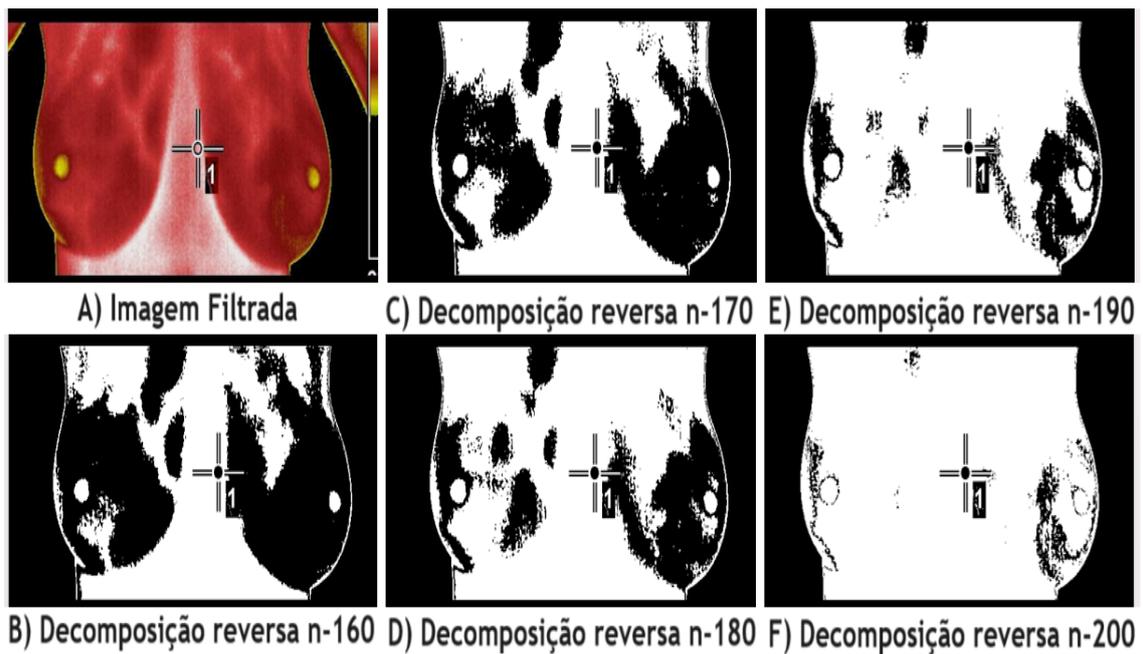
Quando realizada por redes neurais rasas, a etapa de reconhecimento de padrão está em função dos extratores de características das amostras. Por ser de baixa complexidade computacional, as redes rasas não possuem mecanismos visando converter as amostras em repositório de aprendizado estatístico. Ao empregar redes rasas, a tarefa de detectar e classificar lesões mamárias é altamente dependente da etapa de

Figura 4.4: Decomposição multinível



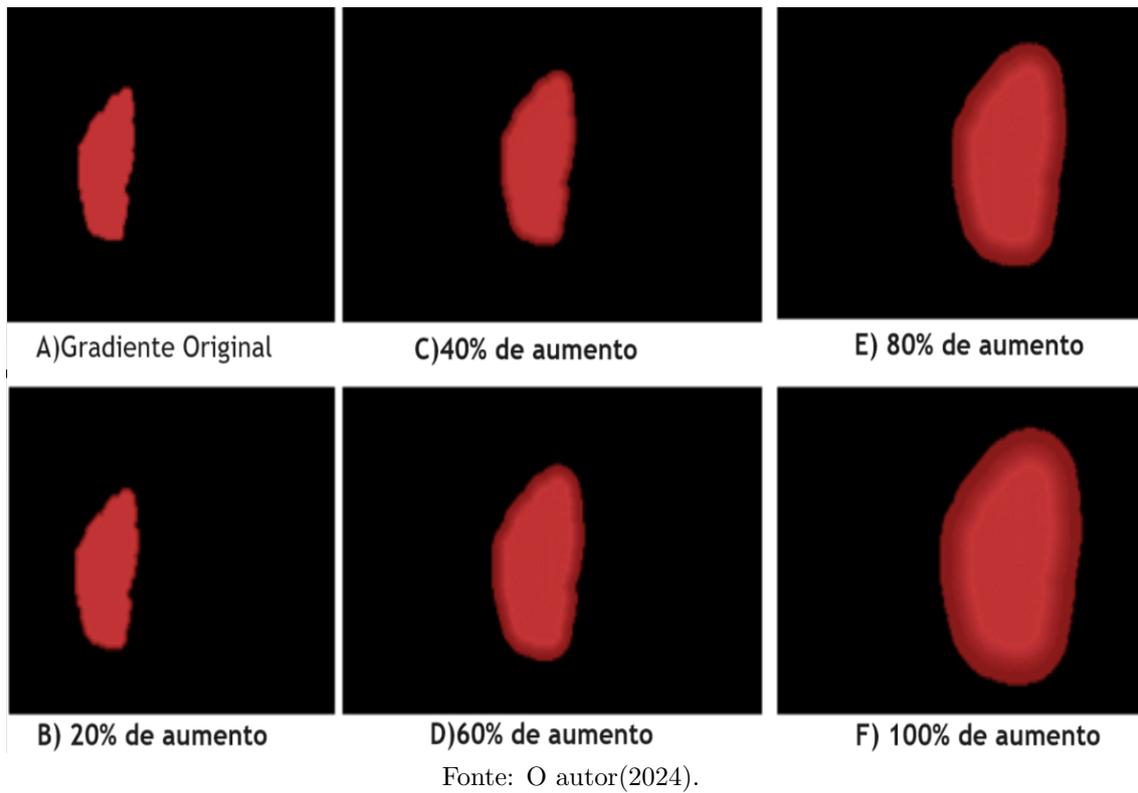
Fonte: O autor (2024).

Figura 4.5: Decomposição multinível reversa

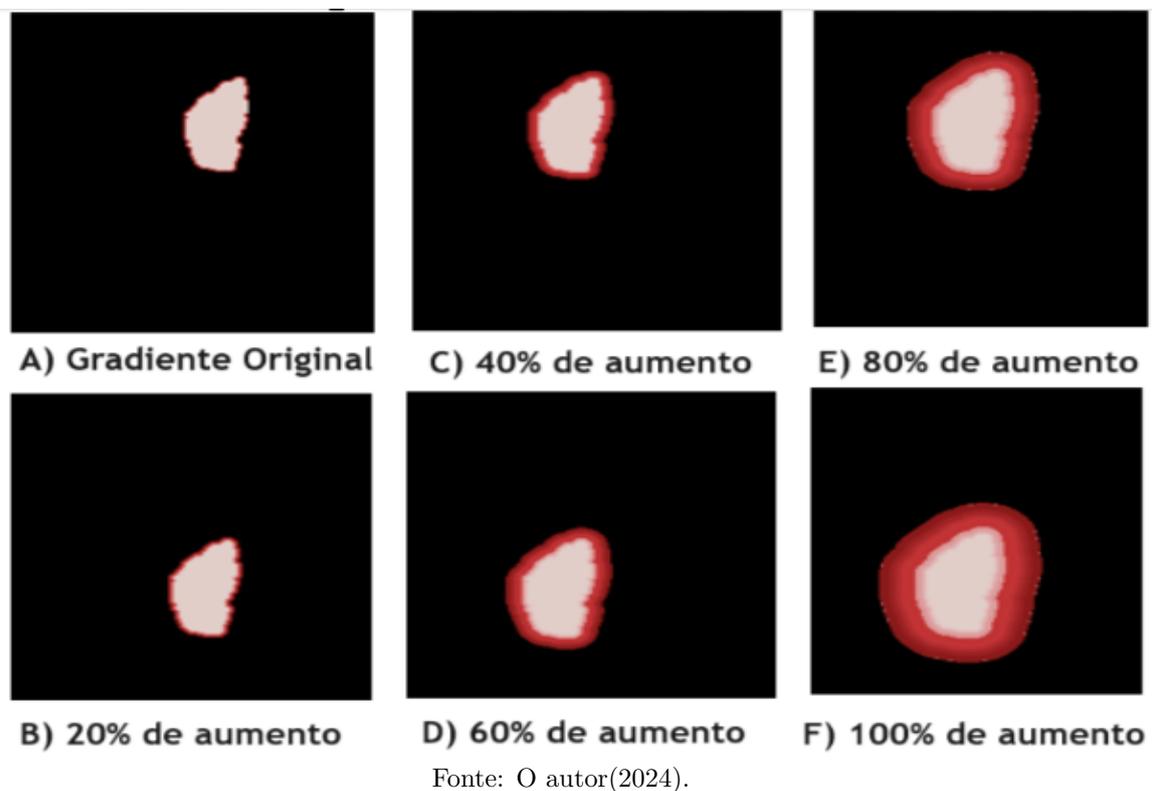


Fonte: O autor(2024).

**Figura 4.6:** Campos receptivos, uma faixa.



**Figura 4.7:** Campos receptivos, duas faixas.



extração de características (de Lima et al.,2016).

No estado-da-arte, os momentos de Zernike têm sido amplamente utilizados para extrair características quanto à forma da lesão de mama (Azevedo et al.,2015a; Azevedo et al.,2015b; Azevedo da Silva et al.,2021). A forma da lesão é essencial para a determinação da grau de malignidade das lesões mamárias (BI-RADS.,2013). Os momentos de Zernike são capazes de descrever a lesão avaliada de acordo com as regras da *American College of Radiology*. O estudo do formato da lesão é necessário para a escolha do tratamento apropriado. Uma lesão regular tem características benignas, enquanto uma lesão espiculada costuma ser maligna.

O método de Zernike diz respeito a polinômios de base radial. A função base de Zernike é projetada sobre o achado, tumor em potencial, presente na imagem biomédica. Os valores do gradiente, em escala, correspondem à intensidade na qual a região de interesse abrangida (sobreposta) ao disco será avaliada. As escalas determinam a intensidade com que a região da imagem, em estudo, abrangidas (sobrepostas) ao disco será avaliada.

Considere, por exemplo, o momento de Zernike  $Z_2^0$ . Nele, a região da imagem em estudo, sobreposta à região central do disco, será avaliada com intensidade máxima por possuir escala de pico, representada na Figura 2.1, através da cor vermelha. Intensidade máxima corresponde à média dos valores dos pixels da região sem qualquer decréscimo. À medida que a região periférica da imagem, projetada sobre o disco, é estudada, a intensidade do gradiente decai até atingir a área da imagem correspondente à borda do disco, representada na Figura 2.1, através da cor azul. Então na periferia da região da imagem sobreposta ao disco, há uma média ponderada, correspondente a um decréscimo, dos valores dos seus pixels. O momento de Zernike  $Z_2^0$  é adequado em relação a lesões regulares, de forma arredondada, como os cistos. A Figura 2.2 mostra um exemplo de um achado anatômico sendo descrito pelo momento de Zernike  $Z_0^0$ .

Nas imagens de mamografia, o momento de Zernike  $Z_5^5$  é capaz de descrever lesões espiculadas. As referidas lesões têm linhas radiantes partindo do centro em

direção à periferia com visto na Figura 2.1. O *American College of Radiology* estabelece que lesões espiculadas correspondem ao maior grau de malignidade quanto às características de um câncer maligno (D'Orsi CJ,2013). Enfatiza-se que muitos casos vistos na prática clínica não se encaixam, com precisão, nas imagens e descrições clássicas (de Lima et al.,2021; de Lima et al.,2016). Uma lesão espiculada, embora improvável, pode ser benigna. Cabe ao profissional especialista solicitar a biopsia da lesão suspeita.

Embora os momentos de Zernike se revelem fundamentais na caracterização de lesões em mamogramas, sua sensibilidade a variáveis como inclinação, área e formas não-geométricas impõe limitações à sua eficácia em cenários específicos. Essas restrições instigam a necessidade de buscar abordagens suplementares e mais robustas na análise de mamografias. O intuito é assegurar que os resultados possam ser apresentados a um profissional especialista de forma racional.

Ao contrário dos momentos de Zernike, o presente trabalho cria campos receptivos autorais. Os campos receptivos são versões harmonizadas oriundas da decomposição da região de interesse da amostra bruta. Ao invés de superfícies geométricas pré-concebidas, são geradas versões harmonizadas do termograma compatível com uma provável lesão.

A explicação do sucesso dos campos receptivos autorais diz respeito a sua capacidade de modelar qualquer lesão ou cisto mamário. O mapeamento feito pelos campos receptivos autorais não obedecem superfícies geométricas pré-concebidas a exemplo dos momentos de Zernike. Os campos receptivos autorais são capazes de naturalmente detectar e modelar às regiões de lesão e cisto mamário. Por ter sido criado a partir de elementos extraídos do próprio termograma, os campos receptivos autorais lidam naturalmente com a detecção e classificação das formas dos corpos presentes no termograma. Enfatiza-se a capacidade de modelagem da anatomia da natureza humana a exemplo de seios retorcidos, assimétricos e abstrusos.

Através dos campos receptivos autorais, torna-se possível formular uma hipótese auto-explicável quanto a presença de uma lesão ou cisto mamário. A rede neural

extrema é empregada visando reconhecer o padrão da anomalia anatômica. As redes neurais extremas são modelos de inteligência computacional dotados de aprendizagem que permitem a criação de mapeamento de dados sem retropropagação. As redes neurais extremas são técnicas de baixíssima complexidade computacional, mas capazes de prover excelentes acurácias (de Lima et al.,2016). Como vantagem, é viável explicar o funcionamento do aprendizado extremo a um humano devido ao baixo volume de cálculos. Tornar-se-ia viável convencer o profissional especialista de que a ferramenta pode prover uma “segunda opinião” ajustada e útil.

Há o estabelecimento de uma correlação entre o campo receptivo e a arquitetura da rede neural extrema proposta. Os atributos de entrada  $x_{it}$  dizem respeito à região decomposta do termograma bruto e temporariamente abrangida pelo campo receptivo. Os atributos de entrada  $x_{it}$  correspondem ao conjunto  $\{x_{it} \in \mathbb{R}; i = 1, \dots, n; t = 1, \dots, v\}$ . Há  $n$  características extraídas da aplicação, onde  $n$  é a quantidade de pixels da região decomposta do termograma bruto,  $v$  é o vetor de dados de treinamento.

De modo a ajustar as dimensões, o campo receptivo é redimensionado em função dos atributos de entrada. Após o redimensionamento, os pixels contidos no campo receptivo dizem respeito aos pesos  $w_{ji}$  atrelados às ligações sinápticas entre a camada de entrada e a camada escondida. A camada escondida  $h_j$ , constituída por  $m$  neurônios, onde  $m$  diz respeito à quantidade de pixels do campo receptivo. A camada escondida  $h_j$  é representada pelo conjunto  $\{h_j \in \mathbb{R}; j \in \mathbb{N}^*; j = 1, \dots, m\}$ . Na sequência, há o cálculo da matriz dos pesos de saída  $\beta = H \dagger Y$ , onde  $H \dagger$  é a matriz inversa generalizada de Moore-Penrose da matriz  $H$ , e  $Y$  corresponde à matriz de saídas desejadas, onde  $\{Y_{tc} \in \mathbb{R}; t = 1, \dots, v; c = 1, \dots, \zeta\}$ .  $\zeta$  é a quantidade de classes (ex. classe-alvo, contra-classes).

A formulação original da rede neural extrema envolve a geração aleatória de pesos, o que difere da abordagem desta proposta de inteligência artificial auto-explicável. A ideia de gerar neurônios aleatórios é descartada, uma vez que a estrutura arquitetural em si fornece os fundamentos para a explicação do diagnóstico

oferecido pela ferramenta de "segunda opinião".

O aprendizado da rede extrema é baseado em *kernel*. Esse tipo de aprendizado possibilita o reconhecimento de padrão do achado anatômico, sem a necessidade de aumentar o número de parâmetros ajustáveis. A Eq. (4.1) descreve o *kernel* autoral em relação ao processamento do primeiro neurônio da camada escondida. Trata-se de do erro médio quadrático entre os atributos de entrada  $x_{it}$  e os pesos sinápticos  $w_{ji}$ .

$$\varphi_t^1 = \frac{1}{n} \sum_{i=1}^n (x_{it} - w_{ji})^2 \quad (4.1)$$

A Figura 4.9 exhibe a atuação de um campo receptivo autoral. A Figura 4.10 apresenta um *QR code* que redireciona para um vídeo no *Youtube* que demonstra o funcionamento da inteligência artificial autoral. Cabe atentar que o campo autoral se encaixa na região decomposta do termograma de maior afinidade e, consequentemente, menor erro médio quadrático. Ao contrário dos momentos de Zernike, os campos receptivos autorais têm a capacidade de se decompor de modo a não ultrapassar os limites da região alvo do termograma. Em tempo de execução, os campos receptivos passam um auto-remodelação de modo a reduzir o erro médio quadrático em relação à região decomposta do termograma. A referida auto-remodelação se dá em termos de forma e de rotação.

Descrito na Eq. (4.2), o segundo neurônio da camada escondida diz respeito à quantidade de *pixels* em interseção da região decomposta do termograma e o campo receptivo auto-remodelável.

$$\varphi_t^2 = \frac{1}{n} \bigcap_{i=1}^n (x_{it}, w_{ji}) \quad (4.2)$$

Do terceiro neurônio ao trigésimo quarto, há extração de características quanto à forma e textura do campo receptivo auto-remodelável. Os referentes neurônios estão descritos nos Anexos. Na atual abordagem de inteligência artificial, o reconhecimento de padrões relacionado a lesões mamárias leva em consideração as informações locais explicitadas nos seus neurônios iniciais.

A inteligência artificial também incorpora informações globais provenientes do termograma, considerando seu mapa de calor como um todo. Do trigésimo quinto neurônio em diante, há a extração do espectro autoral de cor e composto por 9 (nove) faixas. A primeira faixa é destinada às regiões eliminadas preliminarmente descrita na sub-seção 4.1.2. Adicionalmente, há 8 (oito) faixas do espectro autoral: roxo escuro, roxo claro, azul escuro, azul claro, verde, amarelo, vermelho e branco. O referido espectro está definido na sub-seção 4.1.3. A Eq. (4.3) descreve o processamento do segundo ao nono neurônio. Esses neurônios são referentes ao espectro de cor.  $S \rightarrow \{0, 255\}$  é o termograma na forma de uma matriz tal que  $S \in \mathbb{N}^2$ .

$$\varphi_t^{j+35} = \sum_{j=1}^9 s_j \tag{4.3}$$

### 4.3 Discussão

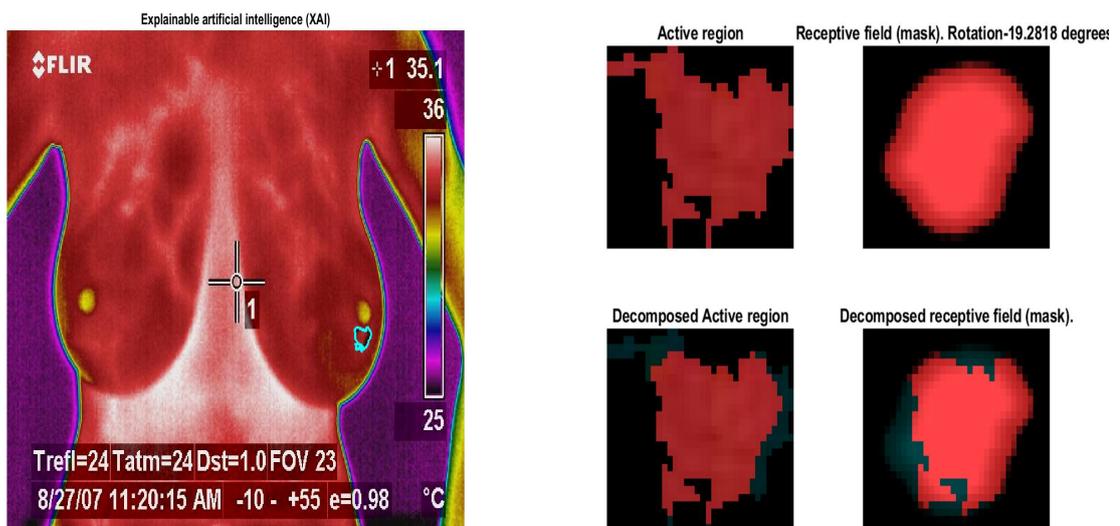
O presente trabalho defende que não basta que a técnica computacional opere corretamente. Os mecanismos devem ser capazes de explicar seu próprio funcionamento. Faz-se necessário que o usuário esteja completamente convencido de que a decisão do mecanismo foi correta. Através da inserção dos campos receptivos, o mecanismo autoral se tornará capaz de explicar seus diagnósticos de forma criativa e inteligente. Ao invés de extratores de características simétricos, o mecanismo autoral cria campos receptivos a partir de elementos oriundos do próprio termograma bruto.

Figura 4.8: Campos receptivos mascarados.



Fonte: o autor(2024).

Figura 4.9: Atuação de um campo receptivo autoral.



Fonte: O autor (2024).

Notam-se as limitações dos mecanismos de detecção de doenças anatômicas em relação aos postulados de Alan Turing . Os diagnósticos providos por ferramentas computacionais, convencionalmente, ocorrem através de rótulos sem maiores esclarecimentos.

Ao considerar as imagens de termografia, a meta é estabelecer descrições e padrões aos moldes do trabalho realizado pelo *American College of Radiology* (D’Orsi CJ,2013).

A motivação é que as lesões achadas em termografia ainda não possuem um padrão técnico auto descritivo. A inteligência artificial se torna uma boa alternativa. A inteligência artificial, durante sua etapa de aprendizado, é capaz de analisar milhares de arquivos e extrair características deles. Após o aprendizado, a inteligência artificial conseguiria estabelecer padrões em relação a formato, densidade e região de vizinhança da lesão. Dessa maneira, a inteligência artificial ganharia subsídios para explicar a sua própria decisão a um humano.

Um problema operacional das redes neurais clássicas consiste em investigar a dependência de sua aleatoriedade inicial. Começam randomicamente as ligações sinápticas entre os pesos  $w_{ji}$  neurônios da camada de entrada e a escondida. Nas redes baseadas em retropropagação, essas ligações sinápticas irão se ajustando à aplicação alvo através da redução entre a distância das respostas desejadas e as respostas obtidas.

Se a semente geradora de aleatórios for adequada a uma determinada aplicação, a rede neural obterá excelentes resultados. Caso a semente for inadequada, a rede neural poderá ter resultados desastrosos. Obter resultados satisfatórios em uma determinada aplicação, com uma semente geradora de números aleatórios iniciais, não significa que essa mesma semente quando for empregada em uma outra aplicação obterá bons resultados. Encontrar a semente ótima para a geração de números aleatórios é um problema que pode requerer uma quantidade elevada de tempo. É, portanto, computacionalmente inviável explorar o espaço de busca de maneira exaustiva.

Uma alternativa comumente empregada diz respeito a dezenas de execuções de uma mesma arquitetura de rede neural. Em cada execução, há o emprego de uma distinta semente geradora de números aleatórios iniciais. Dessa forma, é possível inferir se as variações dos pesos sinápticos iniciais são capazes de influenciar abruptamente os resultados. Ao final dos experimentos, um desvio padrão elevado implicaria que os resultados são dispersos. A rede neural, portanto, sofreria influência e dependência das condições iniciais randômicas. Nessa situação, as condições iniciais poderiam, abruptamente, tanto degradar quanto elevar a acurácia da rede neural. Tornar-se-ia temerária a adoção de uma solução com essa característica na prática clínica, por exemplo.

Na inteligência artificial auto-explicável autoral, as ligações sinápticas não são determinadas de forma aleatória. As ligações sinápticas correspondem aos campos receptivos. A própria arquitetura da rede neural subsidia recursos de modo a tornar o modelo auto-explicável. A estrutura da rede, ao refletir diretamente nos campos receptivos, desempenha um papel crucial na capacidade do modelo de fornecer explicações claras e compreensíveis, promovendo transparência e interpretabilidade no processo de tomada de decisão.

Adicionalmente, é fundamental destacar a compreensibilidade de cada um dos nove neurônios presentes na arquitetura da rede neural autoral. Esses elementos não apenas desempenham um papel fundamental na execução da técnica proposta, mas também servem como blocos de construção essenciais para a explicação do funcionamento do sistema. A transparência oferecida pela compreensibilidade dos neurônios da camada escondida, em camada única, contribui significativamente para a confiança do usuário na metodologia.

Essa ênfase na compreensibilidade não apenas aprimora a eficácia da técnica, mas também responde à crescente necessidade de sistemas explicáveis na área de inteligência artificial. Esse enfoque estratégico fortalece a credibilidade da proposta e também destaca seu potencial impacto em futuras aplicações clínicas e avanços na prevenção e detecção de cânceres de mama.

**Figura 4.10:** *QR code* para vídeo mostrando o funcionamento da IA autoral.



Fonte: O autor (2024).

## Capítulo 5

# Resultados

Nesta seção, são apresentados os resultados da técnica de inteligência artificial auto-explicável autoral. Foram geradas dezenas de milhares de campos receptivos para cisto, lesão maligna e lesão benigna, respectivamente. O alto volume de campos receptivos inviabilizaria o experimento em tempo computacionalmente tratável. Poderia custar meses, talvez anos, a investigação desse volume de campos receptivos em toda sua base de dados.

Visando a redução da dimensionalidade, o presente trabalho selecionou os campos receptivos estatisticamente distintos entre si. Foram empregados descritores clássicos de texturas e formas, incluindo os momentos de Haralick, na descrição dos campos receptivos. Os atributos, oriundos da descrição clássica, foram submetidos a testes estatísticos de hipóteses paramétrico e não-paramétrico. Apenas os campos receptivos estatisticamente distintos entre si permaneceram ao final do experimento.

Ao término do processo de redução dimensional, ainda havia centenas de campos receptivos (máscara) para cada classes-alvo; cistos, lesões malignas e lesões benignas. Essa estratégia otimizou a eficiência computacional. Porém ainda se fazia necessária uma maior redução da dimensionalidade.

A fim de otimizar o tempo de treinamento, a base de dados foi estrategicamente dividida em 20 pacotes, cada um contendo amostras selecionadas aleatoriamente de todas as classes, inclusive mamogramas normais sem lesão aparente. Utilizando o método um-contra-todos, a acurácia dos campos receptivos foi examinada em relação

à classe alvo em cada pacote. Ao final da avaliação de cada pacote, apenas os campos receptivos com acurácia acima da média mais o desvio padrão foram retidos para a análise subsequente.

Em todos os cenários e classes, a investigação de apenas 3 pacotes foi suficiente para concluir o experimento e identificar os campos receptivos escolhidos. Nessa fase de redução da dimensionalidade, é importante observar que havia apenas dois neurônios na camada escondida, conforme descrito na Eq. (4.1) e na Eq. (4.2), sem o suporte dos demais neurônios. Essa abordagem, além de agilizar o tempo de resposta, destaca que a dos campos receptivos é realizada exclusivamente com base nas informações locais, sem favorecimento oriundo das informações globais contidas no espectro de cor do termograma. Essa estratégia reforça a eficiência e a independência do processo de redução de dimensionalidade adotado.

As Figuras 5.1, 5.2 e 5.3 exibem as descrições autorais aos moldes do trabalho realizado pela *American College of Radiology* no ACR BI-RADS ©. A IA autorizada fundamenta suas próprias decisões de maneira compreensível para um humano. Adicionalmente, essa abordagem oferece recursos que capacitam profissionais especialistas a justificar suas decisões perante órgãos reguladores, como conselhos de classe.

A Tabela 5.1 diz respeito à acurácia dos campos receptivos descritos na Figura 5.1, a Figura 5.2 e a Figura 5.3. O resultado da acurácia e desvio padrão da segunda e terceira máscara das lesões malignas foram os mesmos. Utilizando o método um-contratodos, a acurácia dos campos receptivos foi examinada em relação à classe alvo em toda a base. Na contra-classe, estavam presentes todas as demais, inclusive os casos de termogramas sem lesão. Cada campo receptivo foi submetido a experimentos individuais, onde a camada escondida, composta pelos neurônios autoexplicativos apresentados na seção 4.2 foi utilizada em cada reconhecimento de padrão. Ao analisar a Tabela 5.1, torna-se evidente que a acurácia dos campos receptivos é uma métrica crítica para avaliar o impacto dessas unidades na tomada de decisão do sistema. A disposição individual de cada campo receptivo e seu desempe-

Figura 5.1: Grau de acurácia quanto a cistos.



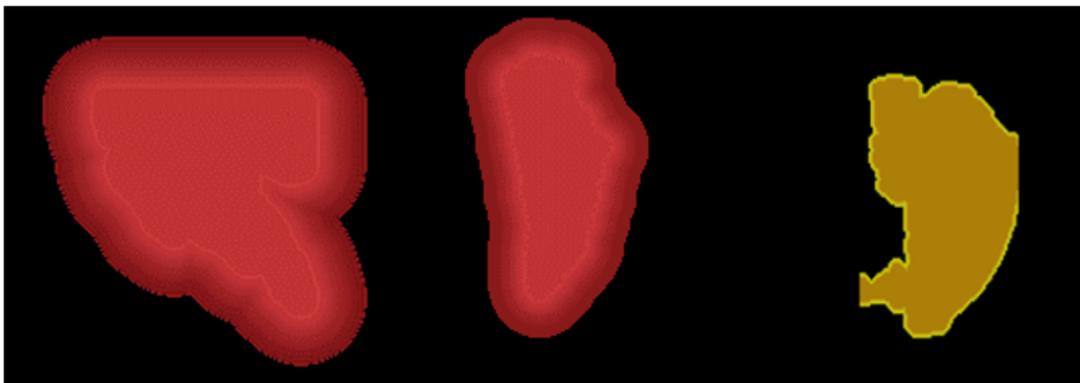
**A)**  
**Média:**  
 83,088%  
**Desvio padrão:**  
 37,62%

**B)**  
**Média:**  
 83,823%  
**Desvio padrão:**  
 36,95%

**C)**  
**Média:**  
 85,294%  
**Desvio padrão:**  
 35,54%

Fonte: O autor (2024).

Figura 5.2: Grau de acurácia quanto à lesões benignas.

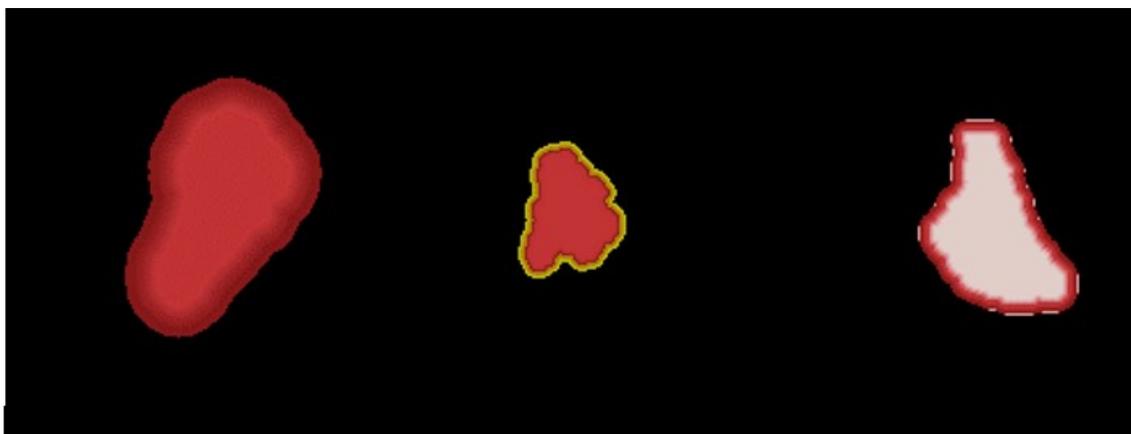


**A)**  
**Média:**  
 74,264%  
**Desvio padrão:**  
 43,87%

**B)**  
**Média:**  
 77,205%  
**Desvio padrão:**  
 42,10%

**C)**  
**Média:**  
 80,882%  
**Desvio padrão:**  
 39,46%

Fonte: O autor (2024).

**Figura 5.3:** Grau de acurácia quanto à lesões malignas.

**A)**  
**Média:**  
**86,764%**  
**Desvio padrão:**  
**34,01%**

**B)**  
**Média:**  
**87,500%**  
**Desvio padrão:**  
**33,19%**

**C)**  
**Média:**  
**87,500%**  
**Desvio padrão:**  
**33,19%**

Fonte: O autor (2024).

**Tabela 5.1:** A acurácia dos campos receptivos em função da classe.

Classe	Ordem dos campos receptivos	Acurácia (%)
Cisto	1	84,55 % ± 36,26 %
	2	87,50 % ± 33,19 %
	3	88,23 % ± 32,33%
Lesão Benigna	1	74,26 % ± 43,87 %
	2	81,61 % ± 38,87 %
	3	82,35 % ± 38,26 %
Lesão Maligna	1	87,50 % ± 33,19 %
	2	88,70 % ± 32,33 %
	3	89,70 % ± 30,50 %

Fonte: O autor (2024).

**Tabela 5.2:** Matriz de confusão dos campos receptivos em função da classe.

Classe	Ordem dos campos receptivos		C	CC
Cisto	1	C	<b>48,39 %</b>	4,76 %
		CC	51,61 %	<b>95,24 %</b>
	2	C	<b>58,06 %</b>	3,81 %
		CC	47,94 %	<b>96,19 %</b>
	3	C	<b>54,84 %</b>	1,90 %
		CC	45,16 %	<b>98,10 %</b>
Lesão Benigna	1	C	<b>55,10 %</b>	14,94 %
		CC	44,90 %	<b>85,06 %</b>
	2	C	<b>67,35 %</b>	10,34 %
		CC	32,65 %	<b>89,66 %</b>
	3	C	<b>71,43 %</b>	11,49 %
		CC	28,57 %	<b>88,51 %</b>
Lesão Maligna	1	C	<b>60,61 %</b>	3,88 %
		CC	39,39 %	<b>96,12 %</b>
	2	C	<b>57,58 %</b>	1,94 %
		CC	42,42 %	<b>98,06 %</b>
	3	C	<b>66,67 %</b>	2,91 %
		CC	33,33 %	<b>97,09 %</b>

Fonte: O autor (2024).

nhos proporcionam insights valiosos sobre a contribuição específica de cada um para a eficácia global do modelo. Essa abordagem detalhada permite uma compreensão mais profunda das nuances do processo de reconhecimento de padrões e destaca a relevância dos neurônios autoexplicativos na camada escondida.

A Tabela 5.2 demonstra as matrizes de confusão dos campos receptivos (máscaras), apresentados na Tabela 5.1 em termos percentuais. A matriz de confusão é importante para verificar a qualidade do aprendizado supervisionado. Na Tabela 5.2, C. e CC. são abreviações de Classe e Contra-Classe visto que o método de treinamento é um-contratodos. As classes desejadas estão dispostas no rótulo vertical, enquanto as contra-classes estão no rótulo horizontal. Na matriz de confusão, a diagonal principal é ocupada pelos casos em que a classe obtida coincide com a classe esperada, denominados casos positivos verdadeiros. Portanto um bom classificador tem a diagonal principal ocupada por valores altos e os outros elementos têm valores baixos.

A Tabela 5.2 exibe as principais diagonais enfatizadas em negrito. Em relação a Cisto, o primeiro campo receptivo classificou erroneamente, em média, 4,76 % dos casos como cistos quando eram casos de outras classes (lesão benigna, lesão maligna e paciente sem lesão). Seguindo o mesmo raciocínio, houve uma classificação média de 51,61 % dos casos da contra-classes quando se tratavam de pacientes com cisto.

Ainda com relação à Tabela 5.2, a sensibilidade e a especificidade referem-se à capacidade do campo receptivo (máscara) reconhecer amostras da classe e contra-classe, respectivamente. O trabalho proposto apresenta a matriz de confusão em termos percentuais para facilitar a interpretação da sensibilidade e da especificidade. Em síntese, a sensibilidade e a especificidade são apresentadas na própria matriz de confusão, descrita na Tabela 5.2. Por exemplo, o primeiro campo receptivo atrelado a cisto tem uma média de 38,70% com relação à sensibilidade e aos verdadeiros positivos. Seguindo o mesmo raciocínio, essa mesma máscara obtém, em média, 96,19 % para a especificidade e os verdadeiros negativos.

É importante apresentar a matriz de confusão em termos percentuais. Isso permite inferir grande parte das métricas relacionadas à classificação estatística. Por

exemplo, métricas como: prevalência, precisão, MCC <sup>1</sup>, FM <sup>2</sup>, curva ROC <sup>3</sup> e curva AUC <sup>4</sup> são derivados da matriz de confusão. Há dezenas de métricas que podem ser extraídas da matriz de confusão apresentada na Tabela 5.2.

## 5.1 Reconhecimento de Padrão com Pesos Ponderados

Acurácia diz respeito à capacidade do classificador detectar amostras tanto da classe quanto da contra-classe. Acurácia é diferente de precisão. Precisão desprivilegia a contra-classe. Por exemplo, a precisão assume papel fundamental na área de engenharia biomédica. A meta é detectar todos os pacientes com alteração do parênquima mamário (ex. câncer de mama), mesmo que, eventualmente, alguma paciente sadia seja erroneamente diagnosticada como enferma. As vantagens são enormes visto que a detecção precoce do câncer, em exames de imagens, é essencial de modo a se aumentar as chances de recuperação da paciente (de Lima et al.,2021). Para cada detecção de paciente com câncer, em exame de imagem, são necessários milhares de exames em pacientes saudáveis. Nesse contexto, aumentar a precisão em detrimento da acurácia é essencial de modo a não deixar de se identificar os pacientes com câncer. Isto é válido particularmente em países subdesenvolvidos e emergentes, nos quais há uma dificuldade, por grande parte da população, em ter acesso a serviços públicos de saúde tais como hospitais e clínicas de exames laboratoriais (Kremer e Glennerster,2011). Ainda como agravante, há uma péssima distribuição de renda (Alvaredo e Gasparini,2015), onde uma grande parcela da sociedade não pode custear seus atendimentos em clínicas e hospitais particulares. Também como fator complicador, a maioria dos habitantes reside em bolsões de pobreza localizados nas periferias dos grandes centros urbanos dos países emergentes (IBGE,2023), bem como, grande parte da população não tem residência

---

<sup>1</sup>MCC: *The Matthews correlation coefficient.*

<sup>2</sup>FM: *Fowlkes–Mallows index.*

<sup>3</sup>ROC: *Receiver Operating Characteristic.*

<sup>4</sup>AUC: *Area Under the Curve.*

fixa (Paulino,2014;Reydon et al.,2015). Conseqüentemente, torna-se impraticável o agendamento de uma nova consulta ou exames de acompanhamento. A péssima distribuição de renda, os bolsões de pobreza e a sobrecarga dos serviços públicos de saúde são problemas recorrentes das nações em desenvolvimento (OMS, 2010), (FAO, 2023).

Pode ser uma oportunidade única o exame de imagem termográfico em uma paciente de um país emergente. Como agravante, uma parcela significativa dos atendimentos realizados, nos serviços públicos de saúde, ocorrem nos estágios terminais das doenças (França et al.,2014). Uma proporção significativa de óbitos relatados como causas mal definidas pode ter sido decorrente da falta de tempo hábil para investigação e certificação das causas da morte (França et al.,2014).

Em síntese, prestigiar a precisão, em detrimento da acurácia, é fundamental em aplicações biomédicas quando empregadas em países emergentes. Nesse cenário, não se pode deixar de detectar a paciente com câncer mesmo que isso ocasione em falsos positivos, ou mesmo, pacientes sadias erroneamente classificadas como enfermas. Em engenharia biomédica, a desvantagem de aumentar a precisão em detrimento da acurácia é aceitável. A paciente teria um trauma psicológico temporário enquanto não for realizado o exame de biópsia, visando a confirmação ou refutação do diagnóstico prévio. Recomenda-se que o diagnóstico positivo, através de exames de imagem, não seja divulgado à paciente por se tratar de um resultado imaturo pendente de confirmação.

A presente inteligência artificial auto explicável investiga a melhor maneira de determinar o espaço  $n$ -dimensional de modo a obter uma taxa de precisão quanto à classe alvo.  $n$  diz respeito à quantidade de neurônios de entrada. A presente seção visa aumentar a precisão diante das classes contendo amostras desbalanceadas.

O trabalho proposto estende a obra de (Zong et al., 2013) e cria uma matriz de pesos nomeada de porcentagem, formalizada na Eq. (5.1).  $v$  diz respeito aos dados de treinamento. Ao considerar  $P_{tt}$  matriz bidimensional, logo as posições  $tt$  denotam a matriz diagonal, onde  $t = 1, \dots, v$ . O símbolo  $:=$  significa a quantidade de casos por

classe  $\zeta$  é a quantidade de classes (ex. classe *versus* contra-classe).

$$P_{tt} = \frac{1}{:= X_{\zeta}} \quad (5.1)$$

Ao atribuir pesos ponderados às classes, a matrizes dos pesos de saída  $\beta$  está de acordo com a Eq. (5.2).  $I$  é a matriz identidade.  $P$  é a matriz de pesos ponderados em função das classes em quantidades desbalanceadas, descrita na Eq. (5.1).  $^T$  significa matriz transposta.

$$\beta = H \cdot \frac{P \cdot H^T \cdot H + I_{vv}}{P \cdot T^T} \quad (5.2)$$

A Tabela 5.3 diz respeito à acurácia dos campos receptivos descritos na Figura 5.1, a Figura 5.2 e a Figura 5.3. Utilizando o método um-contra-todos, a acurácia dos campos receptivos foi examinada em relação à classe alvo em toda a base. Na contra-classe, estavam presentes todas as demais, inclusos os casos de termogramas sem lesão. Cada campo receptivo foi submetido a experimentos individuais, onde a camada escondida, composta pelos neurônios autoexplicativos apresentados na seção 4.2, foi utilizada em cada reconhecimento de padrão.

A Tabela 5.3 apresenta os campos receptivos(máscaras) em termos percentuais. Já a Tabela 5.4 demonstra as matrizes de confusão dos campos receptivos (máscaras), exibindo as principais diagonais enfatizadas em negrito. Em relação a Cisto, o primeiro campo receptivo classificou erroneamente, em média, 34,29 % dos casos como cistos quando eram casos de outras classes (lesão benigna, lesão maligna e paciente sem lesão). Seguindo o mesmo raciocínio, houve uma classificação média de 22,58 % dos casos da contra-classes quando se tratavam de pacientes com cisto (falso negativo).

Observa-se que o propósito dos pesos ponderados não é aumentar a acurácia da solução, mas sim aprimorar a precisão, visando a redução da quantidade de falsos

**Tabela 5.3:** A acurácia dos campos receptivos em função da classe, com pesos ponderados.

Classe	Ordem dos campos receptivos	Acurácia (%)
Cisto	1	68,38 % ± 46,67 %
	2	67,64 % ± 46,95 %
	3	64,70 % ± 47,96%
Lesão Benigna	1	64,70 % ± 47,96 %
	2	66,91 % ± 47,22 %
	3	66,91 % ± 47,22 %
Lesão Maligna	1	72,05 % ± 45,03 %
	2	70,58 % ± 45,73 %
	3	77,94 % ± 41,61 %

Fonte: O autor (2024).

**Tabela 5.4:** Matriz de confusão dos campos receptivos em função da classe, com pesos ponderados.

Classe	Ordem dos campos receptivos		C	CC
Cisto	1	C	<b>77,42 %</b>	34,29 %
		CC	22,58 %	<b>65,71 %</b>
	2	C	<b>83,87 %</b>	37,14 %
		CC	16,13 %	<b>62,86 %</b>
	3	C	<b>87,10 %</b>	41,90 %
		CC	12,90 %	<b>58,10 %</b>
Lesão Benigna	1	C	<b>69,39 %</b>	37,93 %
		CC	30,61 %	<b>62,07 %</b>
	2	C	<b>69,39 %</b>	34,48 %
		CC	30,61 %	<b>65,52 %</b>
	3	C	<b>73,47 %</b>	36,78 %
		CC	26,53 %	<b>63,22 %</b>
Lesão Maligna	1	C	<b>72,73 %</b>	28,16 %
		CC	27,27 %	<b>71,84 %</b>
	2	C	<b>72,73 %</b>	30,10 %
		CC	27,27 %	<b>69,90 %</b>
	3	C	<b>84,85 %</b>	24,27 %
		CC	15,15 %	<b>75,73 %</b>

Fonte: O autor (2024).

negativos. Ao comparar a abordagem original, conforme demonstrado na Tabela 5.2, com a atual abordagem que incorpora pesos ponderados, é evidente que os falsos negativos foram significativamente reduzidos de 51,61 % para 22,58 % em relação ao primeiro campo receptivo de cisto. No cenário mais otimizado, apenas 12,90 % das pacientes afetadas por cisto não foram identificadas pela presente inteligência artificial autoexplicativa, utilizando o terceiro campo receptivo desenvolvido para cistos.

## 5.2 Discussão

A inteligência artificial auto explicável autoral foi capaz de obter acurácias tão elevadas quanto modelo do estado-da-arte baseado em *Deep Learning*. Adicionalmente, acurácias providas por uma inteligência artificial auto explicável contém a confiança e interpretabilidade dos resultados obtidos. A IA autoral alcança altos níveis de acurácia e, ao mesmo tempo, é capaz de explicar de maneira compreensível o raciocínio por trás de suas decisões. Uma IA auto explicável facilita a identificação de possíveis vieses no modelo ou erros sistemáticos. Isso é crucial para garantir que o sistema não esteja tomando decisões discriminatórias ou baseadas em padrões indesejados.

A explicabilidade torna a IA mais aceitável para usuários e profissionais que podem resistir à adoção de modelos de aprendizado de máquina devido à opacidade em suas decisões. A compreensibilidade aumenta a aceitação e a confiança na tecnologia. Modelos auto explicáveis não apenas fornecem resultados acurados, mas também oferecem *insights* sobre as relações causais nos dados. Isso é valioso para entender as variáveis que mais influenciam as decisões do modelo.

Em setores regulamentados, a capacidade de explicar decisões pode ser um requisito legal. Modelos auto explicáveis facilitam o cumprimento de regulamentações e normas éticas. A interpretabilidade permite uma colaboração mais eficaz entre humanos e máquinas, especialmente em tarefas complexas onde a expertise humana é valiosa. Em resumo, a combinação de alta acurácia e explicabilidade em uma IA fortalece sua utilidade prática, confiabilidade e aceitação em diversos contextos, promovendo uma integração mais efetiva e ética da inteligência artificial na sociedade.

## Capítulo 6

### Conclusão

O estudo foi concebido com o objetivo primordial de melhorar as perspectivas de recuperação para pacientes diagnosticados com câncer de mama. A intenção é contribuir significativamente para que essa doença deixe de ocupar as primeiras posições nos índices de mortalidade da população brasileira. No contexto específico do câncer de mama, a proposta deste projeto é de contribuir no diagnóstico precoce e reduzir a necessidade de cirurgias mutilantes, como a mastectomia, quando não forem estritamente indispensáveis. Almeja-se, portanto, que o sistema desenvolvido seja incorporado à rede hospitalar, desempenhando um papel crucial na identificação e interpretação de lesões mamárias. O impacto desejado é que a eficiência e precisão dos exames mamários se tornem menos dependentes da interpretação subjetiva e da experiência individual do profissional examinador. Além disso, espera-se que os resultados desta pesquisa sejam considerados nas próximas atualizações do documento de consenso do Ministério da Saúde para o câncer de mama.

O diagnóstico por imagem é desafiador devido à variabilidade dos casos e ao volume de dados. Para melhorar o diagnóstico, são aplicadas técnicas de processamento de imagens que identificam objetos com precisão computacional. Porém a busca por configurações ideais para essas técnicas é complexa e requer supercomputadores devido ao grande espaço de exploração. Embora as redes neurais profundas (*Deep Learning*) sejam usadas no estado-da-arte para reconhecer padrões em imagens médicas, elas têm desvantagens como os longos tempos de treinamento e a difi-

culdade em explicar suas decisões devido aos seus milhões de parâmetros treináveis. Essas limitações podem ser superadas com o uso de técnicas de aprendizado extremo, que são computacionalmente eficientes e mais explicáveis. O projeto propõe empregar o aprendizado extremo na detecção e classificação de lesões em imagens de termografia. A meta é tornar o aplicativo capaz de explicar seu funcionamento e diagnósticos de forma inteligente e convincente para especialistas médicos.

A ênfase na inteligência artificial auto explicável é fundamental, pois assegura que os avanços acadêmicos não fiquem restritos. Caso uma ferramenta computacional, mesmo sendo acurada, apresente limitações em explicar seu próprio funcionamento, ela poderá ser descartada em favor de métodos mais tradicionais. Este compromisso com a transparência e compreensão do sistema reflete a busca por soluções tecnológicas que sejam não apenas eficazes, mas também acessíveis e compreensíveis. Este projeto sustenta que a mera funcionalidade correta de uma técnica computacional não é suficiente. É fundamental que os mecanismos tenham a capacidade de explicar o próprio processo decisório, proporcionando ao usuário confiança plena nas decisões do sistema.

De maneira sistemática, a técnica inteligente autoral será submetida a periódicos e congressos de alto impacto. Adicionalmente, o projeto buscará o registro de patentes tanto para o fluxo geral do projeto como para possíveis características autorais extraídas das imagens biomédicas. A expectativa é que o estado de Pernambuco assumira uma posição proeminente na prevenção e detecção automatizada de cânceres de mama, proporcionando uma abordagem explicável e confiável.

## 6.1 Dificuldades Encontradas

Durante a pesquisa, encontramos alguns obstáculos, como a baixa resolução de algumas imagens do banco de dados. Nem todas as imagens foram capturadas com a mesma resolução, e, por essa razão, tais imagens foram removidas no pré-processamento para não comprometer a eficiência e acurácia do modelo.

Outro desafio foi a possibilidade de desenvolver um modelo 3D, já que havia

imagens capturadas de diferentes ângulos. Além disso, as imagens estavam desordenadas e não tinham sido obtidas imagens de todas as posições necessárias de algumas pacientes. Para evitar uma redução drástica do conjunto de dados, optou-se por não seguir com essa abordagem.

Esses obstáculos destacam a importância de ter um banco de dados de alta qualidade e bem organizado para melhorar os resultados dos modelos de aprendizado de máquina. Futuras pesquisas podem focar na padronização das imagens coletadas e na organização dos dados para facilitar o desenvolvimento de modelos mais complexos e precisos. Outrossim, técnicas de interpolação e reconstrução de imagens poderiam ser exploradas para lidar com imagens de baixa resolução ou ausentes, permitindo a criação de modelos 3D mais completos e detalhados.

## 6.2 Trabalhos Futuros

No desenvolvimento dessa pesquisa, dois aspectos despertaram o interesse em novas pesquisas:

- A ideia de aprimorar o pré-processamento de imagens para torná-lo mais eficiente. Ao otimizar os métodos envolvidos no pré-processamento, espera-se não apenas reduzir significativamente o tempo de processamento, mas também melhorar a qualidade das imagens resultantes. Isso pode incluir técnicas avançadas de filtragem, remoção de ruído, normalização de intensidade, e realce de bordas. A melhoria dessas técnicas pode levar a uma análise mais precisa e rápida das imagens subsequentes. Ao alcançarmos uma maior precisão e acurácia no pré-processamento, os modelos de aprendizado de máquina e de reconhecimento de padrões podem operar de maneira mais eficaz, resultando em diagnósticos mais confiáveis e decisões mais informadas.
- Outra possível linha de pesquisa seria o desenvolvimento da computação afetiva para auxiliar a máquina a explicar seus diagnósticos aos especialistas. A computação afetiva poderia tornar as interações mais intuitivas e empáticas,

facilitando a compreensão das informações fornecidas pela máquina. Com essa tecnologia, a máquina poderia fornecer explicações detalhadas e técnicas para especialistas experientes, enquanto apresentaria informações de maneira mais simplificada e acessível para profissionais menos familiarizados com o sistema. Esse nível de personalização não só melhoraria a usabilidade do programa, mas também aumentaria a confiança dos especialistas nas decisões automatizadas, promovendo uma integração mais eficaz da inteligência artificial no ambiente clínico.

# Referências

- Alvaredo, F. e Gasparini, L. (2015). Chapter 9 - recent trends in inequality and poverty in developing countries. In Atkinson, A. B. e Bourguignon, F., editors, *Handbook of Income Distribution*, volume 2 of *Handbook of Income Distribution*, páginas 697–805. Elsevier.
- Araújo, M. C., Lima, R. C., e de Souza, R. M. (2014). Interval symbolic feature extraction for thermography breast cancer detection. *Expert Systems with Applications*, 41(15):6728–6737.
- Azevedo, W. W., Lima, S. M. L., Fernandes, I. M. M., Rocha, A. D. D., Cordeiro, F. R., da Silva-Filho, A. G., e dos Santos, W. P. (2015a). *Fuzzy Morphological Extreme Learning Machines to detect and classify masses in mammograms*.
- Azevedo, W. W., Lima, S. M. L., Fernandes, I. M. M., Rocha, A. D. D., Cordeiro, F. R., da Silva-Filho, A. G., e dos Santos, W. P. (2015b). *Morphological extreme learning machines applied to detect and classify masses in mammograms*.
- Azevedo da Silva, W. W., Araújo de Santana, M., Guilhermino da Silva Filho, A., Lopes de Lima, S. M., e Pinheiro dos Santos, W. (2021). *Chapter 3 - Morphological extreme learning machines applied to the detection and classification of mammary lesions*. Hybrid Computational Intelligence for Pattern Analysis and Understanding. Academic Press.
- Ba, J. e Caruana, R. (2014). Do deep nets really need to be deep? In Ghahramani, Z., Welling, M., Cortes, C., Lawrence, N., e Weinberger, K., editors, *Advances in Neural Information Processing Systems*, volume 27. Curran Associates, Inc.
- BI-RADS. (2003). *BI-RADSTM(Breast Imaging Reporting and Data System - Sistema de Diagnóstico e Relatório para Imagens de Mama)*.
- Borchardt, T. B., Conci, A., Lima, R. C., Resmini, R., e Sanchez, A. (2013). -. *Signal Processing*, 93(10):2785–2803. Signal and Image Processing Techniques for Detection of Breast Diseases.

- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- de Lima, S. M., da Silva-Filho, A. G., e dos Santos, W. P. (2016). *Detection and classification of masses in mammographic images in a multi-kernel approach*, volume 134.
- de Lima, S. M. L., da Silva-Filho, A. G., e dos Santos, W. P. (2014). A methodology for classification of lesions in mammographies using zernike moments, elm and svm neural networks in a multi-kernel approach. páginas 988–991.
- de Lima, S. M. L., Silva, H. K. d. L., Luz, J. H. d. S., Lima, H. J. d. N., Silva, S. L. d. P., de Andrade, A. B. A., e da Silva, A. M. (2021). *Artificial intelligence-based antivirus in order to detect malware preventively*, volume 10.
- do Nascimento, M. Z., Martins, A. S., Neves, L. A., Ramos, R. P., Flores, E. L., e Carrijo, G. A. (2013). Classification of masses in mammographic image using wavelet domain features and polynomial classifier. *Expert Systems with Applications*, 40(15):6213–6221.
- dos Santos, M. M., da Silva Filho, A. G., e dos Santos, W. P. (2019). *Deep convolutional extreme learning machines: Filters combination and error model validation*, volume 329.
- D’Orsi CJ, Sickles EA, M. E. M. E. e. a. (2013). *ACR BI-RADS® Atlas, Breast Imaging Reporting and Data System*. Reston, VA. American College of Radiology.
- Ekici, S. e Jawzal, H. (2020). Breast cancer diagnosis using thermography and convolutional neural networks. *Medical Hypotheses*, 137:109542.
- FAO (2023). Food and agriculture organization of the united nations - organização das nações unidas para alimentação e agricultura)developing country regions. .
- França, E. B., da Cunha, C. C., Vasconcelos, A. M. N., Escalante, J. J. C., de Abreu, D. X., de Lima, R. B., e de Moraes Neto, O. L. (2014). Investigation of ill-defined causes of death: assessment of a program’s performance in a state from the northeastern region of brazil. *Rev Bras Epidemiol*, 17(1):119–134.
- Gefen, S., Tretiak, O., Piccoli, C., Donohue, K., Petropulu, A., Shankar, P., Dumane, V., Huang, L., Kutay, M., Genis, V., Forsberg, F., Reid, J., e Goldberg,

B. (2003). *ROC analysis of ultrasound tissue characterization classifiers for breast cancer diagnosis*, volume 22.

Heath, M. D. e Bowyer, K. W. (2000). Mass detection by relative image intensity. *5th International Conference on Digital Mammography. Toronto, Canada, June. Medical Physics Publishing (Madison, WI), ISBN 1-930524-00-5.*

Huang, G.-B., Chen, Y.-Q., e Babri, H. (2000). Classification ability of single hidden layer feedforward neural networks. *IEEE Transactions on Neural Networks*, 11(3):799–801.

Huang, G.-B., Zhou, H., Ding, X., e Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2):513–529.

IARC (2022). Global cancer observatory. world health organization. globocan, 2022. <https://gco.iarc.who.int/today/en/fact-sheets-populationsregions>.

IBGE (2023). Instituto brasileiro de geografia e estatística: Domicílios particulares ocupados em aglomerados subnormais e média de moradores em domicílios particulares ocupados em aglomerados subnormais. <https://sidra.ibge.gov.br/tabela/3380>.

INCA (2004). Inca: Controle do câncer de mama - documento de consenso. *Rev Brasil Cancerologia*, v. 50, n. 2, p. 77-90.

INCA (2011). Fatores prognósticos no câncer da mama feminina. <http://www.inca.gov.br/rbc/n48/v01/pdf/revisao.pdf>.

INCA (2023). Dados e números sobre câncer de mama - relatório anual 2023. <https://www.inca.gov.br/publicacoes/relatorios/dados-e-numeros-sobre-cancer-de-mama-relatorio-anual-2023>.

Juhl, J. H., Crummy, A. B., e Kuhlman, J. E. (2014). *Interpretação Radiológica*. Guanabara, 7. edição.

Karim, C. N., Mohamed, O., e Ryad, T. (2018). A new approach for breast abnormality detection based on thermography. *Medical Technologies Journal*.

Kremer, M. e Glennerster, R. (2011). Chapter four - improving health in developing countries: Evidence from randomized evaluations. In Pauly, M. V., McGuire, T. G., e Barros, P. P., editors, *Handbook of Health Economics*, volume 2 of *Handbook of Health Economics*, páginas 201–315. Elsevier.

- Leucht, W. e Leucht, D. (1996). *Teaching Atlas of Breast Ultrasound*. Georg Thieme Verlag, Thieme Medical Publishers, 2. edição.
- Lima, S. M. L., Silva, S. H. M. T., Pinheiro, R. P., Souza, D. M., Lopes, P. G., de Lima, R. D. T., de Oliveira, J. R., Monteiro, T. d. A., Fernandes, S. M. M., Albuquerque, E. d. Q., Silva, W. W. A. d., e dos Santos, W. P. (2023). Next-generation antivirus endowed with web-server sandbox applied to audit fileless attack. *Soft Computing*, 27(3):1471–1491.
- Lima, S. M. L., Silva-Filho, e Santos, W. P. (2020). *Morphological Decomposition to Detect and Classify Lesions in Mammograms*. In: Wellington Pinheiro dos Santos; Maíra Araújo de Santana; Washington Wagner Azevedo da Silva. (Org.). *Understanding a Cancer Diagnosis*. Disponível em: <https://novapublishers.com/shop/understanding-a-cancer-diagnosis/>.
- Lima, S. M. L., Silva-Filho, A. G., e Dos Santos, W. P. (2014). *A methodology for classification of lesions in mammographies using Zernike Moments, ELM and SVM Neural Networks in a multi-kernel approach*. doi: <https://doi.org/10.1109/SMC.2014.6974041>.
- Macedo, M., Santana, M., dos Santos, W. P., Menezes, R., e Bastos-Filho, C. (2021). Breast cancer diagnosis using thermal image analysis: A data-driven approach based on swarm intelligence and supervised learning for optimized feature selection. *Applied Soft Computing*, 109.
- Manoel, W. J.; Mülbeier, D. F. M. V. F. D. e. a. (2011). Câncer de mama e gravidez: relato do caso. *Rev Bras Mastologia*, v. 21, n. 1, p. 42-45.
- Martins, C. (2013). Incidência oblíqua médio-lateral (oml): Mamografia - oblíquas súpero-medial e Ínfero-lateral. <https://radiologia-tec.blogspot.com/2013/02/incidencia-obliqua-medio-lateral-oml.html>.
- Morales-Cervantes, A., Kolosovas-Machuca, E. S., Guevara, E., Maruris Reducindo, M., Bello Hernández, A. B., Ramos García, M., e González, F. J. (2018). An automated method for the evaluation of breast cancer using infrared thermography. *EXCLI J*, 17:989–998.
- Niu, K. e Tian, C. (2022). Zernike polynomials and their applications. *Journal of Optics*, 24(12):123001.
- OMS (2010). Organização mundial da saúde: Improving the quality and use of birth, death and cause-of-death information: guidance for a standards-based review of country practices. ISBN: 9789241547970.

- Papalia, D., Olds, S., e Feldman, R. (2008). *Human Development*. The McGraw-Hill Companies, 11<sup>a</sup> edição, pág. 162.
- Patterson, D. A., H. J. L. (2013). *Computer Organization and Design*. Morgan Kaufmann, 5. edição.
- Paulino, E. T. (2014). The agricultural, environmental and socio-political repercussions of brazil's land governance system. *Land Use Policy*, 36:134–144.
- Pereira, J.M.S., Santana, M.A., Gomes, e J.C. (2001). Feature selection based on dialectics to support breast cancer diagnosis using thermographic images. *Res. Biomed. Eng.*37, 485–506.
- Pereira, J. M. S., Santana, M. A., Gomes, J. C., de Freitas Barbosa, V. A., Valença, M. J. S., de Lima, S. M. L., e dos Santos, W. P. (2021). Feature selection based on dialectics to support breast cancer diagnosis using thermographic images. *Res. Biomed. Eng.* 37, página 485–506.
- Pereira, J. M. S. et al.. (2020). *Method for Classification of Breast Lesions in Thermographic Images Using ELM Classifiers*. In: SANTOS, W.P.; SANTANA, M.A.; SILVA, W.W.A. *Understanding a Cancer Diagnosis*. Disponível em: <https://novapublishers.com/shop/understanding-a-cancer-diagnosis/>.
- Pinheiro, R. P., Lima, S. M. L., Souza, D. M., Silva, S. H. M. T., Lopes, P. G., de Lima, R. D. T., de Oliveira, J. R., Monteiro, T. d. A., Fernandes, S. M. M., Albuquerque, E. d. Q., Silva, W. W. A. d., e Santos, W. P. d. (2022). Antivirus applied to jar malware detection based on runtime behaviors. *Scientific Reports*, 12(1):1945.
- Quimioral, S. (2018). <http://www.quimioral.com.br>.
- Reydon, B. P., Fernandes, V. B., e Telles, T. S. (2015). Land tenure in brazil: The question of regulation and governance. *Land Use Policy*, 42:509–516.
- Santana, M.A., de Freitas Barbosa, V.A., e de Cássia Fernandes de Lima. (2022a). Combining deep-wavelet neural networks and support-vector machines to classify breast lesions in thermography images. *Health Technol.* 12.
- Santana, M.A., dos Santos, e W.P. (2022b). A deep-wavelet neural network to detect and classify lesions in mammographic images. *Res. Biomed. Eng.*38.
- 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., e Santos, W. P. d. (2018). Breast cancer diagnosis based on mammary thermography and extreme learning machines. *Research on Biomedical Engineering*, 34(1):45–53.

Shalev-Shwartz, S. e Shai Ben-David, J. (2014). *Understanding Machine Learning: From Theory To Algorithms*. Cambridge University Press.

Tahmasbi, A., Saki, F., e Shokouhi, S. B. (2011). Classification of benign and malignant masses based on zernike moments. *Computers in Biology and Medicine*, 41(8):726–735.

Taylor, K. J. W., Merritt, C., Piccoli, C., Schmidt, R., Rouse, G., Fornage, B., Rubin, E., Georgian-Smith, D., Winsberg, F., Goldberg, B., e Mendelson, E. (2002). Ultrasound as a complement to mammography and breast examination to characterize breast masses. *Ultrasound Med Biol*, 28(1):19–26.

Turing, A. M. (1950). Computing machinery and intelligence, mind. *Issue 236, October 1950, Pages 433–460, LIX*.

Xiang, C., Ding, S., e Lee, T. H. (2005). Geometrical interpretation and architecture selection of mlp. *IEEE Transactions on Neural Networks*, 16(1):84–96.

Zong, W., Huang, G.-B., e Chen, Y. (2013). Weighted extreme learning machine for imbalance learning. *Neurocomputing*, 101:229–242.

## Apêndice A

# Descrição de Características de Formas e de Texturas

A seguir, são descritas as características de formas e de texturas dos achados.

**Tabela A.1:** Descrição de Características de Formas e de Texturas

Atributo	Descrição
Cor: EMQ entre a máscara e a região ativa	<p>Uma medida de erro entre as cores de um padrão RGB da máscara decomposta e autoremodelada durante a execução, em relação à região ativa da imagem.</p> <p>Isso sugere uma métrica que calcula o erro médio quadrático entre as cores desses padrões em diferentes regiões da imagem.</p>
A quantidade de decomposição da máscara	<p>Uma proporção da quantidade de pixels remanescentes na máscara decomposta em relação ao seu tamanho original. Fornecendo uma medida da preservação ou perda de informação durante o processo de decomposição da máscara.</p>
Descritor de forma: Área	<p>Número real de pixels na região, representado como uma escalar.</p>
Descritor de forma: Centroide	<p>Centro de massa da região, devolvido como um vetor 1 por Q, em que Q é a dimensionalidade da imagem. O primeiro elemento da centroide é a coordenada horizontal do centro de massa. O segundo elemento é a coordenada vertical. Todos os outros elementos da centroide estão por ordem de dimensão.</p>
Descritor de forma: Caixa delimitadora(1)	<p>Usada para calcular a caixa delimitadora de um conjunto de pontos ou objetos em uma imagem. Essa caixa delimitadora é um retângulo que envolve completamente os pontos ou objetos. A função retorna as coordenadas da caixa delimitadora, geralmente na forma [xmin, ymin, largura, altura], onde Caixa delimitadora(1) representa somente xmin.</p>
Descritor de forma: Caixa delimitadora(2)	<p>Usada para calcular a caixa delimitadora de um conjunto de pontos ou objetos em uma imagem. Essa caixa delimitadora é um retângulo que envolve completamente os pontos ou objetos. A função retorna as coordenadas da caixa delimitadora, geralmente na forma [xmin, ymin, largura, altura], onde Caixa delimitadora(2) representa somente ymin.</p>

Atributo	Descrição
Descritor de forma: Caixa delimitadora(3)	<p>Usada para calcular a caixa delimitadora de um conjunto de pontos ou objetos em uma imagem.</p> <p>Essa caixa delimitadora é um retângulo que envolve completamente os pontos ou objetos.</p> <p>A função retorna as coordenadas da caixa delimitadora, geralmente na forma [xmin, ymin, largura, altura], onde Caixa delimitadora(3) representa somente largura e altura.</p>
Descritor de forma: Caixa delimitadora(4)	<p>Usada para calcular a caixa delimitadora de um conjunto de pontos ou objetos em uma imagem.</p> <p>Essa caixa delimitadora é um retângulo que envolve completamente os pontos ou objetos.</p> <p>A função retorna as coordenadas da caixa delimitadora, geralmente na forma [xmin, ymin, largura, altura], onde Caixa delimitadora(4) representa somente a largura e a altura.</p>
Descritor de forma: Comprimento do eixo principal	<p>Comprimento (em pixels) do eixo maior da elipse que tem os mesmos segundos momentos centrais normalizados que a região, retornado como um escalar.</p>
Descritor de forma: Comprimento do eixo menor	<p>Comprimento (em pixels) do eixo menor da elipse que tem os mesmos segundos momentos centrais normalizados que a região, retornado como um escalar.</p>
Descritor de forma: Excentricidade	<p>Excentricidade da elipse que tem os mesmos segundos momentos que a região, devolvida como um escalar.</p> <p>A excentricidade é o rácio da distância entre os focos da elipse e o comprimento do seu eixo maior. O valor está compreendido entre 0 e 1 . Uma elipse cuja excentricidade é 0 é na realidade uma circunferência, enquanto uma elipse cuja excentricidade é 1 é um segmento de reta).</p>
Descritor de forma: Orientação	<p>Ângulo entre o eixo x e o eixo maior da elipse que tem os mesmos segundos momentos que a região, devolvido como um escalar.</p> <p>O valor está em graus, variando de -90 graus a 90 graus.</p>

Atributo	Descrição
Descritor de forma: Área Convexa	A "Área Convexa" se refere ao número de pixels na "Imagem Convexa", ou seja, na imagem que especifica o casco convexo da região de interesse, onde todos os pixels dentro do casco estão preenchidos (considerados como "ligados"). Essa área é retornada como um valor escalar.
Descritor de forma: Área preenchida	"Área preenchida" é a contagem do número de pixels ativos na imagem preenchida (Área preenchida), a qual especifica uma região com todos os pixels dentro do contorno preenchidos (ligados), retornada como um valor escalar.
Descritor de forma: Número de Euler	Calcula o número de regiões conectadas menos o número de buracos na região de interesse em uma imagem binária. Isso fornece informações sobre a topologia da região, ajudando a distinguir entre diferentes formas e estruturas presentes na imagem. Quanto maior o valor do número de Euler, mais complexa é a estrutura da região.
Descritor de forma: Extrema(1)	Coordenadas da esquerda da parte superior da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Extrema(2)	Coordenadas da direita da parte superior da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Extrema(3)	Coordenadas da parte superior da direita da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.

Atributo	Descrição
Descritor de forma: Extrema(4)	Coordenadas da parte inferior da direita da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Extrema(5)	Coordenadas da direita da parte inferior da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Extrema(6)	Coordenadas da esquerda da parte inferior da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Extrema(7)	Coordenadas da parte inferior da esquerda da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Extrema(8)	Coordenadas da parte superior da esquerda da caixa delimitadora que envolve a região de interesse em uma imagem. Isso permite determinar exatamente onde a região começa e termina na imagem, facilitando uma variedade de operações, como recorte, medição de posição e cálculo de tamanho da região.
Descritor de forma: Diâmetro equivalente	Diâmetro de um círculo com a mesma área que a região, devolvido como um escalar. Calculado como $\sqrt{4 \cdot \text{Área} / \pi}$ .
Descritor de forma: Solidez	Proporção dos pixels no casco convexo que também está na região, devolvida como um escalar. A solidez é calculada como $\text{Área} / \text{Área Convexa}$ .
Descritor de forma: Extensão	Rácio de pixels na região para pixels na caixa delimitadora total, devolvido como um escalar. Calculado como a Área dividida pela área da caixa delimitadora.
Descritor de forma: Lista dos índices dos pixels	Índices lineares dos pixels na região, devolvidos como um vetor de p elementos.

Atributo	Descrição
Descritor de forma: Lista dos pixels	Localizações dos píxeis na região, devolvidas como uma matriz $p$ por $Q$ . Cada linha da matriz tem a forma $[x \ y \ z \ \dots]$ e especifica as coordenadas de um pixel na região.
Descritor de forma: Perímetro	Distância à volta do limite da região devolvida como um escalar. Calcula-se o perímetro calculando a distância entre cada par de pixels adjacentes à volta do limite da região. Se a imagem contiver regiões não contíguas, o resultado será inesperado.
Descritor de forma: PerimeterOld	Distância à volta do limite da região devolvida como um escalar. Calcula-se o perímetro contando apenas os pixels de borda em torno do objeto, sem levar em conta as diagonais.
Texture descriptor: Entropia	A entropia é calculada com base na distribuição de intensidades de pixel na imagem. Uma imagem com alta entropia indica uma distribuição de intensidades mais uniforme ou uma imagem mais complexa, enquanto uma imagem com baixa entropia indica uma distribuição de intensidades mais concentrada ou uma imagem mais simples.
Texture descriptor: Contraste	Uma medida da variação dos níveis de cinza na imagem. Ela quantifica a diferença de intensidade entre os pixels adjacentes em uma determinada direção e distância na imagem. Quanto maior o contraste, maior é a diferença entre os valores de intensidade dos pixels vizinhos, indicando mudanças abruptas na textura da imagem.
Texture descriptor: Correlação	Uma medida da linearidade da relação entre os níveis de cinza na imagem. Ela quantifica o grau de correlação entre os valores de intensidade dos pixels em uma determinada direção e distância na imagem. A correlação varia de -1 a 1, onde valores próximos a 1 indicam uma forte correlação positiva (os pixels tendem a ter valores semelhantes) e valores próximos a -1 indicam uma forte correlação negativa (os pixels tendem a ter valores opostos). Um valor de correlação próximo a zero indica falta de correlação linear. Em termos de texturas, uma alta correlação pode indicar uma textura homogênea e regular, enquanto uma baixa correlação pode indicar uma textura mais complexa ou irregular.

<b>Atributo</b>	<b>Descrição</b>
Texture descriptor: Energia	A energia é uma medida de quão concentrada ou dispersa é a distribuição de intensidades de cinza na imagem. Quanto maior a energia, mais uniforme é a textura da imagem. Essa medida é útil para distinguir entre texturas uniformes e texturas com mudanças abruptas de intensidade.
Texture descriptor: Homogeneidade	Uma medida da uniformidade ou regularidade dos níveis de cinza na imagem. Ela quantifica o quão próximos os valores de intensidade dos pixels são dos outros. Quanto maior a homogeneidade, menor é a variação nos níveis de cinza entre os pixels vizinhos, indicando uma textura mais uniforme e regular na imagem.
Informação global de cor: Recorte manual	Quantidade de pixels eliminado através do recorte manual, descritos na subsecção 4.1.3
Informações globais sobre a cor: Roxo escuro	Histograma da faixa de cor roxo escuro
Informações globais sobre a cor: Roxo claro	Histograma da faixa de cor roxo claro
Informações globais sobre a cor: Azul escuro	Histograma da faixa de cor azul escuro
Informações globais sobre a cor: Azul claro	Histograma da faixa de cor azul claro
Informações globais sobre a cor: Verde	Histograma da faixa de cor verde
Informações globais sobre a cor: Amarelo	Histograma da faixa de cor amarelo
Informações globais sobre a cor: Vermelho	Histograma da faixa de cor vermelho
Informações globais sobre a cor: Branco	Histograma da faixa de cor branco