

JEFFERSON GOMES DO NASCIMENTO

USO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL,  
CORRELAÇÃO DE IMAGENS TÉRMICAS E DO CONCEITO  
DE IMPEDÂNCIA TÉRMICA VISANDO A ESTIMATIVA DA  
LOCALIZAÇÃO E DO TAMANHO DE TUMORES MAMÁRIOS



UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA MECÂNICA

JEFFERSON GOMES DO NASCIMENTO

**Tese** apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia.

Área de Concentração: Transferência de Calor e Mecânica dos Fluidos

Orientador: Prof. Dr. Gilmar Guimarães

**Uberlândia  
2022**

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

N244 Nascimento, Jefferson Gomes do, 1986-  
2022 USO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL, CORRELAÇÃO  
DE IMAGENS TÉRMICAS E DO CONCEITO DE IMPEDÂNCIA TÉRMICA  
VISANDO A ESTIMATIVA DA LOCALIZAÇÃO E DO TAMANHO DE  
TUMORES MAMÁRIOS [recurso eletrônico] / Jefferson Gomes  
do Nascimento. - 2022.

Orientador: Gilmar Guimarães.

Tese (Doutorado) - Universidade Federal de Uberlândia,  
Pós-graduação em Engenharia Mecânica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.te.2022.459>

Inclui bibliografia.

1. Engenharia mecânica. I. Guimarães, Gilmar, 1960-,  
(Orient.). II. Universidade Federal de Uberlândia. Pós-  
graduação em Engenharia Mecânica. III. Título.

CDU: 621

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:  
Gizele Cristine Nunes do Couto - CRB6/2091  
Nelson Marcos Ferreira - CRB6/3074



## UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Engenharia Mecânica  
Av. João Naves de Ávila, nº 2121, Bloco 1M, Sala 212 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902  
Telefone: (34) 3239-4282 - www.posmecanicaufu.com.br - secposmec@mecanica.ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Mecânica				
Defesa de:	Tese de Doutorado Acadêmico, nº 338, PPGEM				
Data:	29/08/2022	Hora de início:	09:00	Hora de encerramento:	12:40
Matrícula do Discente:	11823EMC006				
Nome do Discente:	Jefferson Gomes do Nascimento				
Título do Trabalho:	Uso de Técnicas de Inteligência Artificial, Correlação de Imagens Térmicas e do Conceito de Impedância Térmica visando a Estimativa da Localização e do Tamanho de Tumores Mamários				
Área de concentração:	Transferência de Calor e Mecânica dos Fluidos				
Linha de pesquisa:	Dinâmica dos Fluidos e Transferência de Calor				
Projeto de Pesquisa de vinculação:	PROBLEMAS INVERSOS APLICADOS EM ENGENHARIA BIOMECÂNICA, PROCESSOS DE FABRICAÇÃO E EM SUPERFÍCIE DE MATERIAIS				

Reuniu-se por meio de videoconferência a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Mecânica, assim composta: Professores Doutores: Marcus Antônio Viana Duarte - FEMEC/UFU; Solidônio Rodrigues Carvalho - FEMEC/UFU; Antonio Gilson Barbosa de Lima - UFCG; Saulo Guths -UFSC e Gilmar Guimarães - FEMEC/UFU, orientador do candidato.

Iniciando os trabalhos, o presidente da mesa, Dr. Gilmar Guimarães, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Gilmar Guimarães, Professor(a) do Magistério Superior**, em 29/08/2022, às 12:41, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Solidonio Rodrigues de Carvalho, Professor(a) do Magistério Superior**, em 29/08/2022, às 12:41, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Marcus Antonio Viana Duarte, Professor(a) do Magistério Superior**, em 29/08/2022, às 12:44, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Antonio Gilson Barbosa de Lima, Usuário Externo**, em 29/08/2022, às 12:44, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Saulo Guths, Usuário Externo**, em 29/08/2022, às 12:47, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



A autenticidade deste documento pode ser conferida no site [https://www.sei.ufu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3834956** e o código CRC **F2734420**.

---

# Agradecimentos

À Minha mãe Maria Marta Aparecida e ao meu pai Licomedes Gomes do Nascimento, por terem me concedido o dom da vida e por sempre me apoiarem em todas as decisões que tomei, pelo amor e carinho. Sempre depositaram suas confianças e dirigiram suas boas energias, pensamentos, orações, palavras e intensões em favor da concretização de um sonho;

Ao meu irmão Elvys Gomes do Nascimento, pelo incentivo, confiança, parceria e apoio;

À minha sobrinha Isadora Martins Gomes do Nascimento por ser uma pessoa incrível que alegria os dias da minha família;

Ao Prof. Dr. Gilmar Guimarães por compartilhar seus conhecimentos e por sempre acreditar em mim, pela orientação e inestimável apoio, materializados pelo interesse, amizade e respeito, sempre presentes em nosso trabalho;

Aos membros do Laboratório de Transferência de Calor: Modelagem e Experimento; Em especial aos amigos Alisson Augusto Azevedo Figueiredo e ao José Ricardo Ferreira Oliveira;

À Universidade Federal de Uberlândia e à Faculdade de Engenharia Mecânica pela oportunidade de realizar este Curso;

Aos órgãos de fomento pelo apoio financeiro através da bolsa de estudos;

A todos e todas que colaboraram de alguma forma no processo de construção dessa tese, muito obrigado!

NASCIMENTO, J. G., USO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL, CORRELAÇÃO DE IMAGENS TÉRMICAS E DO CONCEITO DE IMPEDÂNCIA TÉRMICA VISANDO A ESTIMATIVA DA LOCALIZAÇÃO E DO TAMANHO DE TUMORES MAMÁRIOS. 2022. 121 f. Tese de Doutorado, Universidade Federal de Uberlândia, Uberlândia, MG.

### Resumo

O câncer de mama possui a maior incidência e mortalidade na população feminina em todo o mundo. A detecção precoce e precisa do câncer de mama é uma parte crítica da estratégia para reduzir a mortalidade associada a esta doença tão comum. A mamografia é a técnica mais usada para a detecção precoce do câncer de mama, porém, possui várias limitações. Várias imagens são necessárias e existe uma forte dependência do médico ou técnico operador. Existe ainda uma forte dependência de um médico qualificado para identificar tumores nas imagens de raio-X. Além disso, a exposição ao raio-X ao longo da vida pode também induzir o aparecimento de tumores. Nesse projeto, propõe-se o desenvolvimento de técnicas baseadas na aplicação do método de impedância térmica e na detecção de inclusões baseada no uso de correlações de temperaturas superficiais da pele da mama para detectar a origem da fonte de calor (metabolismo anormal de um câncer). A ideia principal deste trabalho é usar o método da inteligência artificial, aprendizado profundo, técnica relacionada ao reconhecimento de características específicas em imagens para detecção de fontes de calor metabólica. Além da técnica proposta não ser invasiva ou causar dor à paciente, ela deve permitir o acesso a pessoas com deficiência ou baixa mobilidade, possuir baixo custo e usar tecnologias nacionais. A baixa sensibilidade aos tumores pequenos e profundos, normalmente existente em análises de temperaturas superficiais usando imagens térmicas é contornada com o uso do conceito de impedância térmica e técnicas de inteligência artificial, como o uso de aprendizado profundo (Deep learning). Apresentam-se nesse trabalho uma breve fundamentação teórica sobre redes neurais convolucionais, otimizadores, funções de ativação e os hiperparâmetros que devem ser ajustados na rede neural. Descrevem-se o desenvolvimento do modelo térmico, e a criação do banco de dados a partir de sua solução bem como a escolha dos parâmetros detectáveis em imagens termográficas, as bibliotecas de *deep learning*, o treinamento da rede com uso de redes neurais convolucionais, e a análise dos hiperparâmetros usados no modelo para convergência dos problemas direto e inverso. Discute-se ainda a necessidade do conhecimento prévio das características tumorais que podem ser estimadas via redes neurais convolucionais e a influência da variação do tamanho do tumor comparando os sinais de temperatura e da impedância térmica. Obteve-se resultados numéricos da estimativa da localização de tumores em simulações numéricas com uso de imagens termográficas obtidas de dados simulados em um modelo cartesiano e em um modelo de mama anatômica. O desenvolvimento de uma técnica que possibilite a identificação da localização e tamanho de tumores na mama a partir de informações de temperatura e fluxo de calor superficiais é uma ferramenta inédita e promissora na detecção precoce do câncer de mama.

---

*Palavras chave: câncer de mama, imagens térmicas, termografia, impedância térmica, redes neurais, deep learning.*

NASCIMENTO, J. G., **USE OF ARTIFICIAL INTELLIGENCE TECHNIQUES, CORRELATION OF THERMAL IMAGES AND THE CONCEPT OF THERMAL IMPEDANCE AIMING TO ESTIMATE THE LOCATION AND SIZE OF BREAST TUMORS**. 2022. 121 f. Doctoral Thesis, Federal University of Uberlândia, Uberlândia, MG.

### Abstract

Breast cancer has the highest incidence and mortality in the female population worldwide. Early and accurate detection of breast cancer is a critical part of the strategy to reduce the mortality associated with this prevalent disease. Mammography is the most used technique for the early detection of breast cancer. However, it has several limitations. Several images are needed, and there is a strong dependence on the operator. There is still a firm reliance on a qualified physician to identify tumors on X-ray images. In addition, lifetime exposure to X-rays can also induce tumors. In this project, we propose the development of techniques based on applying the thermal impedance method and on detecting inclusions based on the use of correlations of surface temperatures of the skin of the breast to detect the origin of the heat source (abnormal metabolism of cancer). The main idea of this work is to use the artificial intelligence method, deep learning, a technique related to the recognition of specific features in images to detect sources of metabolic heat. In addition to the proposed approach not being invasive or causing pain to the patient, it must allow access to people with disabilities or low mobility, have low cost and use national technologies. The low sensitivity to tiny and deep tumors, typically found in the analysis of surface temperatures using thermal imaging, is circumvented by utilizing the concept of thermal impedance and artificial intelligence techniques, such as deep learning. It has been shown a brief theoretical foundation on convolutional neural networks, optimizers, activation functions, and the hyperparameters that must be adjusted in the neural network. The development of the thermal model and the creation of the database from its solution are described, as well as the choice of parameters detectable in thermographic images, *deep learning* libraries, network training using convolutional neural networks, and the analysis of the hyperparameters used in the model for the convergence of the forward and inverse problems. We also discuss the need for prior knowledge of tumor characteristics that can be estimated via convolutional neural networks and the influence of tumor size variation by comparing the temperature and thermal impedance signals. The numerical results of estimating the location of tumors in numerical simulations using thermographic images obtained from simulated data in a Cartesian model and an anatomical breast model are shown. The development of a technique that makes it possible to identify the location and size of breast tumors from information on temperature and surface heat flux is an unprecedented and promising tool in the early detection of breast cancer.

---

*Keywords: breast cancer, thermal imaging, thermography, thermal impedance, neural networks, deep learning.*



# Lista de Figuras

2.1	Evolução da inteligência artificial. . . . .	6
2.2	Aprendizado de máquinas. . . . .	7
3.1	Pixel de Imagens Preto e Branco. . . . .	11
3.2	Pixel de Imagens Coloridas. . . . .	12
3.3	Numeração dos pixels. . . . .	12
3.4	Numeração dos pixels de uma imagem preta e branca. . . . .	13
3.5	Normalização dos pixels. . . . .	13
3.6	Ampliação de uma imagem. . . . .	14
3.7	Imagem Colorida: (a) Extração dos pixels; (b) Separação em canais de matrizes; (c) Normalização dos pixels. . . . .	14
3.8	Resumo de Redes Neurais Convolucionais. . . . .	16
3.9	Disposição dos neurônios:(a) ANN; (b) ConvNets. . . . .	16
3.10	ConvNet simples. . . . .	17
3.11	Pooling máximo. . . . .	18
3.12	Conexão completa. . . . .	19
3.13	Estrutura de um neurônio. . . . .	20
3.14	Estrutura da camada de entrada. . . . .	21
3.15	Estrutura das camadas intermediárias. . . . .	22
3.16	Representação Matemática. . . . .	22
3.17	Atualização dos Pesos e Bias. . . . .	23
3.18	Otimização com Gradiente Descendente. . . . .	30
3.19	Taxa de aprendizagem: (a) Pequena; (b) Grande. . . . .	30
3.20	Esquema de atualização dos pesos com uso do algoritmo de retropropagação. . . . .	33
3.21	Problemas em Redes Neurais: (a) Sem Overfitting; (b) Com Overfitting. . . . .	34
3.22	Modelo de rede neural de eliminação: (a) Rede Neural Padrão; (b) Rede Neural com Dropout. . . . .	35
4.1	Bordas das imagens que não representam o problema físico e dificultam o modelo de aprendizagem. . . . .	36
4.2	Etapas do trabalho, esquema adaptado de Wang e Adachi (2019). . . . .	38
4.3	Mama: (a) Cartesiana; (b) Semi-esférica. . . . .	39
4.4	Modelo tridimensional: Geometria Cartesiana. . . . .	40
4.5	Malhas analisadas. . . . .	41
4.6	Malha: (a) Plano xy; (b) Plano yz. . . . .	41
4.7	Malha tridimensional: Geometria Cartesiana. . . . .	42

5.1	Mama Cartesiana: (a) Posicionamento do tumor; (b) região de análise posicionada.	45
5.2	Pixeis das Imagens Termográficas Simuladas. . . . .	46
5.3	Pixeis normalizados das imagens termográficas simuladas nas seguintes profundidades: (a) $z = 40$ mm; (b) $z = 50$ mm. . . . .	47
5.4	Pixeis normalizados das imagens termográficas simuladas nas seguintes profundidades: (a) $z = 60$ mm; (b) $z = 65$ mm. . . . .	48
5.5	Pixeis normalizados das imagens termográficas simuladas nas seguintes profundidades: (a) $z = 70$ mm; (b) $z = 75$ mm. . . . .	48
5.6	Influência da Posição do Tumor no Perfil de Pixeis: (a) $y = 10$ mm; (b) $y = 20$ mm; (c) $y = 30$ mm; (d) $y = 40$ mm; (e) $y = 50$ mm; (f) $y = 60$ mm; (g) $y = 70$ mm; (h) $y = 80$ mm. . . . .	49
5.7	Influência da Posição do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos. . . . .	50
5.8	Influência da Profundidade do Tumor no Perfil de Pixeis: (a) $z = 30$ mm; (b) $z = 40$ mm; (c) $z = 50$ mm; (d) $z = 60$ mm; (e) $z = 65$ mm; (f) $z = 70$ mm; (g) $z = 75$ mm; (h) $z = 77$ mm. . . . .	51
5.9	Influência da Profundidade do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos. . . . .	52
5.10	Influência da Tamanho do Tumor no Perfil de Pixeis: (a) $r = 3$ mm; (b) $r = 4$ mm; (c) $r = 5$ mm; (d) $r = 6$ mm; (e) $r = 7$ mm; (f) $r = 8$ mm; (g) $r = 9$ mm; (h) $r = 10$ mm. . . . .	53
5.11	Influência do Tamanho do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos. . . . .	54
5.12	Influência do Tamanho do Tumor: (a) Temperatura Superficial Normalizada ; (b) Resíduos. . . . .	55
5.13	Influência da Geração de Calor Metabólica no Perfil de Pixeis: (a) $Q = 10$ W/m <sup>3</sup> ; (b) $Q = 10^2$ W/m <sup>3</sup> ; (c) $Q = 10^3$ W/m <sup>3</sup> ; (d) $Q = 10^4$ W/m <sup>3</sup> ; (e) $Q = 10^5$ W/m <sup>3</sup> ; (f) $Q = 10^6$ W/m <sup>3</sup> ; (g) $Q = 10^7$ W/m <sup>3</sup> ; (h) $Q = 10^8$ W/m <sup>3</sup> . . . . .	56
5.14	Influência da Geração de Calor Metabólico do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos. . . . .	57
5.15	Influência da Geração de Calor Metabólico: (a) Temperatura Superficial Normalizada ; (b) Resíduos. . . . .	58
5.16	Influência da Perfusão Sanguínea do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos. . . . .	58
5.17	Influência da Perfusão Sanguínea do Tumor: (a) Temperatura Superficial Normalizada ; (b) Resíduos. . . . .	59
5.18	Influência da Condutividade Térmica do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos. . . . .	59
5.19	Influência da Condutividade do Tumor: (a) Temperatura Superficial Normalizada ; (b) Resíduos. . . . .	60
5.20	Treinamento da Rede Neural referente a diferentes classes de posições de tumores térmicos simulados: (a) Precisão ; (b) Função erro. . . . .	61
6.1	Geometria cartesiana tridimensional com uma inclusão esférica, modelo no qual pode ser obtida a equação baseada na impedância térmica. . . . .	65

6.2	Comparação da influência do metabolismo do tumor no perfil de pixels na temperatura: (a) $Q = 10^4$ W/m <sup>3</sup> ; (b) $Q = 10^5$ W/m <sup>3</sup> ; (c) $Q = 10^6$ W/m <sup>3</sup> ; (d) $Q = 10^7$ W/m <sup>3</sup> e na impedância: (e) $Q = 10^4$ W/m <sup>3</sup> ; (f) $Q = 10^5$ W/m <sup>3</sup> ; (g) $Q = 10^6$ W/m <sup>3</sup> ; (h) $Q = 10^7$ W/m <sup>3</sup> . . . . .	67
6.3	Influência do metabolismo do tumor no perfil de pixels de: (a) Temperatura; (b) Impedância. . . . .	68
6.4	Influência do metabolismo do tumor no perfil de pixels de resíduo de: (a) Temperatura; (b) Impedância. . . . .	68
6.5	Influência do metabolismo do tumor no perfil de: (a) Temperatura; (b) Impedância. . . . .	69
6.6	Influência do metabolismo do tumor no perfil de: (a) Temperatura; (b) Impedância, normalizados . . . . .	70
6.7	Influência do metabolismo do tumor no perfil de resíduos normalizados de: (a) Temperatura; (b) Impedância. . . . .	70
6.8	Influência do tamanho do tumor no perfil de pixels na temperatura: (a) $r = 2$ mm; (b) $r = 4$ mm; (c) $r = 7$ mm; (d) $r = 10$ mm, e na impedância: (e) $r = 2$ mm; (f) $r = 4$ mm; (g) $r = 7$ mm; (h) $r = 10$ mm. . . . .	71
6.9	Influência do tamanho do tumor no perfil de pixels de: (a) Temperatura; (b) Impedância. . . . .	72
6.10	Influência do tamanho do tumor no perfil de resíduos de pixels de: (a) Temperatura; (b) Impedância. . . . .	72
6.11	Influência do tamanho do tumor no perfil de: (a) Temperatura; (b) Impedância. . . . .	73
6.12	Influência do tamanho do tumor no perfil de resíduos normalizados de : (a) Temperatura; (b) Impedância. . . . .	73
7.1	Peso: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel. . . . .	80
7.2	Peso: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel. . . . .	80
7.3	Bias: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel. . . . .	82
7.4	Bias: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel. . . . .	82
7.5	Funções de Ativação: (a) Função ; (b) Derivada. . . . .	83
7.6	Função de ativação: (a) precisão ; (b) Zoom dos valores da precisão. . . . .	84
7.7	Função de ativação: (a) Função erro ; (b) Zoom dos valores da função erro. . . . .	84
7.8	Quantidade de Camadas Escondidas: (a) Precisão ; (b) Zoom dos valores da precisão. . . . .	85
7.9	Quantidade de Camadas Escondidas: (a) Função erro ; (b) Zoom dos valores da função erro. . . . .	85
7.10	Número de Neurônios Por Camada: (a) Precisão ; (b) Zoom dos valores da precisão. . . . .	86
7.11	Número de Neurônios Por Camada: (a) Função erro ; (b) Zoom dos valores da função erro. . . . .	87
7.12	Otimizadores: (a) Precisão ; (b) Zoom dos valores da precisão. . . . .	88
7.13	Otimizadores: (a) Função erro ; (b) Zoom dos valores da função erro. . . . .	88
7.14	Qualidade da Imagem: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel. . . . .	89
7.15	Qualidade da Imagem: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel. . . . .	89

7.16	Tamanho do lote: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel. . . . .	90
7.17	Tamanho do lote: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel. . . . .	91
7.18	Dropout: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel. . . . .	92
7.19	Dropout: (a) Variação da Precisão ; (b) Média móvel da variação da precisão. . . . .	92
7.20	Dropout: (a) Função erro ; (b) Zoom dos valores da função erro. . . . .	93
8.1	Arquitetura das redes neurais convolucionais usada. . . . .	95
8.2	Formato imagem: (a) 128X128 ; (b) 512X512. . . . .	96
8.3	Tumores simulados: (a) vista tridimensional; (b) vista superior plano xy. . . . .	97
8.4	Tumores simulados: (a) vista lateral direita, plano xz; (b) vista frontal, plano yz. . . . .	98
8.5	Modelo Simulado: (a) Temperatura ; (b) Vista Transparente para visualização da fonte de calor metabólico. . . . .	98
8.6	Banco de dados de imagens termográficas simuladas cuja localização (x,y,z) é dada por: (a) (10, 10, 77) ; (b) (80, 10, 77); (c) (10, 80, 77); (d) (80, 80, 77), a variação na altura com (80, 80, z) é dada: (e) $z = 60$ mm; (f) $z = 65$ mm; (g) $z = 70$ mm; (h) $z = 75$ mm. . . . .	99
8.7	Convergência da rede neural com a imagem de temperatura da superfície da mama cartesiana: (a) Precisão ; (b) Função erro. . . . .	100
8.8	Variação em uma coordenada do posicionamento de tumores fictícios. . . . .	101
8.9	Variação em duas coordenadas do posicionamento de tumores fictícios. . . . .	103
8.10	Superfície de aplicação do fluxo de calor. . . . .	105
8.11	Mama cartesiana em regime transiente: (a) fluxo de calor imposto na superfície da mama; (b) temperatura de um ponto localizado na superfície e no centro da mama, ou seja, $(x, y, z) = (80, 80, 80)$ . . . . .	106
8.12	Influência do tamanho do tumor no perfil de: (a) Temperatura; (b) Impedância. . . . .	108
8.13	Variação do tamanho da inclusão: (a) vista lateral; (b) vista superior. . . . .	109
8.14	Convergência da rede neural com a imagem de temperatura da superfície da mama: (a) Precisão ; (b) Função erro. . . . .	110
8.15	Convergência da rede neural com a imagem da impedância térmica da superfície da mama: (a) Precisão ; (b) Função erro. . . . .	110
8.16	Mama Real: (a) Vista frontal; (b) Vista lateral; (c) vista inferior. . . . .	112
8.17	Mama Real: (a) Malha; (b) mama sem tumor (baseline). . . . .	112
8.18	Banco de dados da mama anatômica. . . . .	113
8.19	Convergência da rede neural da termografia da superfície da mama real: (a) Precisão ; (b) Função erro. . . . .	114

# Lista de Tabelas

4.1	Propriedades Termo-físicas da mama conforme os trabalhos de Agnelli, Barrea e Turner (2011) e Hossain e Mohammadi (2016). . . . .	39
4.2	Tipos de elementos do modelo tridimensional fornecida pelo software COMSOL <i>multiphysics</i> . . . . .	42
4.3	Estatística dos elementos do modelo 3D em análise feito no software COMSOL <i>multiphysics</i> . . . . .	43
7.1	Considerações feitas em relação aos hiperparâmetros no estudo de convergência da rede neural. . . . .	76
7.2	Configurações do computador usado nas análises. . . . .	77
7.3	Custo computacional relativo a qualidade da imagem analisada. . . . .	78
7.4	Tipos de Inicializações das matrizes de peso. . . . .	79
7.5	Tipos de Inicializações dos vetores de bias. . . . .	81
8.1	Estimativa da Localização de tumores: variação do posicionamento em 1 coordenada, primeira configuração de hiperparâmetros. . . . .	102
8.2	Estimativa da Localização de tumores: variação do posicionamento em 1 coordenada, segunda configuração de hiperparâmetros. . . . .	102
8.3	Estimativa da Localização de tumores: variação em 2 coordenadas, primeira configuração de hiperparâmetros. . . . .	103
8.4	Estimativa da Localização de tumores: variação em 2 coordenadas, segunda configuração de hiperparâmetros. . . . .	104
8.5	Estimativa da Localização de tumores: variação do posicionamento em uma (1) coordenada, segunda configuração de hiperparâmetros. . . . .	106
8.6	Estimativa da Localização de tumores: variação em 2 coordenadas, segunda configuração de hiperparâmetros. . . . .	107
8.7	Estimativa da Localização de tumores: variação do posicionamento em 1 coordenada, segunda configuração de hiperparâmetros. . . . .	111
8.8	Estimativa da Localização de tumores na mama real. . . . .	114

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Câncer de mama, mamografia e técnica proposta . . . . .	1
1.2	Estrutura da Tese . . . . .	2
<b>2</b>	<b>Revisão Bibliográfica</b>	<b>4</b>
2.1	Detecção de Tumores Baseada na Técnica da Termografia . . . . .	5
2.2	Desenvolvimento da Inteligência Artificial . . . . .	6
2.3	Aplicações em Medicina . . . . .	8
<b>3</b>	<b>Fundamentos Teóricos</b>	<b>10</b>
3.1	Interpretação das Imagens pelo Computador . . . . .	11
3.2	Redes Neurais Convolucionais . . . . .	14
3.2.1	Camada de Convolução . . . . .	16
3.2.2	Camada de Agrupamento ( <i>Pooling Layer</i> ) . . . . .	17
3.2.3	Camada de Achatamento ( <i>Flattening</i> ) . . . . .	18
3.2.4	Conexão Completa ( <i>Full Connection</i> ) . . . . .	18
3.3	Redes Neurais . . . . .	20
3.4	Pesos e vieses ( <i>Bias</i> ) . . . . .	23
3.5	Função de Ativação . . . . .	24
3.5.1	Relu . . . . .	27
3.5.2	Leaky Relu . . . . .	27
3.5.3	Elu . . . . .	27
3.5.4	Selu . . . . .	28
3.5.5	Softplus . . . . .	28
3.5.6	Softsign . . . . .	28
3.5.7	Sigmoid, Logistic ou Soft Step . . . . .	28
3.5.8	Softmax . . . . .	29
3.6	Função de Perda ( <i>Loss Function</i> ) . . . . .	29
3.7	Algoritmos de Otimização de Gradiente Descendente . . . . .	29
3.7.1	SGD . . . . .	31
3.7.2	AdaGrad . . . . .	31
3.7.3	Adadelta . . . . .	31
3.7.4	RMSprop . . . . .	31
3.7.5	Adam . . . . .	32
3.8	Backpropagation . . . . .	32
3.9	Overfitting e Regularização em Redes Neurais . . . . .	33

3.9.1	Eliminação ( <i>Dropout</i> ) . . . . .	34
3.9.2	Eliminação espacial ( <i>SpatialDropout2D</i> ) . . . . .	35
<b>4</b>	<b>Metodologia</b>	<b>36</b>
4.1	Modelo Térmico . . . . .	38
4.2	Modelo numérico . . . . .	38
4.2.1	Geometria . . . . .	40
4.2.2	Malha Numérica . . . . .	40
<b>5</b>	<b>Análise da influência da localização, de propriedades térmicas e da geometria dos tumores nos perfis de pixels normalizados</b>	<b>44</b>
5.1	Análise dos Pixels de Imagens Termográficas Simuladas . . . . .	45
5.2	Influência da Posição do Tumor no Perfil de Pixels . . . . .	49
5.3	Influência da Profundidade do Tumor no Perfil de Pixels . . . . .	50
5.4	Influência do Tamanho do Tumor no Perfil de Pixels . . . . .	52
5.5	Influência da Geração Metabólica do Tumor no Perfil de Pixels . . . . .	55
5.6	Influência da Perfusão Sanguínea do Tumor . . . . .	58
5.7	Influência da Condutividade Térmica do Tumor . . . . .	59
<b>6</b>	<b>Proposta de uma nova técnica para a localização de tumores usando impedância térmica e redes convolucionais</b>	<b>62</b>
6.1	Técnicas propostas como alternativas à termografia . . . . .	62
6.1.1	Analogia entre a Impedância Térmica e a Impedância Eletromecânica . . . . .	63
6.2	Impedância térmica . . . . .	64
6.3	Efeitos da Variação da Geração de Calor Metabólico na Impedância Térmica . . . . .	67
6.4	Influência da Variação do Tamanho do tumor na temperatura e impedância . . . . .	71
<b>7</b>	<b>Análise da Influência dos Principais Hiperparâmetros usados Para Construção do Modelo em Deep Learning.</b>	<b>74</b>
7.1	Influência do Peso ( <i>Weight</i> ) . . . . .	78
7.2	Influência do Viés ( <i>Bias</i> ) . . . . .	80
7.3	Influência das Funções de Ativação . . . . .	82
7.4	Influência da Quantidade de Camadas Escondidas . . . . .	84
7.5	Influência do Número de Neurônios Por Camada . . . . .	86
7.6	Influência dos Otimizadores . . . . .	87
7.7	Influência da Qualidade da Imagem . . . . .	88
7.8	Influência do Tamanho do lote . . . . .	90
7.9	Influência dos Regularizadores . . . . .	91
<b>8</b>	<b>Estimativa da localização de tumores em simulações numéricas com uso de imagens termográficas</b>	<b>94</b>
8.1	Problema Direto . . . . .	97
8.2	Problema Inverso . . . . .	100
8.2.1	Variação do posicionamento em uma coordenada . . . . .	100
8.2.2	Resultados . . . . .	101
8.2.3	Variação do posicionamento em duas coordenadas . . . . .	102

8.3	Modelo Cartesiano - Análise em regime transiente . . . . .	105
8.4	Mama Cartesiana - Impedância Térmica . . . . .	108
8.5	Mama Anatômica - Análise em regime permanente . . . . .	112
<b>9</b>	<b>Conclusão</b>	<b>115</b>
9.1	Propostas de trabalhos futuros . . . . .	116
	Referências Bibliográficas . . . . .	118



# Capítulo 1

## Introdução

### 1.1 Câncer de mama, mamografia e técnica proposta

O câncer de mama possui a maior incidência e mortalidade na população feminina em todo o mundo. A detecção precoce e precisa do câncer de mama é uma parte crítica da estratégia para reduzir a mortalidade associada a esta doença tão comum.

O número de pessoas afetadas pelo câncer de mama aumentou significativamente nos últimos anos. Os esforços incansáveis de muitos, a cautela e a pesquisa para encontrar a cura dessa doença aumentaram de forma significativa nos últimos anos. Sabe-se que todos os casos de câncer de mama devem ser detectados precocemente para evitar os efeitos colaterais dos tratamentos por radioterapia e quimioterapia, das cicatrizes permanentes deixadas pelas cirurgias e das consequências mortais nos casos de pessoas que não respondem ao tratamento. Como resultado, os pesquisadores compartilham um forte desejo de encontrar maneiras rápidas, precisas e minimamente invasivas de identificar os primeiros sinais do câncer de mama.

A mamografia é a técnica mais usada para a detecção precoce do câncer de mama, porém, possui várias limitações. Várias imagens são necessárias e existe uma forte dependência do médico ou técnico operador. Existe ainda uma forte dependência de um médico qualificado para identificar tumores nas imagens de raio-X. Além disso, a exposição ao raio-X ao longo da vida pode também induzir o aparecimento de tumores. Outra limitação se refere a uma elevada porcentagem de falso positivo o que, por sua vez, irá requerer exames de biopsias desnecessárias. Finalmente, a maior limitação da mamografia se refere à sua aplicação em pacientes jovens com tecidos densos ou pacientes com pouca mobilidade, como cadeirantes.

Por ser mais segura, a ultrassonografia é também bastante usada no diagnóstico do câncer de mama. Porém o ultrassom convencional da mama teve limitações consideráveis até meados de 2010. Como resultado, nasceu a *TechniScan Medical Systems*. A *TechniScan* desenvolveu um método de imagem de ultrassom tridimensional cuja conversão dos dados coletados em

imagens tridimensionais exigia computação considerada na época como demorada e de alto custo. A introdução da primeira GPU da NVIDIA, baseada na arquitetura CUDA, junto com sua linguagem de programação CUDA, forneceu uma plataforma na qual a *TechniScan* pôde melhorar os recursos computacionais e trabalhar com imagens tridimensionais a partir do final de 2010. Seu custo operacional, todavia, impede o acesso da população mais carente.

Nesse projeto, propõe-se o desenvolvimento de técnicas baseadas na aplicação do método de impedância térmica e na detecção de inclusões baseada no uso de correlações de temperaturas superficiais da pele da mama para detectar a origem da fonte de calor (metabolismo anormal de um câncer). A ideia principal deste trabalho é usar o método da inteligência artificial, aprendizado profundo, técnica relacionada ao reconhecimento de características específicas em imagens para detecção de fontes de calor metabólica. O desenvolvimento de uma técnica que possibilite a identificação da localização e tamanho de tumores na mama a partir de informações de temperatura e fluxo de calor superficiais é uma ferramenta inédita e promissora na detecção precoce do câncer de mama.

Alem da técnica proposta não ser invasiva ou causar dor à paciente, ela deve permitir o acesso a pessoas com deficiência ou baixa mobilidade, possuir baixo custo e usar tecnologias nacionais.

A baixa sensibilidade aos tumores pequenos e profundos, normalmente existente em análises de temperaturas superficiais usando imagens térmicas é contornada com o uso do conceito de impedância térmica e técnicas de inteligência artificial, como o uso de aprendizado profundo (Deep learning).

## 1.2 Estrutura da Tese

No capítulo 2 é apresentado uma revisão bibliográfica onde é abordado as formas de detecção de tumores baseada na técnica da termografia e uma abordagem sobre o desenvolvimento da inteligência artificial.

Apresenta-se no capítulo 3 uma breve fundamentação teórica sobre redes neurais convolucionais, otimizadores, funções de ativação e os hiperparâmetros que devem ser ajustados na rede neural.

Apresentam-se no capítulo 4 a metodologia para localização de tumores usando imagem infravermelha. Descrevem-se, nesse caso, etapas como o desenvolvimento do modelo térmico, e a criação do banco de dados a partir de sua solução. Apresentam-se a escolha dos parâmetros detectáveis em imagens termográficas, as bibliotecas de *deep learning*, o treinamento da rede com uso de redes neurais convolucionais, e a análise dos hiperparâmetros usados no modelo para convergência dos problemas direto e inverso.

Demonstra-se no capítulo 5 a influência das propriedades e parâmetros termofísicos nos perfis

de pixels das imagens termográficas simuladas na superfície da pele da mama. Ou seja, discute-se a necessidade do conhecimento prévio das características tumorais que podem ser estimadas via redes neurais convolucionais.

A proposta da nova técnica, baseada em impedância térmica é então apresentada no capítulo 6. Nesse caso, analisa-se também a influência da variação do tamanho do tumor comparando os sinais de temperatura e da impedância térmica.

Explana-se no capítulo 7 uma análise da influência dos principais hiperparâmetros usados para construção do modelo em *deep learning*. No estudo de aprendizado profundo, existem muitos parâmetros que afetam de forma total ou parcial tanto a convergência da rede neural, quanto o resultado de outros parâmetros. Esses são conhecidos como hiperparâmetros, em que alguns podem influenciar significativamente no problema de otimização e outros não. Todavia, mesmo os parâmetros que não possuem influência significativa podem melhorar a precisão dos resultados de convergência da rede neural convolucional em que deseja-se analisar.

No capítulo 8 são evidenciados os resultados numéricos da estimativa da localização de tumores em simulações numéricas com uso de imagens termográficas. O objetivo deste capítulo é de estimar a localização de tumores fictícios com uso de imagens de temperaturas superficiais e de impedância térmica simuladas. Os resultados são apresentados para banco de dados construídos a partir de modelo cartesiano e do modelo da mama anatômica.

Conclui-se o trabalho apresentando as principais contribuições desta proposta.

# Capítulo 2

## Revisão Bibliográfica

O uso de imagens no diagnóstico de câncer tem ajudado de forma decisiva na constatação da doença, na localização de tecidos malignos para biopsia, na detecção de metástase e no planejamento de protocolos de tratamento (SREE et al., 2010).

No Brasil a mamografia está longe de se tornar facilmente acessível a toda mulher, mesmo em situações aonde se palpa um nódulo suspeito o exame é extremamente importante para a decisão terapêutica. Muitos serviços públicos importantes de referência ao câncer que atendem grande parte dos pacientes com suspeitas de tumor não possuem mamografia. Além disso, há uma enorme variação na qualidade dos exames, entre os diferentes serviços de saúde à disposição. Existe ainda o risco da exposição de radiação excessiva quando um novo exame se torna necessário.

A termografia por sua vez tem as vantagens de ser de baixo custo, fácil aplicação e permitir a detecção precoce de tumores. Como desvantagens citam-se a alta dependência do operador para a interpretação das imagens e a limitação de indicação da posição exata da profundidade ou do tamanho de um nódulo.

Conforme o Instituto Nacional de Câncer (INCA), para o Brasil, estimam-se que 66.280 casos novos de câncer de mama para cada ano do triênio 2020-2022. Esse valor corresponde a um risco estimado de 61,61 novos casos a cada 100 mil mulheres sem considerar os tumores de pele não melanoma, o câncer de mama feminina ocupa a primeira posição mais frequente em todas as Regiões brasileiras. A detecção precoce é a melhor forma de combater a doença e, embora as mamografias sejam ferramentas de detecção eficazes, elas podem gerar resultados falso positivos ou falso negativos.

Segundo a American Cancer Society, radiologistas não detectam cerca de 20 % dos casos de câncer de mama nos mamogramas, gerando um resultado falso negativo. E muitas mulheres que fazem os testes têm um resultado falso positivo em algum momento da vida, no qual o exame mostra que ela tem câncer, embora ela esteja saudável.

## 2.1 Detecção de Tumores Baseada na Técnica da Termografia

Uma vez que os tumores são grupos de células que se multiplicam de maneira descontrolada, a taxa de geração de calor metabólica e a taxa de perfusão sanguínea do tumor são superiores (em casos específicos, podem também ser inferiores) a dos tecidos saudáveis. A geração de calor no tumor é dissipado para o tecido circundante e pode ser visto como um pico (ou vale, em alguns casos) de temperatura na superfície da mama.

O uso de imagens infravermelhas no estudo do câncer tem sido investigado por inúmeros pesquisadores, como Parisky *et al.* (2003), Arora *et al.* (2008), Kapoor e Prasad (2010), Sree *et al.* (2010) e Mitra e Balaji (2010). Parisky *et al.* (2003), realizaram um ensaio clínico de 4 anos com 769 pacientes. Nas 875 lesões biopsiadas, o índice de suspeita resultou em sensibilidade de 97%, especificidade de 14%, valor preditivo negativo de 95 % e valor preditivo positivo de 24%. Uma análise do desempenho da imagem infravermelha das 875 lesões biopsiadas revelou que a especificidade era estatisticamente maior no tecido mamário denso do que no adiposo Arora *et al.* (2008), realizaram um estudo prospectivo duplo-cego com 92 pacientes e obtiveram uma sensibilidade de 97%, identificando corretamente 58 de 60 neoplasias com biópsias. Este estudo também mostrou um grande valor adjuvante das imagens em mulheres com parênquima mamário denso.

Para melhorar a precisão preliminar do rastreamento do câncer de mama Kapoor e Prasad (2010) propuseram um termograma para analisar automaticamente imagens térmicas de infravermelho. A detecção de bordas com a transformada de Hough foi utilizada para a análise de assimetria dos padrões de calor nos seios. Sree *et al.* (2010) estabeleceram protocolos padronizados para procedimentos termográficos e interpretação de termogramas. Mitra e Balaji (2010), propuseram uma estimativa da posição e tamanho de um tumor em uma mama humana usando imagens termográficas em conjunto com redes neurais artificiais. Das e Mishra (2015) relatam um estudo numérico referente à estimativa simultânea de tamanho, localização radial e angular de um tumor maligno em uma mama humana em 3D.

Os perfis de temperatura são então obtidos através da resolução da equação de Pennes com uso de soluções numéricas baseadas em elementos finitos com auxílio do software comercial COMSOL. Em outro trabalho, Figueiredo, Fernandes e Guimaraes (2018) estimam a profundidade de um tumor mamário utilizando temperatura experimental da superfície da mama. Existem diferentes métodos que tratam a detecção de tumores da mama como um problema inverso da transferência de calor. Uma grande limitação, no entanto, é o conhecimento das propriedades térmicas e dos parâmetros físicos do tecido vivo necessários. Esses parâmetros incluem perfusão, geração de calor metabólico, temperatura corporal, propriedades arteriais e térmicas das várias camadas de gordura ou tecido epitelial.

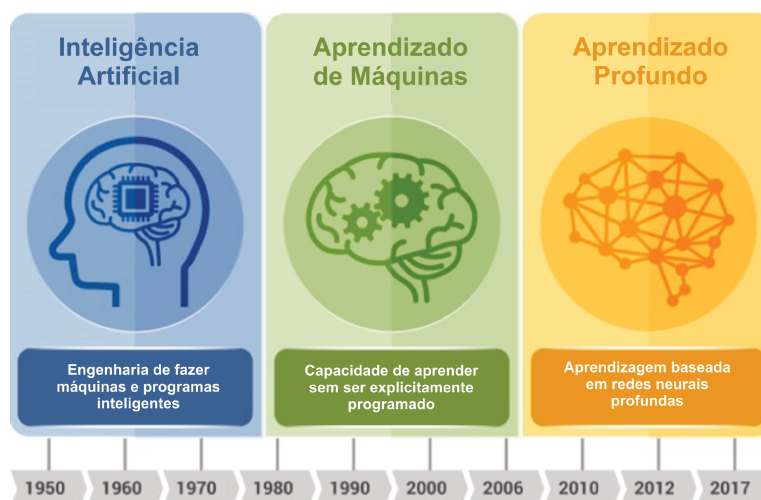
Uma das técnicas em que se baseia esse trabalho usa as informações de temperatura medidas na superfície por meio de sensores infravermelhos ou termopares superficiais e medições do fluxo de calor imposto na mama. A técnica baseia-se no uso de impedância térmica e obtém índices de dano que detectam a presença de tumores sem exigir o conhecimento de parâmetros físicos e propriedades térmicas da mama Menegaz e Guimarães (2019). A analogia entre impedância eletromecânica e térmica representa uma nova abordagem para a detecção de inclusões. A aplicação da impedância térmica na detecção de danos representa uma inovação e pode aumentar a sensibilidade de técnicas baseadas em imagens infravermelhas térmicas.

Este trabalho pretende avançar no desenvolvimento da técnica buscando a identificação do tamanho e posição das inclusões, tornando a técnica um procedimento de diagnóstico através do uso da inteligência artificial.

## 2.2 Desenvolvimento da Inteligência Artificial

O estudo sobre inteligência artificial (artificial intelligence - AI) teve início entre os anos de 1940 a 1970, o qual representava uma pesquisa sobre a engenharia de fabricação de máquinas e programas inteligentes. Tal estudo foi aprimorado entre os anos de 1980 - 2006 e passou por uma nova versão chamada de aprendizado de máquinas, do inglês *machine learning*. Este novo método representa a habilidade de aprendizagem sem ser explicitamente programado. Neste caso foram criadas bibliotecas de funções cujo objetivo era facilitar a programação para novos programadores. Finalmente, desde meados de 2006 até os dias atuais, surgiu a era de aprendizagem profunda, do inglês *deep learning*, cuja base encontra-se na aprendizagem de rede neural profunda. A Figura 2.1 mostra a evolução histórica da inteligência artificial.


Figura 2.1: Evolução da inteligência artificial.



Fonte: adaptado de : <https://www.embedded-vision.com>.

Com o avanço da tecnologia, desde o advento dos computadores, uma quantidade crescente de atenção tem sido focada na viabilidade de construir um dispositivo que possua funções semelhantes à humana, como percepção, reconhecimento, formação de conceitos e capacidade de generalizar com a experiência. A Figura 2.2 traz uma sátira sobre o aprendizado de máquinas. Em particular, essa linha de pesquisa nasceu com interesse centrado na ideia de construir uma máquina que seria capaz de conceituar insumos que interferissem diretamente no ambiente físico, como a luz, o som e a temperatura (ROSENBLATT, 1957).

Figura 2.2: Aprendizado de máquinas.



Fonte: Phil (2017).

Permitir que sistemas computacionais usem a inteligência humana tem sido a inspiração de pesquisadores por mais de meio século. Final dos anos 50, Rosenblatt (1957) tinha como objetivo formular algo análogo ao cérebro humano que seria útil em análises. Isso marcou o início da pesquisa no campo de permitir que as máquinas aprendam e classifiquem como o cérebro humano.

De acordo com Bengio e Yoshua (2009), o principal requisito de qualquer sistema de aprendizagem deve ser duplo: em primeiro lugar, deve haver a capacidade de reconhecer e processar padrões complexos de informações e, em segundo lugar, para alcançar a inteligência humana, uma máquina deve exigir acesso a grande volume de informações.

Um sistema que poderia operar com algumas das noções acima foi chamado perceptron por Rosenblatt (1957). Este perceptron passou a ser base para criação de redes de aprendizagem multi-camada que formaram a base do que é popularmente chamado *Deep Learning* (Arel; Rose; Karnowski, 2010). Segundo Arel, Rose e Karnowski (2010), a aprendizagem profunda *Deep*

*Learning* (DL) é um estudo de aplicação de redes neurais com várias camadas de neurônios (3 ou mais) entre entrada e saída. As múltiplas camadas entre entrada e saída são usadas para realizar identificação e processamento de características através de uma série de estágios como o cérebro humano (Arel; Rose; Karnowski, 2010).

Os mecanismos tradicionais de aprendizado de máquina, *machine learning* - (ML) tinham capacidade limitada de processamento de dados reais em sua forma bruta real. Assim, foi necessário décadas de trabalho e especialização para transformar dados brutos em sua representação adequada como vetores de dados do qual a máquina aprendiz poderia classificar padrões na entrada (LECUN; BENGIO; HINTON, 2015).

A característica notável da aprendizagem profunda é que as camadas de recursos não são projetadas ou determinadas por humanos, mas são aprendidas automaticamente através de um procedimento de aprendizado generalizado Bengio e Yoshua (2009). Através dessa capacidade de aprendizagem autônoma, o aprendizado profundo alcançou um sucesso significativo em relação ao aprendizado de máquinas e IA em vários campos do empreendimento humano.

Em seu trabalho Wason (2018), aborda o sucesso significativo das redes neurais profundas nos domínios de aplicação com desempenho quase humano. Além disso, fala sobre as capacidades das redes neurais profundas em permitir que máquinas executem tarefas humanas que podem ser aprendidas através do que é chamado de observação e experiência.

De acordo com Saba *et al.* (2019), em poucos anos, avanços como carros autônomos, robôs realizando trabalhos que são perigosos para humanos e bots de bate-papo conversando com operadores humanos provaram que o DL já causou grande impacto na sociedade. A natureza de código aberto do DL e os preços decrescentes do hardware do computador impulsionarão ainda mais essas mudanças.

## 2.3 Aplicações em Medicina

Conforme Patel e Goyal (2007), a radiologia está no caminho para se tornar um dos mais importantes campos de aplicação da Inteligência Artificial devido à natureza do trabalho dos radiologistas neste importante ramo da medicina diagnóstica. No entanto, há, até agora, muita expectativa sobre a possibilidade de IA substituir inteiramente profissionais humanos. Em seu estado atual, a IA encontra apenas algumas aplicações especializadas como ferramentas de apoio à decisão para médicos, mas não há dúvida de que, no futuro próximo, substituirá algumas das tarefas realizadas nesta área de estudo.

Muitos especialistas acreditam que técnicas de detecção de anomalias em imagens baseada em inteligência artificial irá superar com grande margem a capacidade de profissionais bem treinados, e uma das razões é a maneira como o Big Data será usado. O diagnóstico por imagem é uma tarefa essencialmente visual, ou seja, quanto mais imagens o profissional vê ao



longo de sua profissão, melhor ele será no diagnóstico. Um profissional da saúde com 30 anos de experiência terá visto provavelmente algumas centenas de casos, mas um computador baseado em aprendizado profundo pode ter acesso a milhares deles.

De acordo com Saba *et al.* (2019), na área da saúde, o potencial é imenso devido à necessidade de automatizar os processos e evoluir paradigmas livres de erros. A enorme quantidade de publicações relacionadas ao tema na área da saúde superou outros domínios que cresceram em um ritmo muito acelerado. É, portanto, imperativo para os cientistas aprender sobre DL e como ele difere de outras abordagens da Inteligência Artificial (IA). Um melhor julgamento clínico, certamente vai melhorar a qualidade de vida do paciente e auxiliará os médicos nas decisões de salvar vidas, ao mesmo tempo em que reduz os custos com a saúde.

# Capítulo 3

## Fundamentos Teóricos

Conforme Sewak, Karim e Pujari (2018) houve inúmeras tentativas de reconhecer imagens por máquinas durante décadas. É um desafio imitar o sistema de reconhecimento visual do cérebro humano em um computador. A visão humana é o sistema sensorial mais difícil de imitar e o mais complexo do cérebro.

Os objetos no mundo físico são tridimensionais, enquanto as imagens desses objetos são bidimensionais. Em 1963, o cientista da computação Larry Roberts, também conhecido como o pai da visão computacional, descreveu a possibilidade de extrair informações geométricas 3D de vistas em perspectiva 2D de blocos em sua dissertação de pesquisa intitulada *Block World*. Esta foi a primeira descoberta no mundo da visão computacional. Muitos pesquisadores em todo o mundo em aprendizado de máquina e inteligência artificial acompanharam este trabalho e estudaram visão computacional no contexto do *Block World*. Os seres humanos podem reconhecer blocos independentemente de qualquer orientação ou mudanças de iluminação que possam acontecer. Nesta dissertação, ele disse que é importante entender formas simples de arestas em imagens. Ele extraiu essas formas semelhantes a arestas de blocos para fazer o computador entender que esses dois blocos são iguais, independentemente da orientação.

O início da visão computacional teve como principal objetivo basear-se em estruturas simples das imagens como pontos, linhas e arestas, sendo este o primeiro modelo de engenharia. David Mark, um cientista de visão computacional do Instituto de Tecnologia de Massachusetts - MIT, deu o próximo conceito importante, que a visão computacional é hierárquica e que uma imagem consiste de várias camadas. Esses dois princípios formaram a base da arquitetura de aprendizado profundo, embora não tenha ficado explícito o tipo de modelo matemático usado.


Segundo Sewak, Karim e Pujari (2018), na década de 1970, o primeiro algoritmo de reconhecimento visual, conhecido como modelo de cilindro generalizado, veio do laboratório de IA da Universidade de Stanford. A ideia principal deste trabalho é que o mundo é composto de formas simples e qualquer objeto do mundo real é uma combinação dessas formas simples. Ao

mesmo tempo, outro modelo, conhecido como estrutura pictórica, foi publicado pela SRI Inc. O conceito ainda é o mesmo do cilindro generalizado, mas as partes são conectadas por molas; assim, introduziu um conceito de variabilidade. O primeiro algoritmo de reconhecimento visual foi usado em uma câmera digital pela Fujifilm em 2006.

### 3.1 Interpretação das Imagens pelo Computador

De acordo com Sewak, Karim e Pujari (2018), cada imagem pode ser representada como uma matriz de valores de pixels. Em outras palavras, as imagens podem ser representadas por uma função  $f$  que fornece o valor de intensidade da luz na posição  $(x, y)$ . Na prática, o valor da função varia apenas de 0 a 255. A Figura 3.1 apresenta um exemplo de uma imagem no formato preto e branco formada por 4 pixels sendo representado por uma matriz de pixels bidimensional de duas linhas e duas colunas, matrizes as quais são interpretadas pelo computador.

Figura 3.1: Pixel de Imagens Preto e Branco.




Uma imagem colorida também é uma função, mas, neste caso, um valor em cada posição  $(x, y)$  não é um único número, e sim, um vetor que possui três intensidades de luz diferentes correspondendo a três canais de cores. Uma imagem colorida pode ser representada como uma pilha de três funções, conforme Eq. 3.1.

$$f(x, y) = [r(x, y) \ g(x, y) \ b(x, y)] \quad (3.1)$$

















A Figura 3.2 mostra uma representação dos pixels de uma imagem colorida, a qual é lida e interpretada pelo computador por uma matriz tridimensional, sendo que cada canal corresponde as cores vermelho, verde e azul.

Figura 3.2: Pixel de Imagens Coloridas.




Tem-se que cada cor possui uma numeração específica entre 0 e 255 dentro da matriz tridimensional. A Figura 3.3 apresenta alguns exemplos de nomes de cores com suas respectivas numeração RGB específica.

Figura 3.3: Numeração dos pixels.

Nome da cor	RGB	Cor
Vermelho	(255, 0, 0)	
Lima	(0, 255, 0)	
Azul	(0, 0, 255)	
Branco	(255, 255, 255)	
Preto	(0, 0, 0)	
Cinza	(128, 128, 128)	
fúcsia	(255, 0, 255)	
Amarelo	(255, 255, 0)	
Verde água	(0, 255, 255)	
Prata	(192, 192, 192)	
Marron	(128, 0, 0)	
Oliva	(128, 128, 0)	
Verde	(0, 128, 0)	
Cerceta	(0, 128, 128)	
Marinha	(0, 0, 128)	
Roxo	(128, 0, 128)	

A Figura 3.4 apresenta uma representação de uma imagem preta e branca de um boneco sorrindo, o computador interpreta a imagem pelos pixels, e os numera de acordo com a intensidade da luz. Nessa simplificação foi usada apenas as cores preta e branca.

Figura 3.4: Numeração dos pixels de uma imagem preta e branca.




Fonte: Autoria própria.

Como será apresentado a seguir, em redes neurais convolucionais, usa-se funções que interpretam valores entre 0 e 1, portanto é necessário trabalhar com imagens normalizadas, ou seja, a Eq. (3.2) mostra o procedimento de normalização dos pixels da imagem da qual se deseja trabalhar.

$$Pixel_{new} = \frac{1}{255} \times pixel \quad (3.2)$$

Figura 3.5: Normalização dos pixels.



Fonte: Autoria própria.

Conforme Rohrer (2019), para recriar uma imagem, os computadores dividem-na em pequenos pedaços chamados de pixels. Para trabalhar com imagens de alta qualidade, é necessário que os pixels sejam tão pequenos que o olho humano tenha dificuldade em separá-los individualmente. Por convenção, os valores de pixel vermelho, verde e azul são separados em suas próprias matrizes. A Figura 3.6 apresenta uma imagem de um quadro de um cachorro, no qual, usando-se recursos computacionais ampliou-se a imagem na região do olho até que seja possível a visualização dos pixels da mesma.

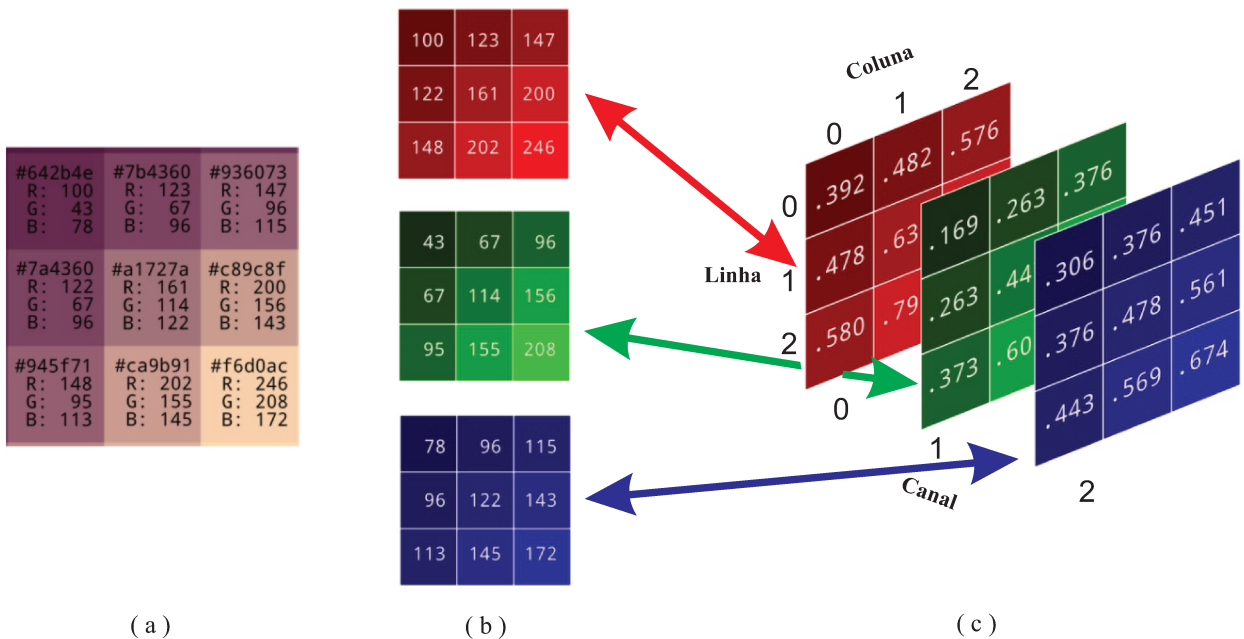
Figura 3.6: Ampliação de uma imagem.



Fonte: Adaptado de Rohrer (2019).

O computador interpreta os pixels da imagem colorida, conforme Fig.3.7(a), depois, separa esses valores em 3 canais de matrizes Fig.3.7(b) e, para trabalhar com redes neurais convolucionais é necessário realizar uma normalização nas matrizes de pixels, como pode ser observado na Fig.3.7(c).

Figura 3.7: Imagem Colorida: (a) Extração dos pixels; (b) Separação em canais de matrizes; (c) Normalização dos pixels.



Fonte: Adaptado de Rohrer (2019).

## 3.2 Redes Neurais Convolucionais

Conforme Sewak, Karim e Pujari (2018), Redes Neurais Convolucionais, do inglês (*Convolutional neural networks*), CNNs, ou ConvNets, são bastante semelhantes às redes neurais

artificiais, do inglês, (*Artificial Neural Networks*) ou ANN. Todas as técnicas usadas em ANN são válidas para CNN.

De acordo com Shanmugamani (2018), CNNs têm pesos, bias e resultados de saídas de neurônios que são influenciados por uma função de ativação. Redes neurais regulares recebem valores de entrada e os neurônios são totalmente conectados às próximas camadas, dentro da mesma camada esses não compartilham nenhuma conexão. Se for usado redes neurais regulares para imagens, elas serão muito grandes devido a um grande número de neurônios, resultando em overfitting. Redes neurais regulares não podem ser usadas para trabalhar com imagens pois essas são grandes em tamanho e isso necessitaria de grande quantidade de neurônios.

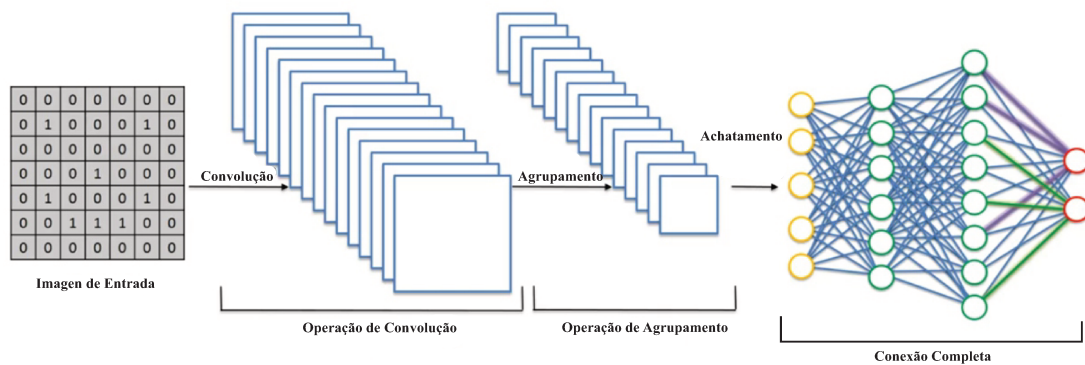
Uma diferença básica entre esses problemas de aprendizado profundo é que em ANN trabalha-se com dados dispostos em tabelas, já em CNN, trabalha-se com imagens, e como visto no seção 3.1, usa-se os valores dos pixels das imagens, ou seja, a partir das mesmas são formadas matrizes de pixels tridimensionais para os canais RGB, isto é, canais vermelho, verde e azul a partir das imagens que deseja-se analisar.

Quando trabalha-se com imagens, em CNN, é necessário fazer operações nas matrizes tridimensionais de pixels das mesmas, antes de usar os dados na rede neural. Geralmente, para se trabalhar com redes neurais convolucionais, o problema é subdividido em 4 etapas principais, sendo elas:

1. Camada de Convolução.
2. Camada de Agrupamento (*Pooling Layer*).
3. Camada de Achatamento (*Flattening*).
4. Conexão Completa (*Full Connection*).

A Figura 3.8 apresenta de forma esquemática um resumo das principais etapas de redes neurais convolucionais.


Figura 3.8: Resumo de Redes Neurais Convolucionais.



Fonte: Byun, Xu e Krishna (2020).

De acordo com Shanmugamani (2018), uma imagem pode ser considerada um volume com dimensões de altura, largura e profundidade. Profundidade é o canal de uma imagem, que é vermelho, azul e verde. Os neurônios de uma CNN são organizados de forma volumétrica. Cada uma das camadas transforma o volume de entrada em um volume de saída, conforme mostrado na imagem a seguir:

Figura 3.9: Disposição dos neurônios:(a) ANN; (b) ConvNets.



Fonte: Byun, Xu e Krishna (2020).

### 3.2.1 Camada de Convolução

O principal objetivo da convolução é extrair recursos da imagem de entrada. Esta camada faz a maior parte do cálculo em um ConvNet. Conforme Sewak, Karim e Pujari (2018), uma camada convolucional é uma pilha de mapas de recursos, com um mapa de recursos para cada filtro, a medida que aumenta-se o número de filtros aumenta-se a dimensionalidade da convolução, e isso resulta num aumento do número de parâmetros a serem avaliados pela rede neural.

Conforme Shanmugamani (2018), os filtros detectam recursos ou padrões em imagens. Quanto mais profunda a camada, mais abstrato é o padrão. Alguns estudos mostraram que essas ca-



madras têm a capacidade de detectar bordas, cantos e padrões.

Os parâmetros da camada convolucional consistem em um conjunto de filtros que podem ser aprendidos. Cada filtro é pequeno espacialmente (ao longo da largura e da altura), mas se estende por toda a profundidade do volume de entrada. Como exemplo, um filtro em uma primeira camada de um ConvNet pode ter tamanho 5x5x3 (ou seja, 5 pixels de largura e altura e 3 porque as imagens têm profundidade 3 referente aos canais de cores) (BYUN; XU; KRISHNA, 2020).

Durante a passagem para frente, desliza-se (mais precisamente, convolve-se) cada filtro ao longo da largura e da altura do volume de entrada e calcula-se produtos escalares entre as entradas do filtro e a entrada em qualquer posição. Conforme convolve-se o filtro sobre a largura e altura do volume de entrada, produz-se mapas de ativação bidimensional que fornecem as respostas desse filtro em cada posição espacial.


Em uma CNN, pode-se controlar o comportamento da camada convolucional especificando o número e o tamanho de cada filtro. Para aumentar o número de nós em uma camada convolucional, pode-se aumentar o número de filtros e, para aumentar o tamanho do padrão, pode-se aumentar o tamanho do filtro.

Conforme Shanmugamani (2018), *Kernel* é o parâmetro da camada de convolução usado para convolver imagens, esse, possui dois fatores, chamados de tamanho e passo, do inglês *size* e *stride* respectivamente. O tamanho do *kernel* pode ser qualquer dimensão de um retângulo. O passo do *kernel* é o número de pixels movidos na convolução, ou seja, este parâmetro controla como o filtro convolve sobre os pixels da matriz de entrada, se esse parâmetro for definido como 1, o filtro se moverá em 1 pixel por vez e se for 2, o filtro se moverá 2 pixels por vez e assim por diante. Outro parâmetro muito usado nesta camada de convolução é chamado de preenchimento, do inglês *padding* da imagem ajudará a obter o mesmo tamanho da entrada.

### 3.2.2 Camada de Agrupamento (*Pooling Layer*)

Segundo Shanmugamani (2018), a camada de agrupamento é posicionada após a camada de convolução, como pode se observar na Fig. 3.10 e geralmente, usa-se os dados dessa camada convolucional como valores de entrada.

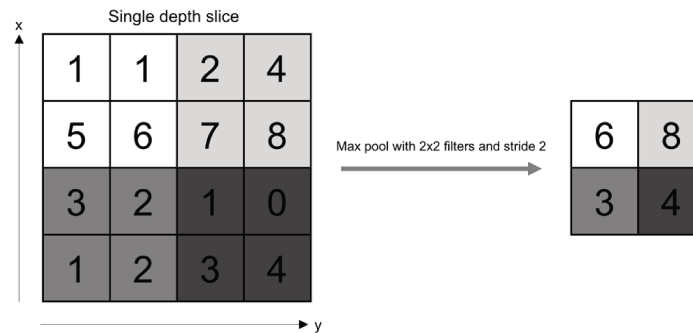
Figura 3.10: ConvNet simples.



Fonte: Sewak, Karim e Pujari (2018)

A abordagem *pooling* mais comumente usada atualmente é o pooling máximo, do inglês *max pooling*. Essa abordagem, seleciona o elemento máximo do mapa de recursos (mapa de características) e o resultado contém características importantes da convolução, a Fig 3.11 apresenta um exemplo de cálculo usando-se este método. Outra abordagem é o pooling médio, do inglês *average pooling* que envolve o cálculo médio do mapa de recursos.

Figura 3.11: Pooling máximo.



Fonte: Shanmugamani (2018).

A camada de agrupamento (pooling layer) reduz o número de parâmetros da camada convolucional e conseqüentemente o tempo de computação. Esta camada possui dois parâmetros principais, sendo eles: o passo de agrupamento e o tamanho do agrupamento, do inglês *pool size* e *pool stride*. O tamanho do agrupamento é a dimensão de um retângulo e o passo do agrupamento possui mesmo significado do passo do kernel, ou seja, o número de pixels que o filtro se moverá no agrupamento.

### 3.2.3 Camada de Achatamento (*Flattening*)

A operação de agrupamento, como visto no Cap. 3.2.2, gera uma matriz de dados com as características principais das imagens, e para que esses dados sejam interpretados pela rede neural, os mesmos devem ser transformados na forma de um vetor coluna, ou seja, uma matriz de dimensões  $(l, c = 1)$ , onde  $l$  é o número de linhas e  $c$  é o número de colunas. Basicamente, esta operação pega os números linha a linha da matriz e os ordena em uma coluna.

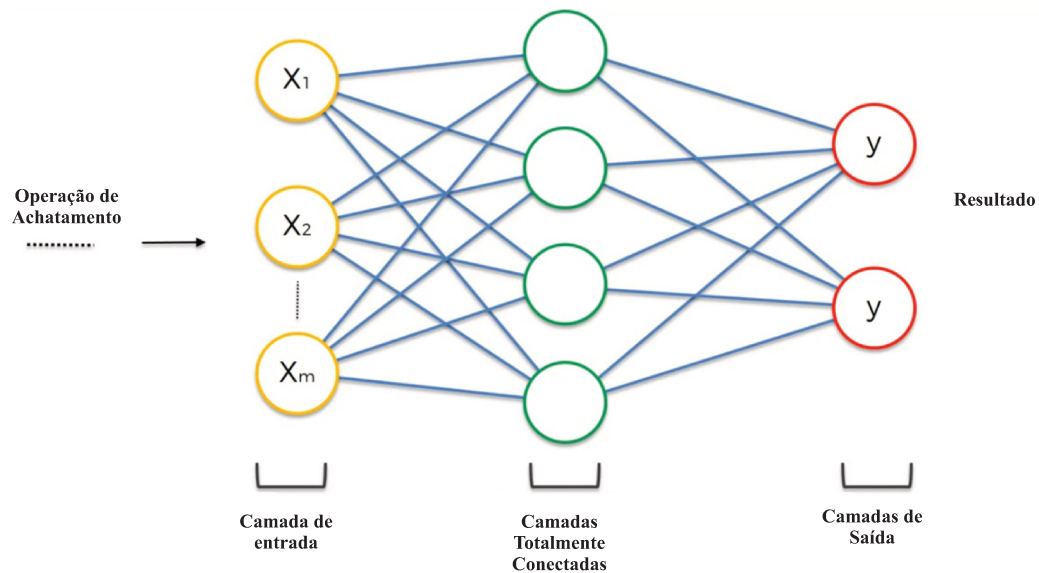
### 3.2.4 Conexão Completa (*Full Connection*)

A camada totalmente conectada parece uma rede neural regular que conecta todos os neurônios e forma as últimas camadas da rede, ou seja esta etapa adiciona uma rede neural artificial a rede neural convolucional. A camada de entrada contém os dados da imagem já tratados pelas operações anteriores. Isto significa que a rede neural recebe dados de entrada como um único vetor e passa esses dados por uma série de camadas ocultas. Cada camada oculta consiste em

um conjunto de neurônios, em que cada um deles está totalmente conectado a todos os outros neurônios da camada anterior. Em uma única camada, cada neurônio é completamente independente e os mesmos não compartilham nenhuma conexão entre si, ou seja, em uma camada totalmente conectada, os neurônios entre duas camadas adjacentes são conectados aos pares, mas não compartilham nenhuma conexão dentro da mesma camada a qual pertence.

A última camada, também chamada de camada de saída, contém resultados de diferentes classes, no caso de um problema de classificação de imagem. Na Figura 3.12, a camada de entrada consiste em três entradas, representadas por  $x_1$ ,  $x_2$  e  $x_3$ .

Figura 3.12: Conexão completa.




Fonte: Byun, Xu e Krishna (2020).

### 3.3 Redes Neurais

Conforme Finocchio (2014), todas as redes neurais são compostas por elementos matemáticos denominados neurônios, também chamados de nó. O neurônio pode ser entendido pela Fig. 3.13, que representa a estrutura de um neurônio.

Figura 3.13: Estrutura de um neurônio.



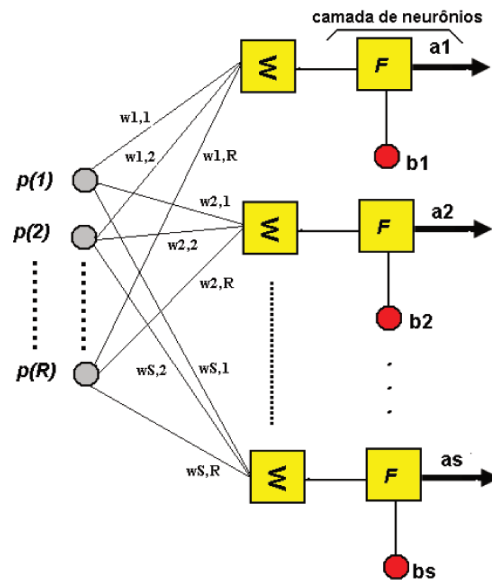
Fonte: Finocchio (2014).

Onde,  $p$  é a entrada de sinal,  $w$  é o peso,  $b$  é o termo linear (bias),  $F$  é a função do neurônio (transferência ou ativação) e  $a$  é a saída de sinal. Os termos  $w$  e  $b$  são parâmetros ajustáveis (livres, variáveis) do neurônio e da rede neural. Na Seção 3.4 será mostrado os tipos de inicialização desses parâmetros, o termo  $F$  será abordado com mais detalhes no Seção 3.5 e tem como objetivo transformar os sinais combinados de entrada no sinal de saída  $a$ . Em termos matemáticos a estrutura do neurônio pode ser representada pela Eq. (3.3).

$$a = F(w.p + b) \quad (3.3)$$

Em redes neurais convolucionais, usa-se muitos valores de entrada de sinais com várias camadas de neurônios para receber esses sinais de entrada, a primeira camada de neurônios é chamada de camada de entrada. A representação dessa camada de neurônios pode ser representada pela Fig. 3.14.

Figura 3.14: Estrutura da camada de entrada.



Fonte: Finocchio (2014).

Nesse caso, cada sinal de entrada está ligado a cada neurônio através de um peso, sendo  $R$  sinais de entrada e  $S$  neurônios na camada de saída, serão  $R \times S$  pesos e  $S$  bias que se agrupam em matriz de pesos e vetores de bias. A Expressão matemática pra este caso é dada por

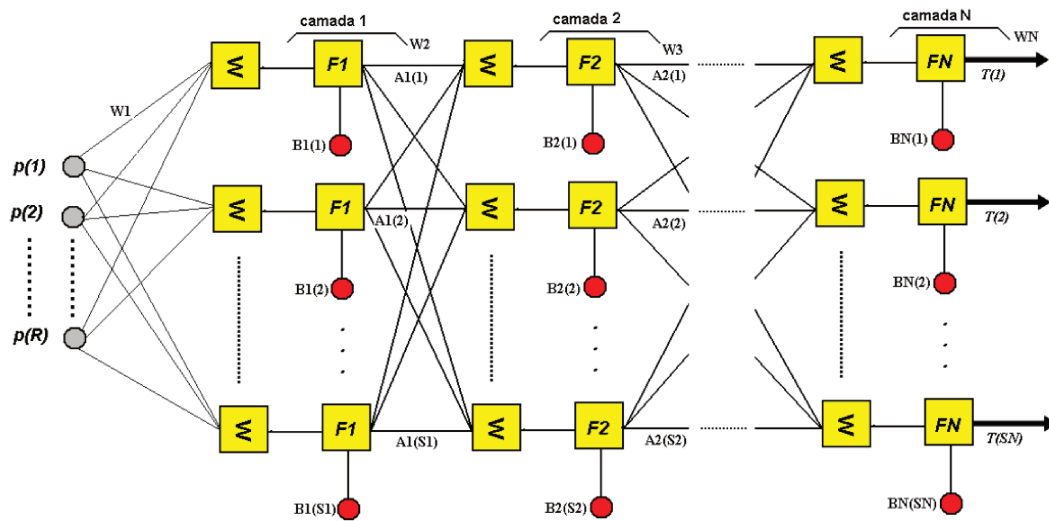
$$\vec{a}_{S,1} = F(W_{S,R} \cdot \vec{p}_{R,1} + \vec{b}_{S,1}) \quad (3.4)$$

onde:

$$\vec{a}_{S,1} = \begin{bmatrix} a_{1,1} \\ a_{2,1} \\ \vdots \\ a_{S,1} \end{bmatrix}; \quad W_{S,R} = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{S,1} & w_{S,2} & \cdots & w_{S,R} \end{bmatrix}; \quad \vec{p}_{R,1} = \begin{bmatrix} p_{1,1} \\ p_{2,1} \\ \vdots \\ p_{R,1} \end{bmatrix}; \quad \vec{b}_{S,1} = \begin{bmatrix} b_{1,1} \\ b_{2,1} \\ \vdots \\ b_{S,1} \end{bmatrix}$$

Sabe-se que em aprendizado de máquinas, *Machine Learning*, usa-se apenas uma camada escondida, já em Aprendizado Profundo, *Deep Learning*, a rede neural possui mais de uma camada escondida podendo ser infinitas camadas compostas por neurônios, dispostos em sequência, como pode ser observado na Figura 3.15. Finocchio (2014) mostra como é feito os cálculos quando usa-se várias camadas escondidas.

Figura 3.15: Estrutura das camadas intermediárias.




Fonte: Finocchio (2014).

Onde,  $N$  é o número de camadas, cada uma com  $S_i$  neurônios na camada  $i$ , com  $i = 1, 2, \dots, N$ . As funções de transferência em cada camada são representadas pela letra  $F$ , o problema possui  $R$  entradas organizadas no vetor  $\vec{P}$ , matrizes de pesos  $W$  e vetores de bias  $\vec{B}_i$  para cada camada.

A Figura 3.16 apresenta uma estrutura típica de rede neural, a qual é caracterizada por dados de entrada que se propagam até saída, através de uma sucessão de aplicações de pesos, bias e funções de transferência ou seja as redes neurais são sequências de multiplicações e somas de matrizes e aplicações de funções de transferência.

Figura 3.16: Representação Matemática.



Fonte: Finocchio (2014).

Onde:

$$\vec{A}_1 = F_1(\vec{W}_1 \cdot \vec{P} + \vec{B}_1) \quad \vec{A}_2 = F_2(\vec{W}_2 \cdot \vec{A}_1 + \vec{B}_2) \quad \vec{T} = F_N(\vec{W}_N \cdot \vec{A}_{N-1} + \vec{B}_N)$$

Segundo Finocchio (2014), no estudo de redes neurais é necessário conhecer os dados de entrada e os dados de saída, ou seja  $P$  e  $A_N = T$ . As matrizes de pesos  $W$  e os vetores de bias  $B$ , tanto para cada camadas quanto para cada neurônio são estimados, de modo que a rede seja

capaz de reproduzir os dados de saída com os dados de entrada a partir de uma correlação entre os dados de entrada e saída.

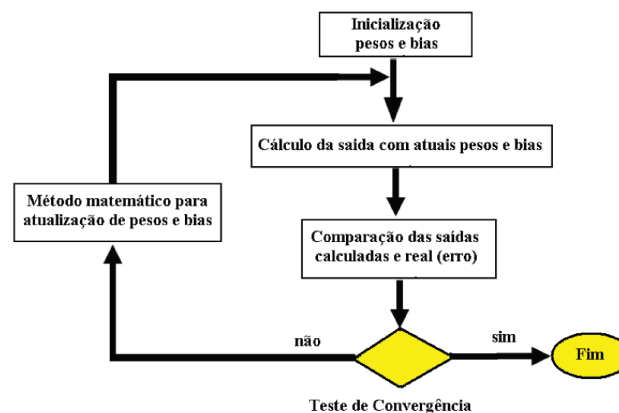
### 3.4 Pesos e vieses (*Bias*)

Como mencionado anteriormente, as matrizes de pesos  $W$  e os vetores de bias  $B$  são estimados para cada neurônio, de modo que a rede seja capaz de reproduzir os dados de saída com os dados de entrada a partir de uma correlação entre os dados de entrada e saída. Existem muitas propostas de inicialização das matrizes de peso e dos vetores de bias. Os primeiros métodos de inicialização desses parâmetros foram propostos antes de 2006. Inicialmente, usou-se matriz com todos elementos unitários, matriz nula, matriz identidade, matriz constante. Observou-se uma necessidade de gerar melhores formas de inicialização destes parâmetros, pois são extremamente importantes para convergência da rede neural.

Glorot e Bengio (2010a) propôs uma nova forma de inicializar as matrizes de peso com uma convergência mais rápida e conhecida atualmente por *Glorot Normal* também chamada de inicializador Xavier normal, uma segunda forma de inicialização dos pesos também proposta pelo autor é a *Glorot Uniform* também chamada de inicializador Xavier uniforme.

Uma das formas mais recentes de inicialização dos pesos proposta com ênfase no estudo de aprendizado profundo foi desenvolvida por Saxe, McClelland e Ganguli (2014), a qual pertence a uma nova classe de condições iniciais ortogonais aleatórias em pesos. Saxe, McClelland e Ganguli (2013).

Figura 3.17: Atualização dos Pesos e Bias.



Fonte: Finocchio (2014).

## 3.5 Função de Ativação

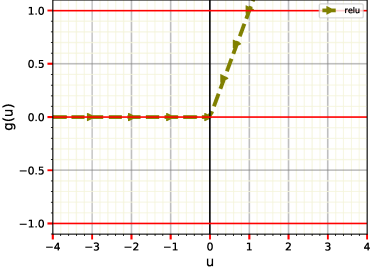
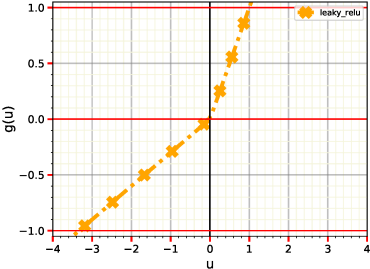
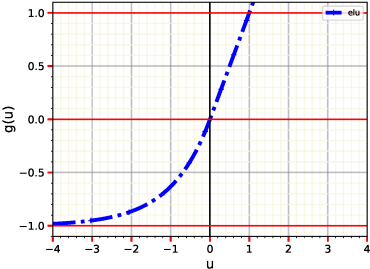
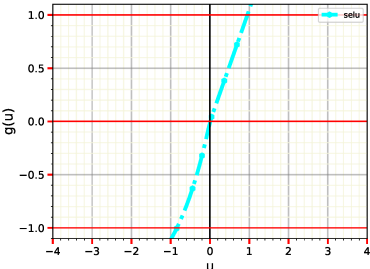
Uma função de ativação, do inglês (*activation function*), são equações matemáticas usadas em modelos de aprendizado profundo. Teoricamente, qualquer função diferencial pode ser usada como uma função de ativação. Existem muitos tipos de funções de ativação e todas tem como objetivo principal ajudar na capacidade e na velocidade de convergência dos resultados da rede neural. As mesmas são anexadas a cada neurônio e determinam os valores das saídas do modelo de aprendizado profundo. Além disso, as funções de ativação normalizam os valores de saída de cada neurônio para um intervalo entre 0 e 1 ou entre -1 e 1.

Em uma rede neural, os dados de entrada provenientes do banco de dados são enviados para os neurônios na camada de entrada. Cada neurônio tem um peso, e multiplicar o valor da entrada pelo peso resulta nos valores de saída do neurônio, que são transferidos para a próxima camada.

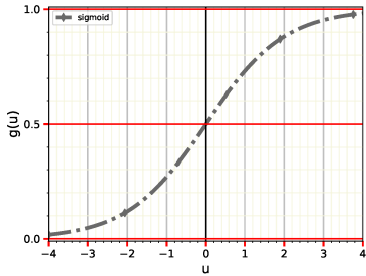
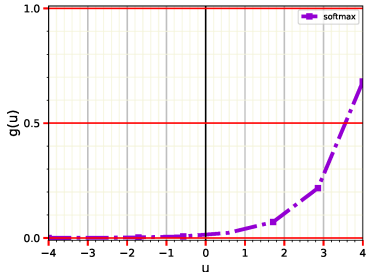
Cada vez mais, as redes neurais usam funções de ativação não lineares, que podem ajudar a rede a aprender dados complexos, calcular quase todas as correlações e fornecer previsões precisas.

Redes neurais modernas usam uma técnica chamada retropropagação *backpropagation* para treinar o modelo, este método usa tanto a função de ativação quanto a derivada da mesma para encontrar máximos e mínimos de funções, por isso deve-se escolher funções de ativação para camadas ocultas e de saída que são diferenciáveis, pois sua derivada é usada para efetuar o cálculo do erro para determinar as atualizações dos parâmetros da rede neural que requerem o gradiente da função de ativação para atualizar a camada. As funções de ativação mais usadas são mostradas na Tabela abaixo.



Função	Equação	Gráfico
Relu	$\text{relu}(u) = \begin{cases} u & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases}$	
Lrelu	$\text{Lrelu}(u) = \begin{cases} u & \text{se } u \geq 0 \\ 0.3 \cdot u & \text{se } u < 0 \end{cases}$	
Elu	$\text{elu}(u) = \begin{cases} u & \text{se } u > 0 \\ \alpha(e^u - 1) & \text{se } u \leq 0 \end{cases}$	
Selu	$\text{selu}(u) = \lambda \begin{cases} u & \text{se } u > 0 \\ \alpha(e^u - 1) & \text{se } u \leq 0 \end{cases}$	

Função	Equação	Gráfico
Tanh	$\tanh(u) = \frac{\sinh(u)}{\cosh(u)}$	
Exponential	$\text{exponential}(u) = e^u$	
Softplus	$\text{softplus}(u) = \log(e^u + 1)$	
Softsign	$\text{softsign}(u) = \frac{u}{\text{abs}(u) + 1}$	

Função	Equação	Gráfico
Sigmoid	$\text{sigmoid}(u) = \frac{1}{1 + e^{(-u)}}$	 <p>O gráfico mostra a função Sigmoid, uma curva em forma de S que varia de 0 a 1. O eixo horizontal é rotulado 'u' e varia de -4 a 4. O eixo vertical é rotulado 'g(u)' e varia de 0.0 a 1.0. A curva passa pelo ponto (0, 0.5). Há uma linha horizontal vermelha em g(u) = 0.5 e uma linha vertical preta em u = 0.</p>
Softmax	$\text{softmax}(u_i) = \frac{e^{u_i}}{\sum_{j=1}^n e^{u_j}}$	 <p>O gráfico mostra a função Softmax, uma curva que varia de 0 a 1. O eixo horizontal é rotulado 'u' e varia de -4 a 4. O eixo vertical é rotulado 'g(u)' e varia de 0.0 a 1.0. A curva permanece próxima de 0 para valores negativos e aumenta rapidamente para 1 para valores positivos. Há uma linha horizontal vermelha em g(u) = 0.5 e uma linha vertical preta em u = 0.</p>

### 3.5.1 Relu

Unidade linear retificada, do inglês *Rectified linear unit*, usada por (NAIR; HINTON, 2010) é uma das funções de ativação mais usadas e é definida como:

$$\text{relu}(u) = \begin{cases} u & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (3.5)$$

### 3.5.2 Leaky Relu

Unidade Linear retificada com vazamento, do inglês *Leaky rectified linear (LRelu)*, proposta por Xu *et al.* (2015) para reduzir problemas causados pela função de ativação Relu para  $u < 0 = 0$ , essa função foi avaliada para valores diferentes de zero no intervalo em questão e verificou-se que isso permite um pequeno gradiente diferente de zero quando a unidade está saturada e inativa.

$$\text{Lrelu}(u) = \begin{cases} u & \text{se } u \geq 0 \\ 0,01.u & \text{se } u < 0 \end{cases} \quad (3.6)$$

### 3.5.3 Elu

Unidade Linear Exponencial, do inglês *Exponential Linear Unit (elu)*, introduzida por Clevert, Unterthiner e Hochreiter (2016), representado pela Eq. (3.7), onde,  $\alpha = 1$ , valor usado

pelo autor em suas análises.

$$\text{elu}(u) = \begin{cases} u & \text{se } u > 0 \\ \alpha(e^u - 1) & \text{se } u \leq 0 \end{cases} \quad (3.7)$$

### 3.5.4 Selu

Unidade Linear Exponencial Escalada, do inglês *The Scaled Exponential Linear Unit (selu)*, proposta por Klambauer *et al.* (2017), representado pela Eq.(3.8), onde,  $\lambda = 1.05070098$  e  $\alpha = 1.67326324$ . Esses valores foram escolhidos de forma com que a média e a variância dos pesos nas entradas sejam preservadas entre duas camadas consecutivas.

$$\text{selu}(u) = \lambda \begin{cases} u & \text{se } u > 0 \\ \alpha(e^u - 1) & \text{se } u \leq 0 \end{cases} \quad (3.8)$$

### 3.5.5 Softplus

Conforme Glorot, Bordes e Bengio (2011), a função softplus é uma função de ativação que possui uma certa aproximação com a função ReLU e pode ser usada para restringir a saída de cada neurônio a valores de saída a ser sempre positiva.

$$\text{softplus}(u) = \log(e^u + 1) \quad (3.9)$$

### 3.5.6 Softsign

Conforme Glorot e Bengio (2010b) a função softsign é uma função de ativação que redimensiona os valores entre -1 e 1 aplicando um limite como uma função sigmóide. A vantagem, ou seja, o valor de um softsign é centrado em zero, o que ajuda o próximo neurônio durante a propagação.

$$\text{softsign}(u) = \frac{u}{\text{abs}(u) + 1} \quad (3.10)$$

### 3.5.7 Sigmoid, Logistic ou Soft Step

A função de ativação sigmoid é comumente utilizada por redes neurais com propagação positiva (Feedforward) que precisam ter como saída apenas números positivos, normalmente utilizada na camada de saída para problemas de classificação binária.

$$\text{sigmoid}(u) = \frac{1}{1 + e^{(-u)}} \quad (3.11)$$

### 3.5.8 Softmax

De acordo com Goodfellow, Bengio e Courville (2016), a função softmax transforma um vetor de números reais em um vetor de probabilidades. Cada probabilidade no resultado está no intervalo  $0 \dots 1$ , e a soma das probabilidades é 1.

$$\text{softmax}(u_i) = \frac{e^{u_i}}{\sum_{j=1}^n e^{u_j}} \quad (3.12)$$

## 3.6 Função de Perda (*Loss Function*)

Sabe-se que redes neurais aprendem através do processo de ajuste dos pesos das entradas em cada camada. Para o ajuste desses pesos é necessário uma forma de calcular o quão próximo um resultado estimado está do valor correto, e para isso se faz necessário usar uma função erro, também conhecida como função objetivo. Ou seja, usa-se a mesma para minimizar os parâmetros no conjunto de dados.

Em aprendizado profundo, existe uma diferença na nomeação destas funções erro, sendo que em Redes Neurais Convolucionais (CNN), a mesma recebe o nome de função perda, do inglês *Loss Function*, já em Redes Neurais Artificiais (ANN), recebe o nome de função custo, do inglês *Cost Function*.

Uma, frequentemente usada, é o erro quadrático médio ou *Mean Square error*, que mede a diferença entre o estimador (o conjunto de dados) e o valor estimado (a previsão), sendo a mesma muito usada em problemas de regressão. Outra função erro muito conhecida é a entropia cruzada ou *Cross-Entropy*, usada em problemas de classificação.

Estas funções permitem quantificar a qualidade de qualquer conjunto particular de pesos  $W$ . O objetivo da otimização, como será mostrado na Seção 3.7 é encontrar o conjunto de peso  $W$  que minimize a função de perda ou função erro.

## 3.7 Algoritmos de Otimização de Gradiente Descendente

Conforme Ruder (2016), o gradiente descendente, representado pela Eq. (3.13) é um dos algoritmos mais populares para realizar a otimização e a maneira mais comum de otimizar redes neurais.

Segundo Shanmugamani (2018), o algoritmo gradiente descendente realiza otimização multidimensional. Além disso, existem várias implementações deste algoritmo, sendo que o mais comum é chamado de descida do gradiente estocástico (SGD). A otimização envolve o cálculo


do valor do erro e a alteração dos pesos para atingir o erro mínimo.

$$\theta(t+1) = \theta(t) - \eta \cdot \nabla_{\theta} J(\theta) \quad (3.13)$$

A Equação (3.13) mostra a fórmula de otimização Gradiente Descendente, onde,  $\theta$  é o parâmetro do modelo analisado,  $\nabla_{\theta} J(\theta)$  é a função objetivo,  $\eta$  é a taxa de aprendizagem. A Equação (3.13) pode ser simplificada usando os termos  $g_t = \nabla_{\theta} J(\theta)$  e  $\Delta\theta_t = -\eta \cdot g_t$ .

$$\theta_t = \theta_t + \Delta\theta_t \quad (3.14)$$


Figura 3.18: Otimização com Gradiente Descendente.



Fonte:Ruder (2016).

Um dos desafios deste método é a escolha da taxa de aprendizagem  $\eta$ , uma taxa de aprendizado muito pequena leva a uma convergência lenta, enquanto uma taxa de aprendizado muito grande pode impedir a convergência e fazer com que a função de perda flutue em torno do mínimo ou até mesmo divirja.

Figura 3.19: Taxa de aprendizagem: (a) Pequena; (b) Grande.



Fonte: Adaptado de Srivastava *et al.* (2014).

A seguir, apresenta-se alguns algoritmos que são amplamente usados pela comunidade de Deep Learning para lidar com problemas de otimização e de convergência deste método.

### 3.7.1 SGD

Descida do gradiente estocástico, do inglês *Stochastic gradient descent (SGD)*, é usado com uma taxa de aprendizagem constante, normalmente igual a 0,01.

$$\Delta\theta_t = -\eta \cdot g_t \quad (3.15)$$

### 3.7.2 AdaGrad

Algoritmo de Gradiente Adaptativo, do inglês *Adaptive Gradient Algorithm (AdaGrad)*, proposto por Duchi, Hazan e Singer (2011), representou uma inovação nos algoritmos de otimização pois o algoritmo em questão tem a capacidade de modificar a taxa de aprendizagem  $\eta$  com base nos gradientes anteriores que foram calculados para  $\theta$ . Na Eq. (3.16), o termo  $\epsilon$  é um termo de suavização que evita a divisão por zero (geralmente na ordem de  $e^{-8}$ ) e  $G_t$  é uma matriz diagonal onde cada elemento da diagonal é a soma dos quadrados dos gradientes  $\theta$  até o passo de tempo  $t$  em análise.

$$\Delta\theta_t = -\frac{\eta}{\sqrt{G_t + \epsilon}} \cdot g_t \quad (3.16)$$

### 3.7.3 Adadelta

Proposto por Zeiler (2012), esta técnica é uma extensão do Adagrad, este método acumula os gradientes quadrados anteriores, representado pelo termo, onde  $E[g^2]_t$  é uma média no intervalo de tempo  $t$  e  $\gamma = 0.9$

$$\Delta\theta_t = -\frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} \cdot g_t \quad (3.17)$$

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma)g_t^2 \quad (3.18)$$

### 3.7.4 RMSprop

Propagação da Raiz Quadrada Média, do inglês *Root Mean Square Propagation (RMSProp)* é um algoritmo de otimização projetado para redes neurais, proposto pela primeira vez por Hinton G.; Srivastava N. (2012) na aula do curso online de redes neurais para aprendizado de máquinas.

Desenvolvido independentemente de Adadelta e na mesma época. Também é um dos métodos de taxa de aprendizagem adaptativa - famoso por não ter sido publicado. Entretanto, é conhecido e a maioria das estruturas de aprendizado profundo incluem este algoritmo.

$$\Delta\theta_t = -\frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} \cdot g_t \quad (3.19)$$

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma)g_t^2 \quad (3.20)$$

O autor sugere que o parâmetro de decaimento seja  $\gamma = 0.9$  e que a taxa de aprendizagem seja  $\eta = 0.001$

### 3.7.5 Adam

Estimativa de Momento Adaptativo, do inglês *Adaptive Moment Estimation (Adam)*, proposto por Kingma e Ba (2015) é outro método de otimização que calcula as taxas de aprendizado os quais são adaptados para cada parâmetro.

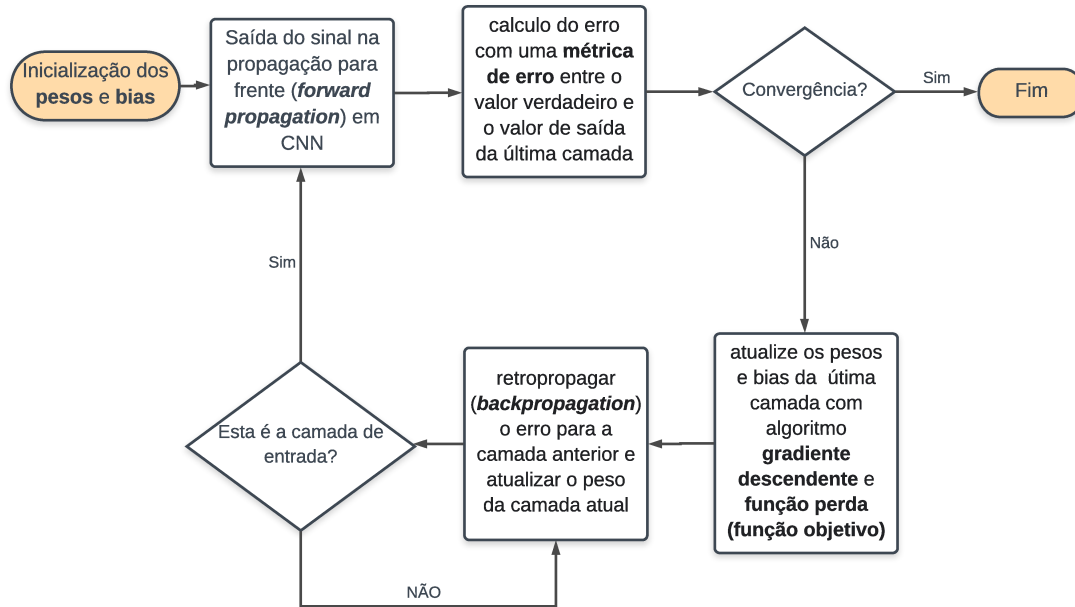
## 3.8 Backpropagation

O algoritmo retropropagação, do inglês *backpropagation*, usa o cálculo do erro obtido da função de perda na camada de saída da rede neural para recalcular os valores dos pesos da matriz  $w$  da última camada de neurônios com a técnica de otimização gradiente descendente e, assim, proceder para as camadas anteriores, de trás para frente, ou seja, atualizar todos os pesos  $w$  das camadas a partir da última até atingir a camada de entrada da rede, para isso realiza-se a retropropagação do erro obtido pela rede em estudo.

Para ser mais preciso, é necessário descobrir quais valores de peso e bias produzem o menor erro. Objetiva-se encontrar o peso que representa corretamente os sinais contidos nos dados de entrada e os traduz para uma classificação correta.



Figura 3.20: Esquema de atualização dos pesos com uso do algoritmo de retropropagação.




Fonte: Autoria própria.

### 3.9 Overfitting e Regularização em Redes Neurais

No estudo de redes neurais existem problemas com sobreajuste, do inglês *overfitting*, que ocorre quando um modelo é bom para classificar ou prever os dados conjunto de treinamento, mas não é bom em classificar ou prever os dados no conjunto de teste, pode-se dizer que o modelo aprendeu os dados fornecidos no conjunto de treinamento, mas se os dados desviarem um pouco dos dados de teste, o modelo não é capaz de prever ou classificar com precisão. As Figuras 3.21 mostram curvas cujo eixo y apresenta o valor obtido pela função erro, e no eixo x o número de épocas que representa cada iteração ao longo do conjunto de treinamento rumo ao mínimo (convergência) do conjunto de dados. A Figura 3.21 (a) mostra um caso de uma rede neural treinada na qual o modelo é capaz de prever dados desejados, ou seja, o erro entre os conjuntos de treinamento e teste é muito pequeno. Já a Figura 3.21 (b) mostra um caso de *overfitting*, onde existe um valor de época que é o ponto crítico onde o erro de treinamento do conjunto teste diverge do treinamento.

Figura 3.21: Problemas em Redes Neurais: (a) Sem Overfitting; (b) Com Overfitting.




Fonte: Adaptado de Srivastava *et al.* (2014).

Conforme Shanmugamani (2018), existem três maneiras possíveis de evitar ou atenuar o overfitting, sendo que a primeira é o de aumentar a quantidade de dados de treinamento. Um segundo método possível é reduzir o tamanho da rede neural, no entanto, redes grandes possuem o potencial de serem mais precisas do que redes pequenas e essa é uma opção que só deve ser adotada caso o terceiro método não seja eficaz, já esta metodologia está relacionado ao uso de técnicas de regularização que serão apresentadas a seguir.

### 3.9.1 Eliminação (*Dropout*)

Uma rede neural pode ser considerada um problema de pesquisa. Cada nó na rede neural procura correlação entre os dados de entrada e os dados de saída. Conforme Srivastava *et al.* (2014), dropout desativa os nós aleatoriamente durante a propagação para frente e, portanto, ajuda a evitar que os pesos convergem para posições idênticas. Depois de fazer isso, ele ativa todos os nós e se propaga de volta. Usa-se o dropout apenas durante o treinamento, logo, não se deve usa-lo no conjunto de dados de teste.

Figura 3.22: Modelo de rede neural de eliminação: (a) Rede Neural Padrão; (b) Rede Neural com Dropout.



Fonte: Adaptado de Srivastava *et al.* (2014).

### 3.9.2 Eliminação espacial (*SpatialDropout2D*)

Outro método de regularização muito usado em redes neurais foi proposto por Tompson *et al.* (2014). Essa técnica executa a mesma função que Dropout, no entanto, ela descarta mapas completos de recursos 2D em vez de elementos individuais. Se os pixels adjacentes nas matrizes estiverem fortemente correlacionadas (como é normalmente no caso das primeiras camadas de convolução), então o abandono regular não regularizará as ativações e, de outra forma, apenas resultará em uma diminuição efetiva da taxa de aprendizagem.


# Capítulo 4

## Metodologia

Como mencionado anteriormente, este trabalho tem como objetivo usar a técnica de inteligência artificial, mais especificamente aprendizado profundo, para estimar a localização do posicionamento de tumores usando apenas imagens térmicas da superfície da pele da mama obtidas por uma câmera infravermelha ou por uma malha de termopares superficiais. Para validação da técnica, usou-se imagens termográficas simuladas. Portanto, etapas possíveis para o desenvolvimento do trabalho podem ser vistas no fluxograma da Fig. 4.2, na qual aborda primeiramente a criação do banco de dados.

Imagens termográficas simuladas foram criadas usando-se o software comercial COMSOL *multiphysics*. Após geradas, as mesmas foram tratadas com o software Corel Drawn, pois as imagens exportadas pelo COMSOL possuem bordas com dados que não representam o comportamento térmico nem a física do problema como pode ser observado na Fig. 4.1. Caso essas imagens não fossem tratadas, aumentaria-se o número de pixels das imagens, consequentemente aumentando-se a quantidade de parâmetros avaliados pela rede neural, gerando-se assim, um maior custo computacional e maior fonte de erros no modelo.

Figura 4.1: Bordas das imagens que não representam o problema físico e dificultam o modelo de aprendizagem.



O trabalho de aprendizado profundo foi completamente feito usando-se python como linguagem de programação e para isto usou-se o ambiente de desenvolvimento integrado (IDE),

*Jupyter notebook*. A programação em aprendizado profundo foi feita com uso de bibliotecas específicas de *deep learning*, sendo elas *keras* e *tensorflow*. As mesmas foram escolhidas por serem bibliotecas de rede neural de código aberto escritas em python e possuem grande aplicação como detectar e decifrar padrões e correlações.

No Capítulo 5 será verificado quais parâmetros dos tumores são detectáveis nos pixels das imagens térmicas, ou seja, tanto sua posição geométrica quanto suas propriedades térmicas. Feito isso, o banco de dados é criado. Sabe-se que os conjuntos de dados de treinamento e teste devem ser diferentes, e para isto, as imagens térmicas dos conjuntos de treinamento e teste são feitas alterando-se tanto as propriedades térmicas do tumor quanto valores das condições iniciais do problema térmico de forma aleatória. Observa-se que estas propriedades interferem de forma pouco significativa nas imagens térmicas em regime permanente, funcionando-se apenas como uma forma de ruídos adicionados as imagens como forma de diferenciá-las.

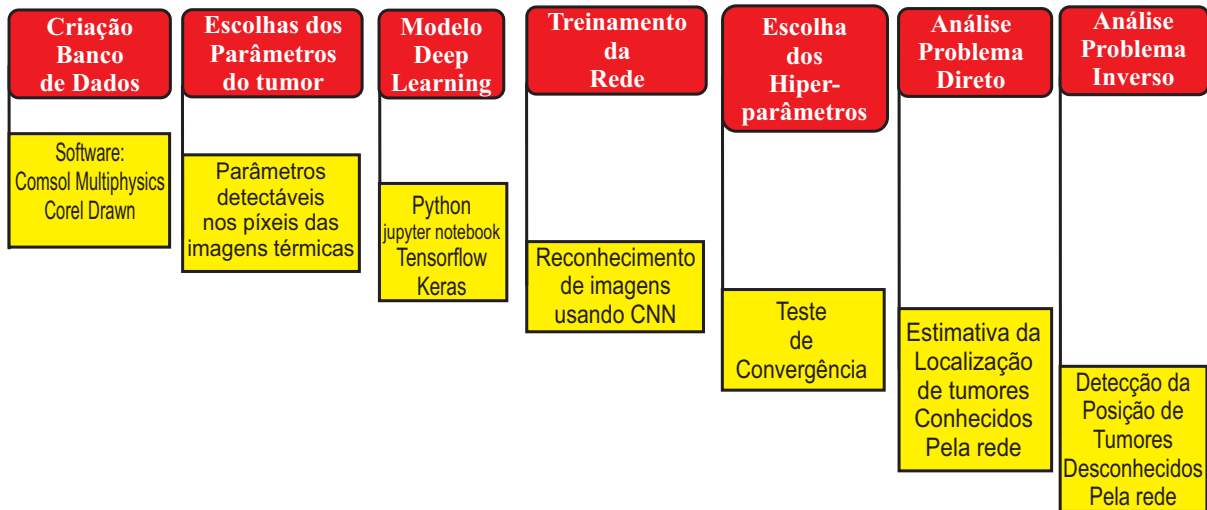
Usam-se redes neurais convolucionais como subárea da técnica de aprendizado profundo para localizar padrões ou classes de parâmetros que deseja-se avaliar nas imagens térmicas simuladas. Inicialmente cria-se um banco de dados com classes de diferentes localização de tumores. Assim, numa fase inicial, tumores são posicionados em diversas localizações em uma mama com características geométricas cartesianas. Esse procedimento apenas visa facilitar o posicionamento e recuperação da localização. No Capítulo 8 são obtidos resultados com uma mama em formato anatômica usada para treinamento de estudantes de medicina para localização de tumores através de ultrassom. Uma vez obtida a solução do problema térmico em todo o domínio, o campo de temperatura superficial é extraído.

O estudo de redes neurais convolucionais possui muitos parâmetros que podem influenciar de forma significativa na convergência do modelo, para estimar a localização de tumores em imagens térmicas superficiais tendo várias classes deste parâmetro. É muito importante que o modelo em estudo tenha uma boa acurácia e para isto tanto análise dos hiperparâmetros quanto a criação do banco de dados com parâmetros de classes que possam ser identificáveis em imagens térmicas são importantes para atingir esse objetivo.

Para validação do problema analisou-se a capacidade do programa em estimar a localização de tumores situados em posições conhecidas previamente pela rede neural convolucional, porém com imagens criadas com parâmetros térmicos diferentes. Esta análise foi chamada de problema direto.

Após, verificou-se a capacidade do modelo gerado em analisar o posicionamento de classes de tumores que não são conhecidas previamente pela rede neural, com objetivo de verificar a capacidade do modelo em considerar dentro das classes conhecidas pelo modelo a classe mais lógica para inferir a posição do novo tumor.

Figura 4.2: Etapas do trabalho, esquema adaptado de Wang e Adachi (2019).



## 4.1 Modelo Térmico

De acordo com Brioschi *et al.* (2010), os testes clínicos que usam termografia infravermelha são realizados em condições de estado estacionário. O comportamento térmico caracterizado pelo processo de transferência de calor para o problema bio-térmico pode ser expressado pela equação de Pennes em regime estacionário e sem fonte de calor externa.

$$k\nabla^2 T + w\rho_s c_s(T_a - T) + Q_m = 0 \quad (4.1)$$

onde  $k$  é a condutividade térmica do tecido,  $w$ ,  $\rho_s$  e  $c_s$ , representam respectivamente, a perfusão, a massa específica e o calor específico do sangue. A geração de calor volumétrica metabólica do tecido é dado por  $Q_m$  e  $T$  é a temperatura do tecido. O domínio do tecido está sujeito as seguintes condições de contorno:

Temperatura prescrita na superfície interna da mama

$$T(x, y, z = 0) = T_c \quad (4.2)$$

e em todas as outras superfícies do modelo cartesiano é considerado convecção térmica, com coeficiente de convecção  $h$  e temperatura ambiente  $T_\infty$ .


## 4.2 Modelo numérico

Sabe-se que a mama real é constituída de várias estruturas complexas como músculo, costela, gordura, lóbulo, mamilo, aréola, dutos, etc. Devido a geometria irregular e ao grande número

de componentes que a mama é composta, problema torna-se de difícil solução analítica, sendo indicado o uso de soluções numéricas. Para simulação do comportamento do tumor usou-se o software COMSOL *multiphysics*, o qual apresenta simulações na área da bio-transferência de calor.

Inicialmente usou-se um modelo geométrico idealizado da mama em coordenadas cartesianas, conforme apresentado na Fig. 4.3 (a). O modelo esquemático tridimensional da mama em coordenadas cartesianas é composto de uma região de tecido saudável e de um tumor esférico com localização arbitrária. As condições de contorno idealizadas onde toda a superfície externa da pele está exposta a convecção térmica do ambiente externo tendendo a zero (para aumentar a sensibilidade da foto termográfica simulada), já a superfície interna da mama está sujeita à uma temperatura constante  $T_s$  igual a temperatura interna do corpo, ou seja,  $37\text{ }^\circ\text{C}$ , e a temperatura ambiente,  $T_\infty=20\text{ }^\circ\text{C}$ .

Figura 4.3: Mama: (a) Cartesiana; (b) Semi-esférica.



As propriedades termo-físicas da mama: condutividade térmica,  $k$ , perfusão sanguínea,  $w$ , geração de calor volumétrico,  $Q_m$ , densidade,  $\rho$  e o calor específico,  $c_p$  dos tecidos biológicos usados nas simulações são listados na Tab. 4.1.


Tabela 4.1: Propriedades Termo-físicas da mama conforme os trabalhos de Agnelli, Barrea e Turner (2011) e Hossain e Mohammadi (2016).

Parâmetros	$k$ [W/mK]	$w$ [1/s]	$Q_m$ [W/m <sup>3</sup> ]	$\rho$ [kJ/m <sup>3</sup> ]	$c_p$ [J/kg.K]
Mama	0,35	$1,4 \cdot 10^{-4}$	420	1000	4186
Tumor	0,62	$1,4 \cdot 10^{-2}$	$10^5$	1000	4186

### 4.2.1 Geometria

Na Figura 4.4 observa-se o modelo geométrico tridimensional que foi usado para fazer a análise numérica. Usou-se um bloco com dimensões: 160 mm  $\times$  160 mm  $\times$  80 mm, dimensões representativas do tamanho médio de uma mama.

Figura 4.4: Modelo tridimensional: Geometria Cartesiana.




### 4.2.2 Malha Numérica

Todas as imagens termográficas usadas nas simulações numéricas apresentadas neste trabalho foram feitas no software COMSOL *multiphysics*, o qual possui soluções de problemas através do método de elementos finitos. O software disponibiliza algumas malhas relacionadas ao tamanho do elemento da mesma, sendo elas divididas em: extremamente grosseira, extra grosseira, mais grosseira, grosseira, normal, fina, mais fina, extra fina e extremamente fina.

Foi feita uma breve comparação na resposta de temperatura variando-se os tipos de malha. Conforme Fig.4.5, as malhas do tipo grosseira apresentaram uma grande incoerência nos resultados em comparação com as malhas mais refinadas, a malha normal também apresentou grande divergência em relação as malhas finas, já as malhas mais fina e extra fina apresentaram boa coerência com a malha extremamente fina.



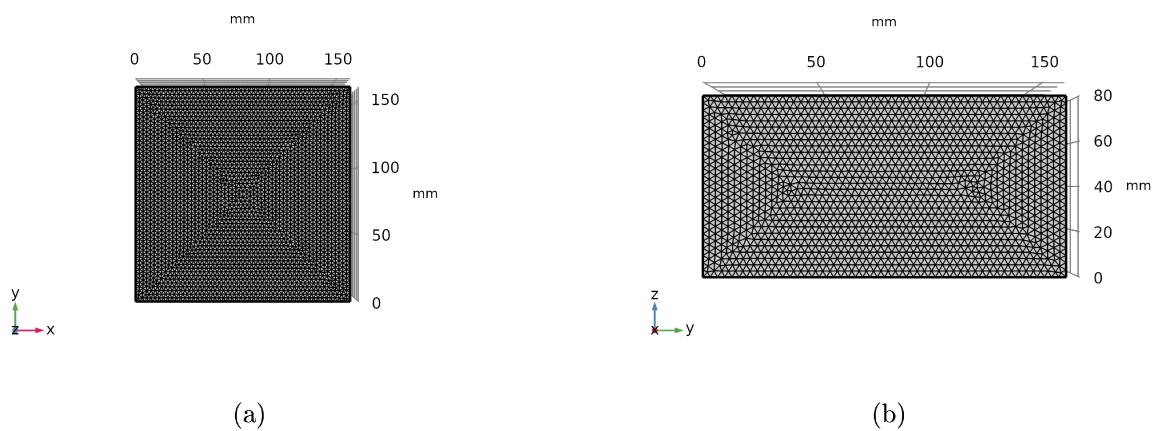
Figura 4.5: Malhas analisadas.



Fonte: Autoria própria.


Como as imagens termográficas simuladas são usadas apenas na condição permanente, pode-se usar uma malha extremamente fina, pois o tempo para gerar as mesmas é pequeno quando comparados a trabalhos que necessitam ser feitos em regime transiente. Observa-se na Figura 4.6 (a) e (b) a malha usada neste trabalho, e na Fig.4.7 a malha no formato tridimensional.

Figura 4.6: Malha: (a) Plano xy; (b) Plano yz.



Fonte: Autoria própria.

Figura 4.7: Malha tridimensional: Geometria Cartesiana.



Fonte: Autoria própria.

Na Tabela 4.2 apresenta-se os tipos de elementos do modelo tridimensional fornecidos pelo software comercial utilizado, enquanto na Tab. 4.3 apresenta-se a estatística dos elementos do modelo 3D em análise.

Tabela 4.2: Tipos de elementos do modelo tridimensional fornecida pelo software COMSOL *multiphysics*.

Malha	Tipo de elementos
Elementos tetraédricos	1100982
Elementos triangulares	24332
Elementos de borda	596
Elementos de vértice	14

Tabela 4.3: Estatística dos elementos do modelo 3D em análise feito no software COMSOL *multiphysics*.

<b>Elemento</b>	<b>Estatística</b>
Número de elementos	1100982
Qualidade mínima do elemento	0,1902
Qualidade média do elemento	0,6622
Relação do volume do elemento	2,437e-4
Volume de malha	2048000.0 $mm^3$

## Capítulo 5

# Análise da influência da localização, de propriedades térmicas e da geometria dos tumores nos perfis de pixels normalizados


Este capítulo tem como objetivo principal verificar a influência da localização, de propriedades térmica e da geometria dos tumores nos perfis de pixels de imagens termográficas superficiais de uma mama cartesiana tridimensional. A primeira análise é feita para verificar a variação dos pixels das imagens termográficas simuladas alterando-se a posição dos tumores em relação ao plano  $(x, y)$  e mantendo-se a profundidade constante, representada pela coordenada  $(z)$ . A segunda análise também foi feita em relação a localização do tumor, porém verificou-se aqui a variação dos pixels quando mantêm-se as coordenadas  $(x, y)$  constantes e varia-se apenas a coordenada  $(z)$ . A partir destas duas análises é possível prever se existe uma alteração significativa no valor dos pixels e se sim, qual a capacidade de usar os pixels das imagens termográficas simuladas para estimar a localização de uma fonte de calor metabólico simulando-se tumores fictícios.

Além destes, fez-se um terceiro estudo em relação a geometria do tumor, isto é, o tamanho do mesmo. Como mencionado anteriormente, o tumor aqui simulado possui uma geometria esférica, portanto variou-se o raio do mesmo e analisou-se o comportamento dos pixels das imagens térmicas.

Em relação as propriedades térmicas analisadas, verificaram-se o efeito da variação da geração de calor metabólica, da perfusão sanguínea e da condutividade térmica do tumor. Todas as simulações foram feitas no software COMSOL *multiphysics* e o modelo usado é o da mama cartesiana mostrado na Fig. 5.1 (a) na qual pode-se observar as dimensões da mama e a posição de um tumor fictício localizado no centro da mama e posicionada a 20 mm da superfície representada pela coordenada  $z = 80$  mm. Observa-se na Figura 5.1 (b), a linha de análise da

resposta dos valores de pixels para diferentes configurações de localização, tamanho e propriedades térmicas do tumor nesse perfil de pixel.

Figura 5.1: Mama Cartesiana: (a) Posicionamento do tumor; (b) região de análise posicionada.




Fonte: Autoria própria.

## 5.1 Análise dos Pixels de Imagens Termográficas Simuladas

As imagens usadas na construção do banco de dados do problema proposto possuem 937.024 pixels no canal vermelho, 937.024 no canal verde e 937.024 no canal azul, ou seja, são matrizes de  $968 \times 968$  pixels em cada canal RGB. A Figura 5.2 mostra o número de pixels da imagem termográfica simulada para um tumor posicionado em  $(x, y, z) = (80, 80, 60)$  mm.

Figura 5.2: Pixeis das Imagens Termográficas Simuladas.

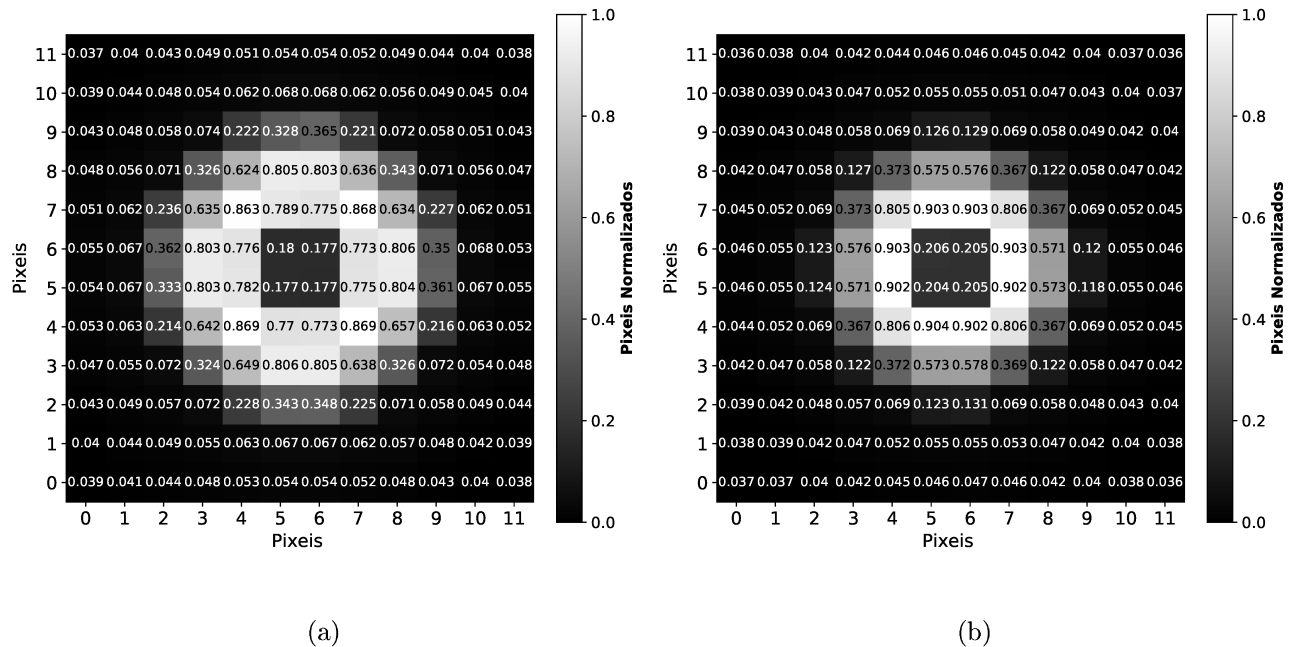


Fonte: Autoria própria.

Devido a grandeza dos pixels das imagens simuladas e da dificuldade de representação das matrizes de pixels tridimensionais formadas pelos canais RGB. Fez-se uma representação da mesma só que em menor escala, ou seja, reduziu-se o número de pixels para fazer a representação. A análise foi feita para uma imagem preta e branca, resultando em matrizes bidimensionais, conforme a Fig.3.3. Após a normalização dos pixels, as cores preta e branca possuem respectivamente valores de pixels entre 0 e 1.

Notam-se nas Figuras 5.3 e 5.4 uma simplificação da matriz de pixels normalizados que são usados para resolver problemas de redes neurais convolucionais. No exemplo usou-se imagens com 144 pixels, ou seja,  $12 \times 12$  pixels, sendo que cada posição representa a média dos valores dos pixels da matriz original. Observam-se nas Figuras 5.3 e 5.4 tumores posicionados nas posições  $(x, y) = (80, 80)$  mm, posicionamento referente ao tamanho da geometria, ou em  $(x, y) = (484, 484)$ , posicionamento referente aos pixels da matriz bidimensional. Elas diferenciam-se no posicionamento em relação a profundidade representada pela coordenada ( $z$ ), sendo observado nas Figs. 5.3 (a) e (b) tumores simulados posicionados em  $z = 40$  mm e  $z = 50$  mm, respectivamente.

Figura 5.3: Pixels normalizados das imagens termográficas simuladas nas seguintes profundidades: (a)  $z = 40$  mm; (b)  $z = 50$  mm.



Fonte: Autoria própria.

Observam-se nas Figuras 5.4 (a) e (b) os pixels normalizados das imagens termográficas simuladas nas profundidades:  $z = 60$  mm e  $z = 65$  mm, respectivamente. Nas Figuras 5.5 (a) e (b) são apresentados os tumores posicionados em  $z = 70$  mm e  $z = 75$  mm, respectivamente.

Figura 5.4: Pixels normalizados das imagens termográficas simuladas nas seguintes profundidades: (a)  $z = 60$  mm; (b)  $z = 65$  mm.

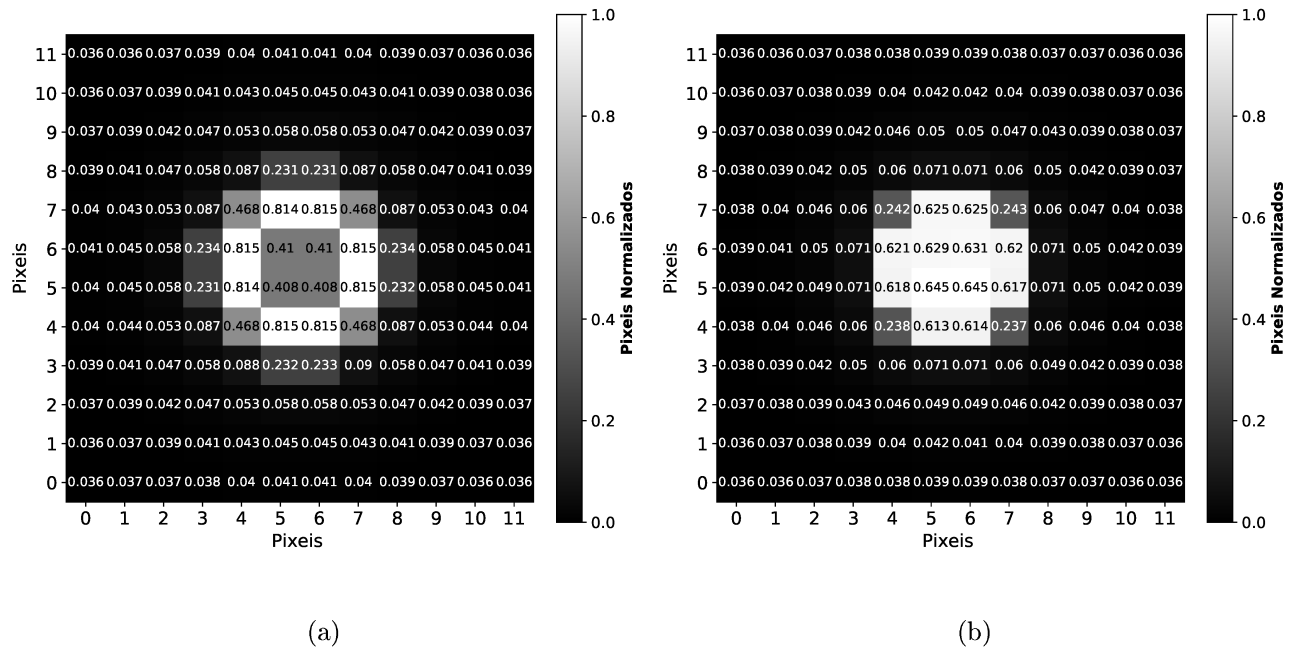
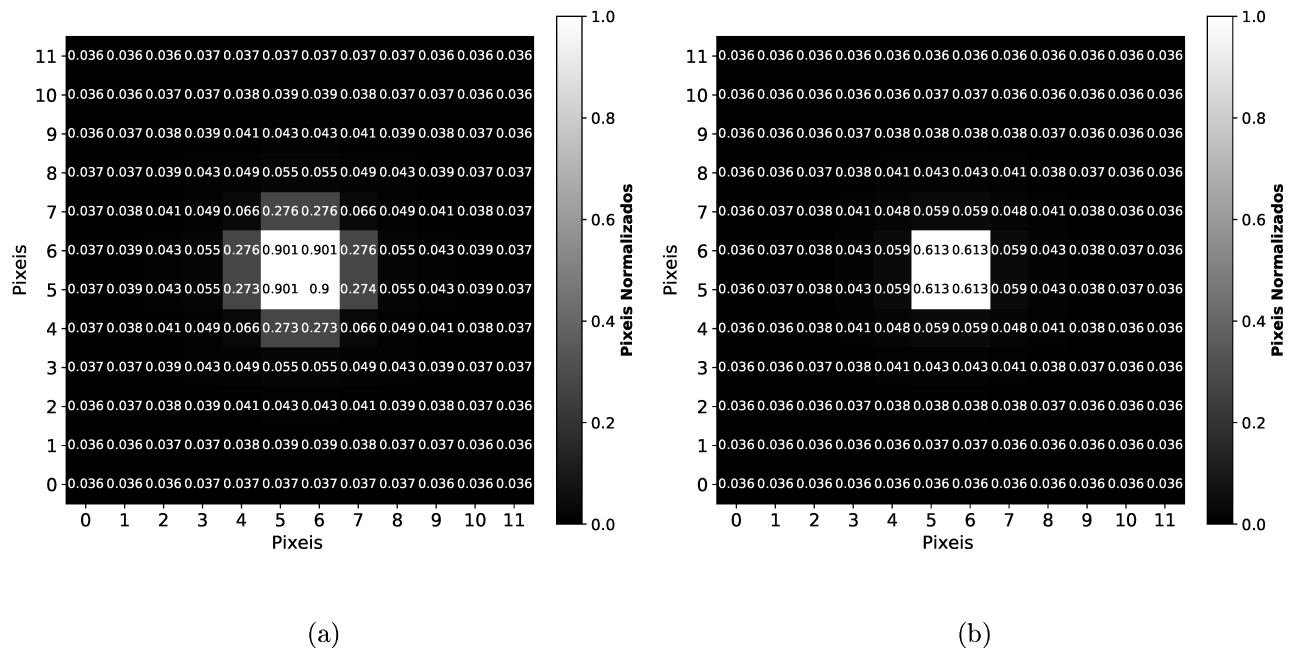


Figura 5.5: Pixels normalizados das imagens termográficas simuladas nas seguintes profundidades: (a)  $z = 70$  mm; (b)  $z = 75$  mm.



Fonte: Autoria própria.




## 5.2 Influência da Posição do Tumor no Perfil de Pixels

Um parâmetro geométrico muito estudada em relação aos tumores é a sua localização. Primeiramente, objetiva-se analisar a influência do posicionamento dos tumores em relação ao plano que o mesmo se encontra. Para isso, avaliou-se o comportamento térmico de imagens infravermelhas simuladas com tumores fictícios localizados no plano  $(x, z) = (80, 60)$  mm e alterou-se a posição  $y$  entre as posições  $10 \leq y \leq 80$  com variações de 10 mm em cada, conforme Fig.5.6. De acordo com a barra de cor, localizada no lado direito da imagem, observa-se que os pixels normalizados possuem valores entre 0 e 1, sendo que valores mais próximos de zero são representados pela cor preta e valores próximos de um correspondem a cor branca.

Observa-se também na Fig.5.6 que ocorre uma distinção clara entre variações do posicionamento do tumor no campo térmico gerado pelas imagens termográficas simuladas variando sua posição no plano em estudo.

Figura 5.6: Influência da Posição do Tumor no Perfil de Pixels: (a)  $y = 10$  mm; (b)  $y = 20$  mm; (c)  $y = 30$  mm; (d)  $y = 40$  mm; (e)  $y = 50$  mm; (f)  $y = 60$  mm; (g)  $y = 70$  mm; (h)  $y = 80$  mm.



Fonte: Autoria própria.

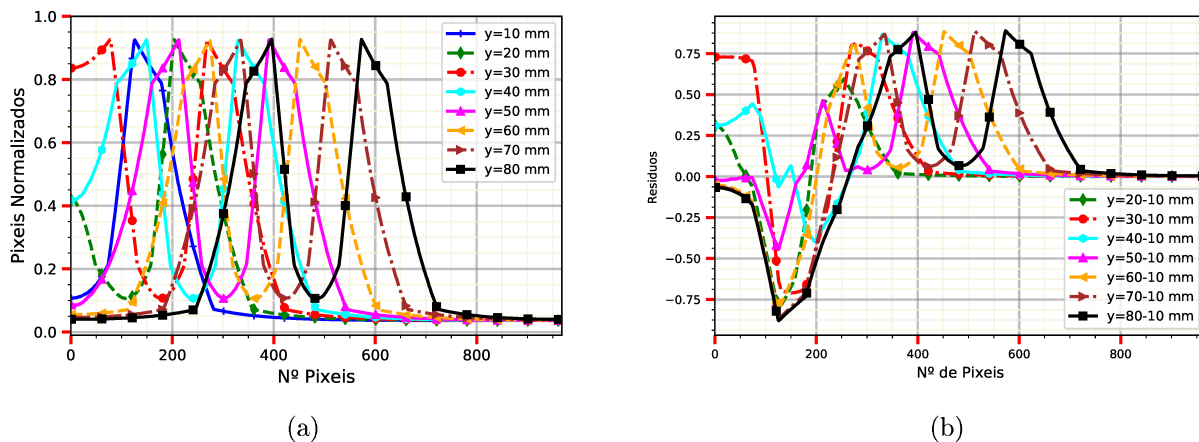
A Fig.5.7 (a) mostra o perfil de pixels normalizados após realizar um corte na matriz de pixels no plano  $x = 80$  mm ou  $x = 484$  pixel, conforme Fig. 5.6. O eixo  $y$  mostra valores de pixels normalizados entre 0 e 1, sendo que, aqui também valores mais próximos de zero são representados pela cor preta e valores próximos de um correspondem a cor branca. Já o eixo  $x$  mostra o  $N^0$  de pixels que varia de 0 até 968 pixels referente ao corte feito no plano  $x = 80$  mm.

É possível observar na Fig.5.7 (a) que todas as curvas chamadas de  $y = 10$  mm até  $y =$

80 mm, nomes representativos de suas posições, possuem comportamentos semelhantes, por exemplo, a curva  $y = 80$  mm mostra o perfil de pixels de um tumor localizado no centro da imagem, representado por uma curva com linha contínua e cor preta. Essa curva apresenta inicialmente formato ascendente e o que muda é sua inclinação sendo que do pixel 0 ao pixel 250 apresenta uma leve inclinação representada por uma instabilidade térmica, após o pixel 250, ela apresenta uma aumento na inclinação até em torno do pixel 350 onde essa inclinação reduz até o pixel 400, após, a curva apresenta uma forte inclinação com formato descendente até o centro do tumor que ocorre no pixel 484, e esse formato é simétrico do pixel 484 até o pixel 968, ou seja, essa curva lembra a letra *M*, onde o centro do tumor está no ponto simétrico da letra. Observa-se que ocorre uma distinção clara entre as curvas.

Observa-se na Fig.5.7 (b) o quão varia o perfil de pixels, ou seja fez-se a diferença dos valores de pixels entre as curvas para verificar a variação das mesmas conforme muda-se o posicionamento dos tumores fictícios. Observa-se uma resposta geral em torno de  $-0,75$  a  $0,75$ . Nota-se uma clara distinção entre as curvas validando a possibilidade de encontrar o posicionamento de tumores com alteração da posição do plano onde os mesmos se encontram.

Figura 5.7: Influência da Posição do Tumor no Perfil de Pixels: (a) Pixels Normalizados; (b) Resíduos.



Fonte: Autoria própria.


### 5.3 Influência da Profundidade do Tumor no Perfil de Pixels

Outra parâmetro geométrica muito importante é a localização do tumor referente a profundidade em que se encontra até a superfície da pele da mama, para isso, avaliou-se o comportamento térmico de imagens infravermelhas simuladas com variações de profundidades de tumores fictí-

cios localizados no plano  $(x, z) = (80, 80)$  mm e alterou-se a profundidade (altura), representada pela letra  $z$ , conforme Fig.5.8.

Observa-se na Fig.5.8 que ocorre uma distinção clara entre variações da profundidade do tumor no campo térmico gerado por esses, ou seja, tumores mais afastados da superfície, como em  $z = 40$  mm, mostrado na Fig.5.8 (a), possui imagem termográfica com campo térmico de diâmetros maiores, já tumores mais próximos da superfície, como no caso de  $z = 77$  mm, Fig.5.8 (h), possui diâmetro menor, ou seja quanto maior a profundidade do tumor em relação a superfície da pele da mama maior será o diâmetro do mesmo gerado no campo térmico da imagem termográfica e quanto menor a profundidade menor o diâmetro ou tamanho do mesmo na imagem térmica.

Figura 5.8: Influência da Profundidade do Tumor no Perfil de Pixels: (a)  $z = 30$  mm; (b)  $z = 40$  mm; (c)  $z = 50$  mm; (d)  $z = 60$  mm; (e)  $z = 65$  mm; (f)  $z = 70$  mm; (g)  $z = 75$  mm; (h)  $z = 77$  mm.



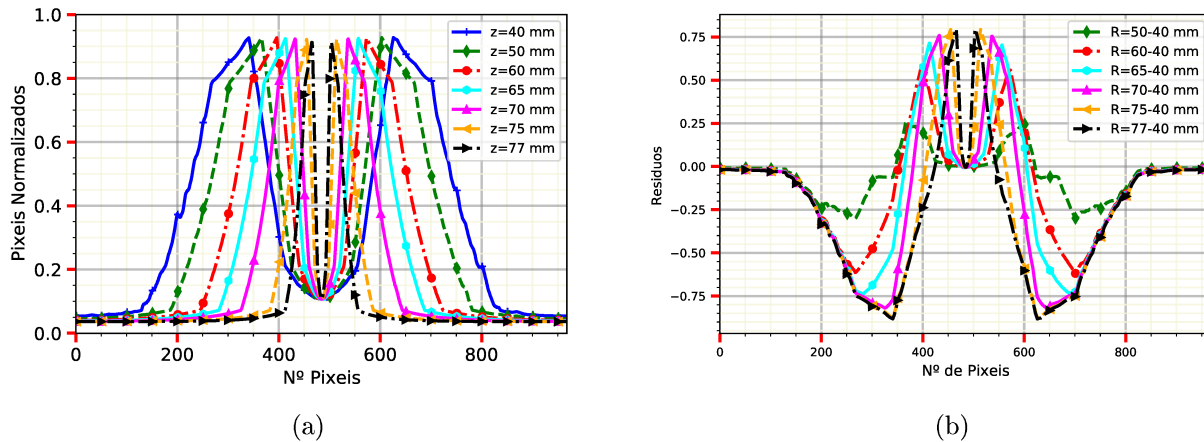
Fonte: Autoria própria.

É possível observar na Fig.5.9 (a) que todas as curvas chamadas de  $z = 40$  mm até  $z = 77$  mm, nomes representativos de suas profundidades, possuem formatos semelhantes, e esse formato é simétrico em relação ao pixel 484, ou seja, essas curvas lembram a letra  $M$ , em que o centro do tumor está no ponto simétrico da letra. Observa-se que ocorre uma distinção clara entre as curvas, quanto maior a profundidade do tumor, como em  $z = 40$  mm, maior e mais larga é a letra  $M$  e quanto menor a profundidade como em  $z = 77$  mm menor e mais estreita é a letra  $M$ .

A Fig.5.9 (b) mostra o quão varia o perfil de pixels, ou seja fez-se a diferença dos valores de pixels entre as curvas para verificar a variação das mesmas conforme muda-se a profundidade

dos tumores fictícios. Observa-se uma resposta geral em torno de  $-0,75$  a  $0,75$ . Observa-se uma clara distinção entre as curvas validando a possibilidade de encontrar a profundidade de tumores devido a imagens termográficas simuladas.

Figura 5.9: Influência da Profundidade do Tumor no Perfil de Pixeis: (a) Pixeis Normalizados; (b) Resíduos.



Fonte: Autoria própria.


## 5.4 Influência do Tamanho do Tumor no Perfil de Pixeis

Para este estudo numérico, considerou-se tumores com geometria esférica, avaliou-se o comportamento térmico de imagens infravermelhas simuladas com variações do diâmetro dos mesmos, com tumores posicionados em  $(x, y, z) = (80, 80, 60)$  mm. Análises feitas são mostradas na Fig.5.10.

O estudo levou em consideração tumores com raio de 3 mm, cujo campo térmico é apresentado na Fig.5.10 (a), até tumores com raio de  $r = 10$  mm, resposta térmica mostrada na Fig.5.10 (h), valores estes que englobam tanto tumores de menores dimensões que não são identificáveis pelo toque de mama como no caso de  $r = 3$  mm necessitando-se assim outros métodos como a mamografia para detecção dos mesmos, quanto tumores que possuem maiores dimensões como no caso de  $r = 10$  mm.

Observa-se na Fig.5.10 que visualmente é impossível detectar variações do tamanho do tumor no campo térmico gerado nas imagens, ou seja, variando-se esta propriedade de  $r = 3$  mm até  $r = 10$  mm as imagens térmicas apresentam a mesmo campo térmico como resposta.

Figura 5.10: Influência da Tamanho do Tumor no Perfil de Pixels: (a)  $r = 3$  mm; (b)  $r = 4$  mm; (c)  $r = 5$  mm; (d)  $r = 6$  mm; (e)  $r = 7$  mm; (f)  $r = 8$  mm; (g)  $r = 9$  mm; (h)  $r = 10$  mm.

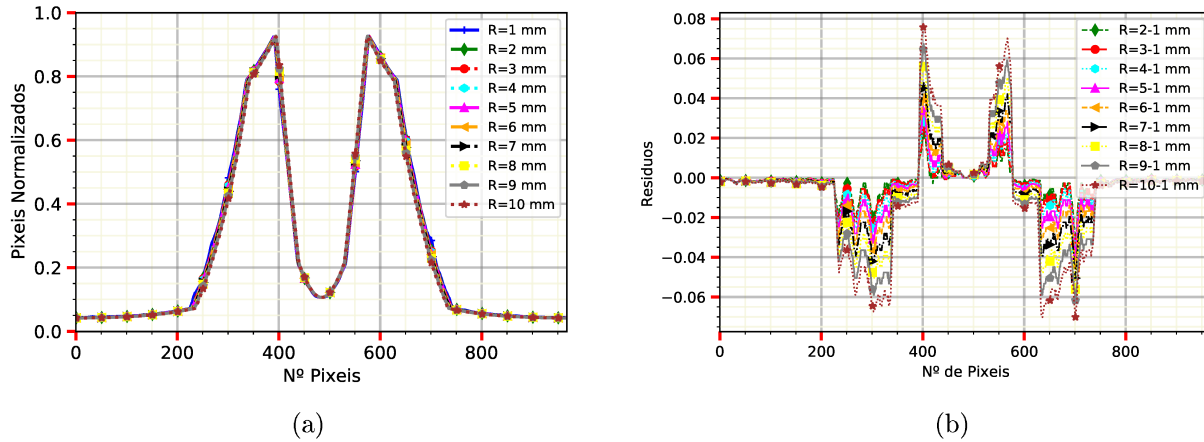


Fonte: Autoria própria.

É possível observar na Fig.5.11 (a), curvas chamadas de  $r = 1$  mm até  $r = 10$  mm, nomes representativos da variação de tamanho do tumor, possuem formatos e perfis semelhantes, e esse formato também é simétrico em relação ao pixel 484, ou seja, essas curvas também lembram o formato da letra *M*, onde o centro do tumor está no ponto simétrico da letra. Observa-se que ocorre uma sobreposição entre as curvas, não sendo possível distingui-las visualmente, daí verifica-se uma necessidade em analisar a variação entre essas curvas para avaliar se existe uma mudança significativa ou não.

A Fig.5.11 (b) mostra o quão varia o perfil de pixels, ou seja, fez-se a diferença dos valores de pixels entre as curvas para verificar a variação das mesmas conforme muda-se o tamanho dos tumores simulados. Observa-se uma resposta geral em torno de  $-0,06$  a  $0,08$  correspondendo basicamente uma variação predominante na segunda casa decimal, ou seja, a sensibilidade entre as curvas é muito pequena sendo um parâmetro de difícil estimativa referente a imagem termográfica.

Figura 5.11: Influência do Tamanho do Tumor no Perfil de Pixels: (a) Pixels Normalizados; (b) Resíduos.



Fonte: Autoria própria.


Figueiredo (2018) estudou os perfis de temperatura normalizadas na superfície da pele da mama tanto em modelos bidimensionais quanto em geometrias tridimensionais e verificou que variações dos parâmetros do tumor como: tamanho, geração metabólica, perfusão sanguínea e a condutividade térmica não podem ser identificadas através do perfil de temperatura, pois estas variações afetam de forma mínima no perfil de temperatura superficial normalizada, porém o autor não mostrou qual seria estas variações mínimas.

Neste trabalho será feita uma comparação entre as sensibilidades da temperatura superficial e dos perfis de pixels proposta na tese em questão para avaliar qual destas técnicas apresentam maior sensibilidade referente a variação dos parâmetros geométrico e térmico do tumor.

A temperatura superficial normalizada é apresentada para os mesmos valores de tamanho de tumores analisados referentes aos pixels das imagens. A Fig.5.12 (a) mostra o perfil de variação da temperatura superficial normalizada para os diferentes casos de tamanho de tumores, percebe-se que todas as curvas são sobrepostas com mesmo perfil de temperatura normalizada. Aqui também não é possível distinguir visualmente o efeito da variação do tamanho nos perfis de temperatura.

A Fig.5.12 (b) mostra o gráfico de resíduos entre as curvas, observa-se uma resposta geral em torno de  $-0,025$  a  $0,05$  correspondendo basicamente a uma variação predominante na terceira casa decimal.

Figura 5.12: Influência do Tamanho do Tumor: (a) Temperatura Superficial Normalizada ; (b) Resíduos.




Fonte: Autoria própria.

## 5.5 Influência da Geração Metabólica do Tumor no Perfil de Pixels

Avaliou-se o comportamento térmico de imagens infravermelhas simuladas com a variação da geração metabólica, com tumor posicionado em  $x = 80$  mm,  $y = 80$  mm e  $z = 60$  mm, com raio de 3 mm. As imagens foram avaliadas quando o modelo térmico atinge o regime permanente. Análises são mostradas na Fig.5.13.

Nota-se na Fig.5.13 que visualmente é impossível detectar variações da geração metabólica do tumor no campo térmico gerado nas imagens, ou seja, variando-se esta propriedade de  $Q = 10$  W/m<sup>3</sup>, Fig.5.13 (a), até  $Q = 100.000.000$  W/m<sup>3</sup>, Fig.5.13 (h), valores estes que extrapolam dados da literatura de geração metabólica de tumores, porém, objetivou-se realizar um estresse térmico para verificar se ocorreria alterações nas imagens de temperatura.

Figura 5.13: Influência da Geração de Calor Metabólica no Perfil de Pixeis: (a)  $Q = 10 \text{ W/m}^3$ ; (b)  $Q = 10^2 \text{ W/m}^3$ ; (c)  $Q = 10^3 \text{ W/m}^3$ ; (d)  $Q = 10^4 \text{ W/m}^3$ ; (e)  $Q = 10^5 \text{ W/m}^3$ ; (f)  $Q = 10^6 \text{ W/m}^3$ ; (g)  $Q = 10^7 \text{ W/m}^3$ ; (h)  $Q = 10^8 \text{ W/m}^3$ .



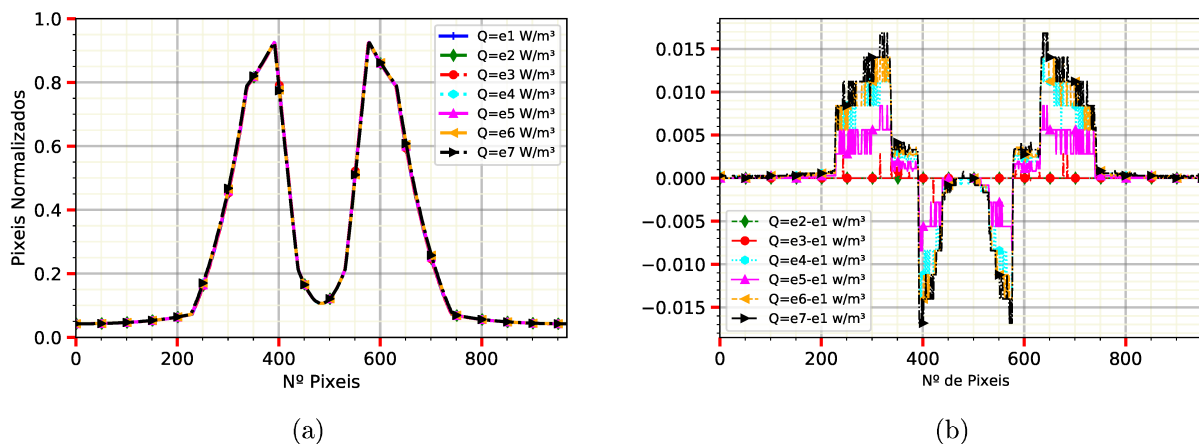
Fonte: Autoria própria.

Na Fig.5.14 (a), curvas chamadas de  $Q = 10^1 \text{ W/m}^3$  até  $Q = 10^8 \text{ W/m}^3$ , nomes representativos de suas gerações metabólicas, possuem formatos e perfis semelhantes, e esse formato também é simétrico em relação ao pixel 484. Essas curvas também lembram o formato da letra *M*, onde o centro do tumor está no ponto simétrico da letra. Ocorre ainda uma sobreposição entre as curvas, não sendo possível distingui-las visualmente, daí verifica-se uma necessidade em analisar a variação entre essas curvas para avaliar se existe uma mudança significativa ou não.

A Fig.5.14 (b) mostra o quanto varia o perfil de pixeis. Realizou-se a diferença dos valores de pixeis entre as curvas para verificar a variação das mesmas conforme muda-se a geração metabólica dos tumores fictícios. Observa-se uma resposta geral em torno de  $-0,015$  a  $0,015$  correspondendo basicamente uma variação predominante na terceira casa decimal, ou seja, a sensibilidade entre as curvas é muito pequena sendo um parâmetro de difícil estimativa referente a imagem termográfica.



Figura 5.14: Influência da Geração de Calor Metabólico do Tumor no Perfil de Pixels: (a) Pixels Normalizados; (b) Resíduos.

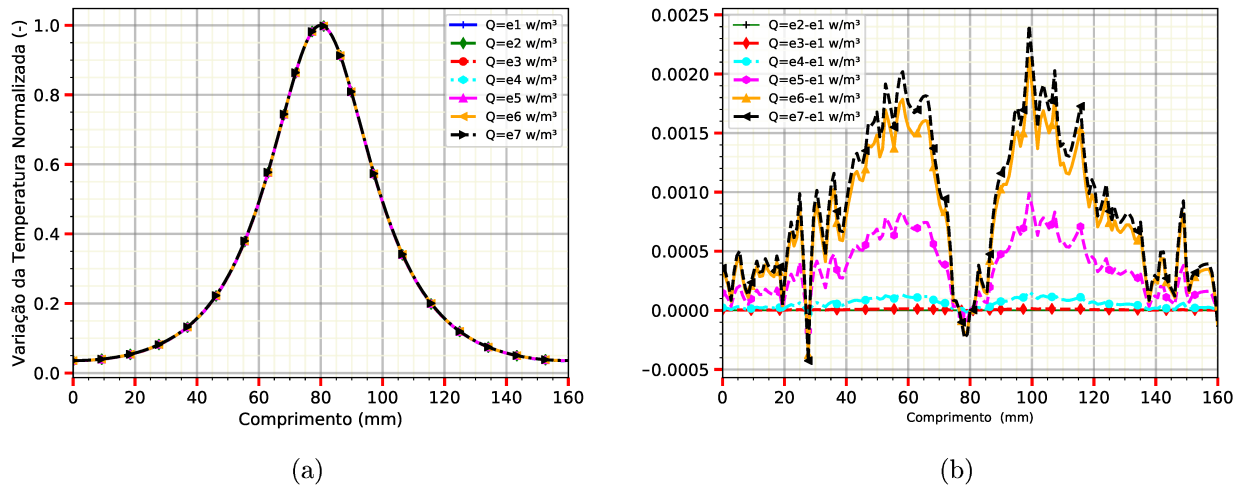


Fonte: Autoria própria.

A temperatura superficial normalizada é apresentada para os mesmos valores de geração metabólica analisados referentes aos pixels das imagens. A Fig.5.15 (a) mostra o perfil de variação da temperatura superficial normalizada para os diferentes casos de gerações metabólicas, percebe-se que todas as curvas são sobrepostas com mesmo perfil de temperatura normalizada. Aqui também não é possível distinguir visualmente o efeito da variação da geração metabólica nos perfis de temperatura.

A Fig.5.15 (b) mostra o gráfico de resíduos entre as curvas, observa-se uma resposta geral em torno de  $-0,0005$  a  $0,0025$  correspondendo basicamente a uma variação predominante na quarta casa decimal, ou seja, a sensibilidade entre as curvas são inferiores quando analisa-se o perfil de pixels.

Figura 5.15: Influência da Geração de Calor Metabólico: (a) Temperatura Superficial Normalizada ; (b) Resíduos.

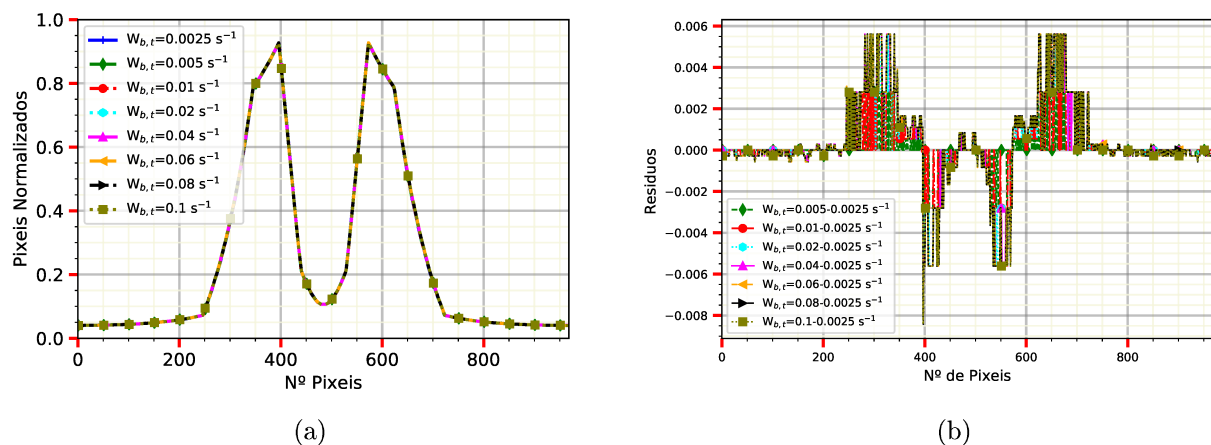


Fonte: Autoria própria.

## 5.6 Influência da Perfusão Sanguínea do Tumor

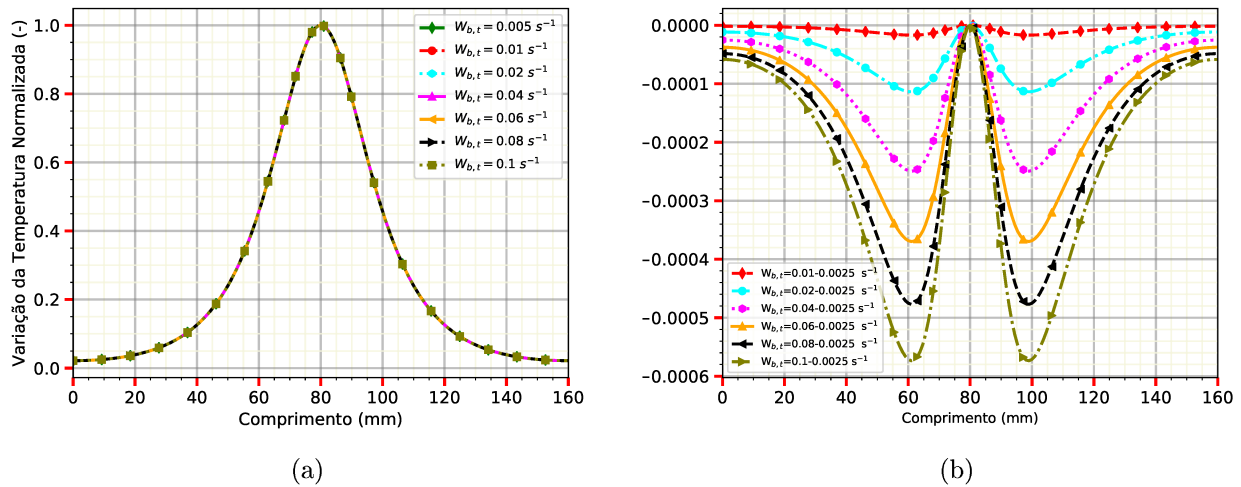
Observa-se nas Figs. 5.16 (a) e (b) e nas Figs. 5.17 (a) e (b) que as curvas de variação da perfusão sanguínea do tumor não apresentam variação significativa nem nos pixels das imagens nem nas temperaturas superficiais, sendo impossível identifica-las através destas técnicas.

Figura 5.16: Influência da Perfusão Sanguínea do Tumor no Perfil de Pixels: (a) Pixels Normalizados; (b) Resíduos.



Fonte: Autoria própria.

Figura 5.17: Influência da Perfusão Sanguínea do Tumor: (a) Temperatura Superficial Normalizada ; (b) Resíduos.




Fonte: Autoria própria.

## 5.7 Influência da Condutividade Térmica do Tumor


Observa-se nas Figs. 5.18 (a) e (b) e nas Figs. 5.19 (a) e (b) que as curvas de variação da condutividade térmica do tumor também não apresentam variação significativa nem nos pixels das imagens nem nas temperaturas superficiais, sendo impossível identifica-las através destas técnicas.

Figura 5.18: Influência da Condutividade Térmica do Tumor no Perfil de Pixels: (a) Pixels Normalizados; (b) Resíduos.



Fonte: Autoria própria.

Figura 5.19: Influência da Condutividade do Tumor: (a) Temperatura Superficial Normalizada ; (b) Resíduos.




Fonte: Autoria própria.

As análises apresentadas neste capítulo são fundamentais para verificar alterações nas matrizes de pixels com mudanças de parâmetros do tumor e com isso verificar a capacidade da técnica em se estimar diferentes classes para tumores simulados via imagem termográfica.


Como observado, existem algumas propriedades térmicas e parâmetros geométricos que não são possíveis de serem identificadas nas imagens térmicas devido a sua baixa sensibilidade em relação a temperatura superficial. Portanto, valores médios desses parâmetros foram usados para criar o banco de dados. Tanto o conjunto de dados de treinamento quanto o conjunto de teste foram montados com imagens superficiais cujas classes de tumores baseada na localização tanto no plano quanto na profundidade foram diferenciáveis através de ruídos aplicados as imagens térmicas simuladas.

O banco de dados foi montado com classes de posições de tumores na mama tridimensionais. A Fig. 5.20 apresenta um dos casos de análises feitas para um conjunto de treinamento e testes com classes diferentes de tumores reconhecíveis pela rede neural convolucional, pois as imagens termográficas simuladas possuem padrões de pixels bem distintos.

Figura 5.20: Treinamento da Rede Neural referente a diferentes classes de posições de tumores térmicos simulados: (a) Precisão ; (b) Função erro.



(a)



(b)

Fonte: Autoria própria.

## Capítulo 6

# Proposta de uma nova técnica para a localização de tumores usando impedância térmica e redes convolucionais

Observou-se no capítulo 5 que a localização dos tumores tanto no plano ( $xy$ ) quanto em relação à profundidade ( $z$ ) pode ser estimada com uso de imagens termográficas (imagens de temperatura). Porém constatou-se que propriedades térmicas e alguns parâmetros geométricos do tumor como o tamanho, geração metabólica, perfusão sanguínea e condutividade térmica não podem ser identificadas nem pelos perfis de temperatura superficial nem pelos pixels das imagens termográficas, pois as mesmas possuem baixa sensibilidade em relação a variação desses parâmetros já que não alteram a resposta nos pixels das imagens térmicas.

Apresentam-se neste capítulo uma análise de sensibilidade desses mesmos parâmetros porém usando redes neurais aplicadas a imagens de impedância e admitância. Para verificar a eficiência e o comportamento destas novas técnicas de imagens faz-se uma comparação entre os resultados das redes nas imagens de temperatura e impedância.

### 6.1 Técnicas propostas como alternativas à termografia

A análise do fenômeno da biotransferência de calor que ocorre na mama, com ou sem tumor, depende da solução de um problema térmico. A solução numérica desse problema depende das propriedades e parâmetros térmicos da mama. Logo, dados experimentais de temperatura são também dependentes dessas propriedades e parâmetros. Observa-se que existe uma grande dificuldade na estimativa destes parâmetros em situações reais. Uma alternativa é a busca de modelos que possam prescindir desses parâmetros e ainda melhorar a sensibilidade para a estimativa de tumores. Propõe-se, assim, a criação e o desenvolvimento de um método que não

dependa fortemente das propriedades e dos parâmetros térmicos dos tecidos biológicos e que tenha sensibilidade suficiente para a identificação de pequenos tumores.

No capítulo anterior demonstrou-se que imagens térmicas possuem baixa sensibilidade no que se refere a estimativa de tamanho e da profundidade do tumor. Apresenta-se neste capítulo o uso de duas funções alternativas: imagem da impedância térmica superficial da mama e imagem da admitância térmica superficial (inverso da impedância) da mama.

### 6.1.1 Analogia entre a Impedância Térmica e a Impedância Eletromecânica

Uma vez que as células de tecidos humanos, saudáveis ou não, são estruturas físicas com massa, rigidez e amortecimento, elas podem também ser representadas por um sistema dinâmico (MENEGAZ *et al.*, 2019). Se em determinadas condições o tecido humano pode ser representado por um sistema dinâmico então, por analogia, é possível também o estabelecimento de um sistema térmico equivalente deste tecido. Como os tecidos humanos possuem metabolismo e perfusão, o mecanismo de transferência de calor está presente nesses tecidos através da geração de calor metabólica, dos mecanismos de perfusão, difusão de calor e da troca de calor com o meio ambiente. Observa-se ainda que nesse caso uma analogia entre sistemas térmicos, elétricos e mecânico pode ser estabelecida. Propõe-se, nesse sentido, o desenvolvimento de um sistema térmico equivalente presente em um tecido humano e a consequente aplicação do conceito de impedância térmica para a identificação da presença de inclusões. Em outras palavras, propõe-se nesse trabalho, analogamente à impedância eletromecânica, uma definição da impedância térmica,  $Z(\omega)$ , como sendo

$$Z(\omega) = \frac{\Delta V(\omega)}{I(\omega)} = \frac{\Delta T(\omega)}{q(\omega)} = \frac{T_{y=0}(\omega) - T_a(\omega)}{q_0(\omega)} \quad (6.1)$$

onde,  $q_0(\omega)$  é a excitação térmica representada pelo fluxo de calor imposto na superfície e  $\Delta T(\omega)$  a resposta a este fluxo em termos de temperatura superficial da amostra (sistema térmico). As variáveis  $\Delta V(\omega)$  e  $I(\omega)$  representam a variação de tensão e corrente elétrica em um sistema eletromecânico. A variável  $\omega$  representa o domínio da frequência obtido pela aplicação da transformada de Fourier nos sinais temporais de  $\Delta T(t)$  e  $q(t)$  medidos por transdutores de fluxo de calor e temperatura. Uma vez que o sistema térmico é função de propriedades térmicas como condutividade térmica, difusividade térmica, calor específico e o próprio meio, a impedância térmica também deverá assumir valores diferentes caso o meio possua inclusões com propriedades térmicas diferentes de sua vizinhança.

Observa-se ainda que a Eq.(6.1) não apresenta explicitamente os parâmetros térmicos como

perfusão e metabolismo. A pergunta que surge é: Podem estes parâmetros, presentes num tecido humano in vivo alterar a impedância térmica experimental?

Em caso positivo, existe uma impedância térmica que possa ser definida a partir deles? Apresenta-se a seguir a descrição do problema térmico decorrente do metabolismo, perfusão e excitação térmica externa, assim como a definição da impedância térmica relacionada a esse sistema.

## 6.2 Impedância térmica

Como já mencionado, o problema térmico proposto pode ser modelado matematicamente a partir da equação de biotransferência de calor, também conhecida como equação de Pennes Brioschi *et al.* (2010).

Porém, de forma diferente do apresentado até aqui, a análise da impedância térmica exige uma modelagem transiente. Da mesma forma, apenas para efeito de análise de sensibilidade, será usado um sistema cartesiano, representando a mama, conforme apresentado na Fig. 4.3 (a). Resultados aplicados a uma mama em formato anatômico serão apresentadas posteriormente.


Analogamente, o modelo esquemático tridimensional da mama em coordenadas cartesianas é composto de uma região de tecido saudável e de um tumor esférico com localização arbitrária. As condições de contorno idealizadas são:

1) Aplicação de um aquecimento externo em uma região da mama, sendo toda a superfície remanescente da pele exposta à convecção térmica do ambiente externo, com coeficiente de transferência de calor  $h$  e temperatura do meio  $T_{\infty}=20$  °C;

2) Superfície interna sujeita a uma temperatura prescrita e constante  $T_s$  igual a temperatura interna do corpo, ou seja, 37 °C, e a temperatura ambiente,  $T_{\infty}=20$  °C.



Figura 6.1: Geometria cartesiana tridimensional com uma inclusão esférica, modelo no qual pode ser obtida a equação baseada na impedância térmica.



A equação governante do problema pode ser escrita como

$$\frac{\partial^2 \theta}{\partial x^2} + \frac{\partial^2 \theta}{\partial y^2} + \frac{\partial^2 \theta}{\partial z^2} + \frac{w\rho_s c_s}{k} \theta_a + \frac{Q_m}{k} + \frac{Q_g(x, y, z)}{k} = \frac{1}{\alpha} \frac{\partial \theta}{\partial t} \quad (6.2)$$

sujeita às condições de contorno

$$k \frac{\partial \theta}{\partial x} \Big|_{x=0} = h\theta; \quad -k \frac{\partial \theta}{\partial x} \Big|_{x=L} = h\theta; \quad (6.3)$$

$$k \frac{\partial \theta}{\partial z} \Big|_{z=0} = h\theta; \quad -k \frac{\partial \theta}{\partial z} \Big|_{z=H} = h\theta; \quad (6.4)$$

$$k \frac{\partial \theta}{\partial y} \Big|_{y=W} = q_0(x, W, z, t); \quad \theta(x, 0, z, t) = \theta_a = T(x, 0, z, t) - T_a \quad (6.5)$$

e a condição inicial

$$\theta(x, y, z, 0) = \theta_a = T(x, y, z, 0) - T_a \quad (6.6)$$

Utilizando o conceito de sistemas de controle, cuja a entrada seria o valor do fluxo de calor medido em um dado ponto e a saída a diferença entre temperatura superficial medida neste mesmo ponto, a impedância térmica seria definida a partir do conceito da integral de convolução

via método de funções de Green, ou seja, simbolicamente pode-se escrever

$$\theta^*(x, y, z, t) = \theta(x, y, z, t) - \theta_{Q_m}(x, y, z, t) - \theta_{Q_g}(x, y, z, t) = \int_0^t \int_{b_1}^{b_2} \int_{c_1}^{c_2} H_1(t - \tau) dx' dz' q(\tau) d\tau \quad (6.7)$$

onde  $\theta(x, y, z, t)$  é o campo de temperatura do tecido,  $\theta_{Q_m}(x, y, z, t)$  é contribuição do termo de geração metabólica e  $\theta_{Q_g}(x, y, z, t)$  é a contribuição do termo de geração metabólica devido ao tumor. Nesse caso, a impedância poderia ser definida a partir da razão entre a temperatura modificada,  $\theta^*(x, y, z, t)$ , e o fluxo de calor imposto  $q(x, z, t)$ , ou seja

$$\theta^*(x, y, z, t) = \int_0^t \int_{b_1}^{b_2} \int_{c_1}^{c_2} H_1(t - \tau) dx' dz' q(\tau) d\tau \quad (6.8)$$

e portanto

$$Z(x, y, z, t) = \frac{\theta^*(x, y, z, t)}{q(x, z, t)} \quad (6.9)$$

Observa-se, ainda, que  $H_1(t - \tau)$  representa simbolicamente a função transferência cuja dependência de  $w$ ,  $\rho_s$  e  $c_s$  pode ser explicitada por

$$H_1(x, y, z, t) = h_1(x, y, z, t) \times \exp^{u^2 \alpha t} \quad (6.10)$$

A função  $h_1(x, y, z, t)$  é a função de Green do problema térmico em estudo vezes o produto  $\alpha/k$  e  $u^2 = w\rho_s c_s/k$ .

Embora neste trabalho a forma teórica explícita da função transferência não seja utilizada, ela pode ser obtida usando-se o método de funções de Green.

Outra observação se faz necessária. Infere-se da Equação (6.9) que a impedância é definida a partir da temperatura modificada  $\theta^*(x, y, z, t)$ .

A proposta desse trabalho, entretanto, é usar a definição de impedância considerando a temperatura da superfície  $\theta^*(x, y, z, t)$  uma vez que do ponto de vista de correlação de imagens não haveria qualquer problema, pois a dependência do metabolismo do tecido saudável e do tumor são explícitos e adicionais, como demonstra a equação

$$\theta(x, y, z, t) = \theta^*(x, y, z, t) + \theta_{Q_m}(x, y, z, t) + \theta_{Q_g}(x, y, z, t) \quad (6.11)$$


A seguir serão analisadas as influências dos diversos parâmetros físicos e térmicos no sinal de saída da impedância e admitância térmica definidos pela Equação (6.9) porém considerando as temperaturas medidas na superfície.

Os fluxos de calor, por sua vez, são obtidos diretamente de um módulo/função do software COMSOL que calcula o fluxo de calor logo abaixo do nó respectivo da temperatura calculada. Esses nó superficiais representam em um problema aplicado os pontos onde são medidos a temperatura e seu respectivo fluxo de calor.

### 6.3 Efeitos da Variação da Geração de Calor Metabólico na Impedância Térmica

Apresentam-se na Figura 6.2 uma comparação da influência do metabolismo do tumor no perfil de pixels na temperatura superficial e na impedância para diversos valores de  $Q$ .

Figura 6.2: Comparação da influência do metabolismo do tumor no perfil de pixels na temperatura: (a)  $Q = 10^4 \text{ W/m}^3$ ; (b)  $Q = 10^5 \text{ W/m}^3$ ; (c)  $Q = 10^6 \text{ W/m}^3$ ; (d)  $Q = 10^7 \text{ W/m}^3$  e na impedância: (e)  $Q = 10^4 \text{ W/m}^3$ ; (f)  $Q = 10^5 \text{ W/m}^3$ ; (g)  $Q = 10^6 \text{ W/m}^3$ ; (h)  $Q = 10^7 \text{ W/m}^3$ .



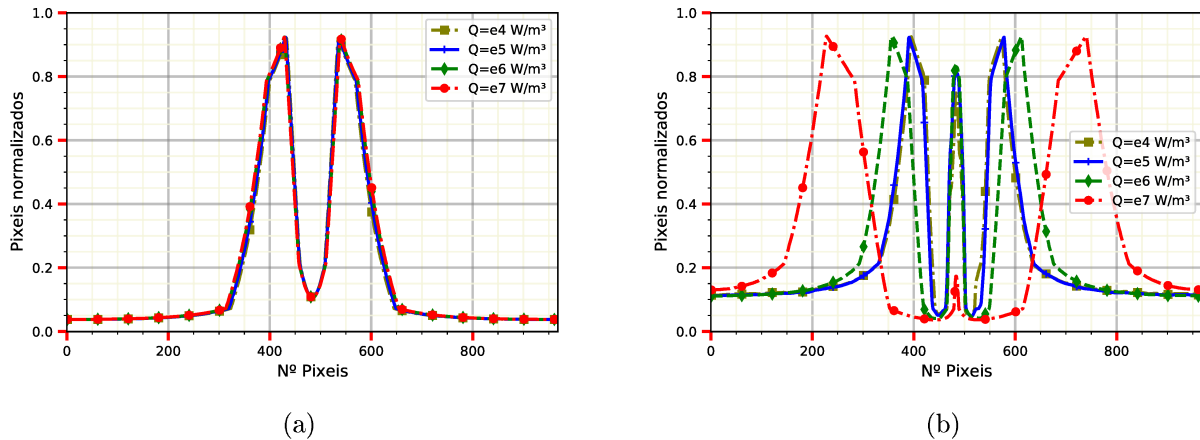
Fonte: Autoria própria.

Observa-se que visualmente nas Figs.6.2 se destaca um maior contraste e nitidez das imagens da impedância térmica em relação a da temperatura. Isto pode ser observado ao se comparar as Figs. 6.2 (e, f, g e h) com as Figs. 6.2 (a, b, c, e d). Mesmo para baixo valor de metabolismo,  $Q = 10^4 \text{ W/m}^3$  (compare Fig. 6.2a com Fig. 6.2e) até com valores altos de metabolismo,  $Q = 10^7 \text{ W/m}^3$  (compare a Fig. 6.2d com a Fig. 6.2h). Além disso, é possível observar nas imagens de temperatura que a localização do centro do tumor é representada pela cor vermelha (ponto de máxima temperatura) e ao redor é representado pela cor azul (ponto de mínima temperatura), já nas curvas de impedância térmica, esse efeito é ao contrário, a localização do centro da inclusão é representada pela cor azul (ponto de mínima impedância), afastado da

região do tumor, cor vermelha, é um ponto de máximo valor de impedância térmica.

Apresentam-se na Fig.6.3 esta comparação em termos de valores numéricos da variação de temperatura e impedância térmica relativos aos pixels normalizados.

Figura 6.3: Influência do metabolismo do tumor no perfil de pixels de: (a) Temperatura; (b) Impedância.

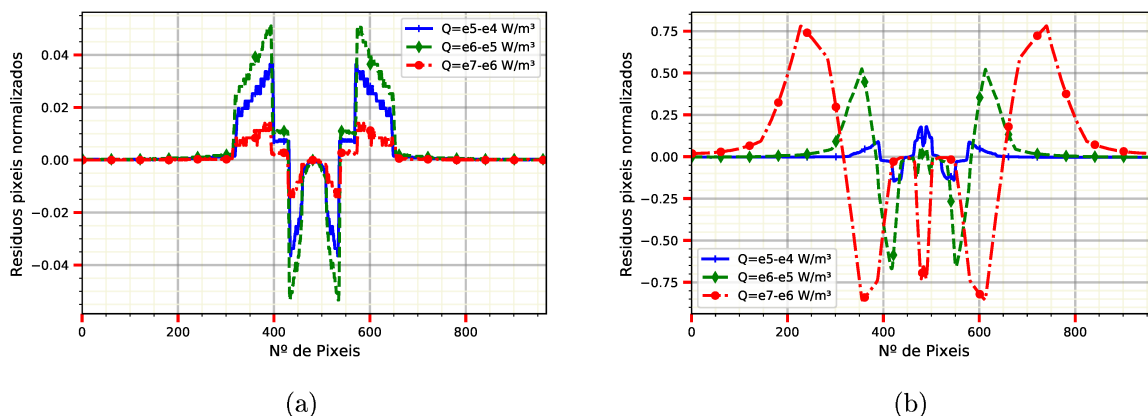


Fonte: Autoria própria.

Nota-se claramente na Fig.6.3a que nenhuma variação no perfil normalizado ocorre para diferentes valores de metabolismo. Já o efeito na impedância pode ser observado tanto nos perfis de pixels normalizados Fig.6.3 b.

Esta comparação fica ainda mais nítida ao se observar os resíduos dos pixels de temperatura e impedância, dados por 6.4a e 6.4b, respectivamente.

Figura 6.4: Influência do metabolismo do tumor no perfil de pixels de resíduo de: (a) Temperatura; (b) Impedância.

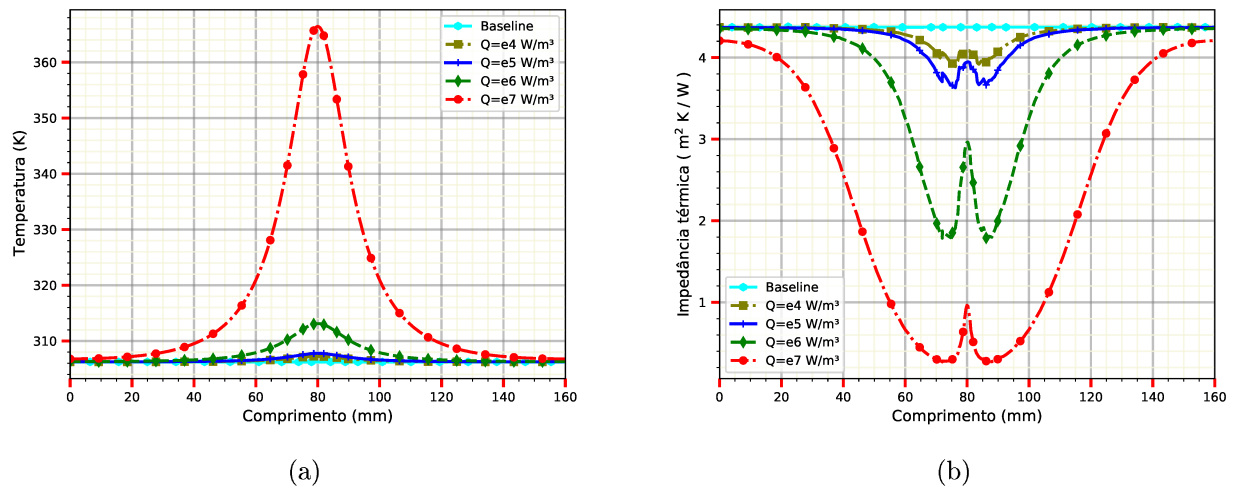


Fonte: Autoria própria.

Neste caso, pode-se notar os resíduos máximos alcançados em torno de 0.75 pela impedância, enquanto são inferiores a 0.045 para a temperatura.

Finalmente, apresenta-se a comparação em termos de valores numéricos da diferença de temperatura e impedância. A Fig. 6.5 apresenta esta variação.

Figura 6.5: Influência do metabolismo do tumor no perfil de: (a) Temperatura; (b) Impedância.

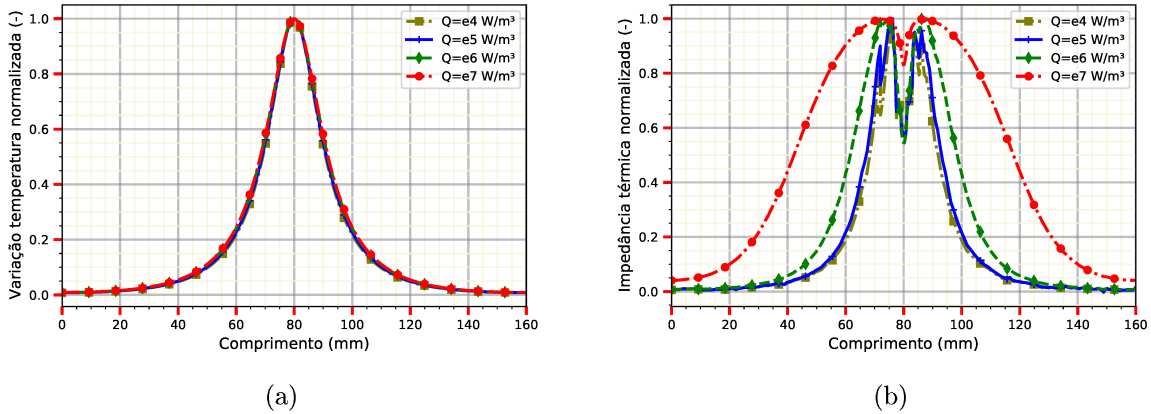


Fonte: Autoria própria.

Observa-se diferentes comportamentos dos perfis de temperatura e impedância para diferentes valores de Q. Entretanto, como já mencionado no capítulo anterior, ao se observar o comportamento desses perfis através de sua normalização nota-se que o comportamento dos perfis de temperatura são praticamente os mesmos. Os perfis de temperatura e impedância normalizados são apresentados na Fig. 6.6.

Observa-se que nenhuma alteração no perfil de temperatura ocorre, enquanto nos perfis da impedância térmica, para cada valor diferente do metabolismo uma curva de impedância térmica é observada.

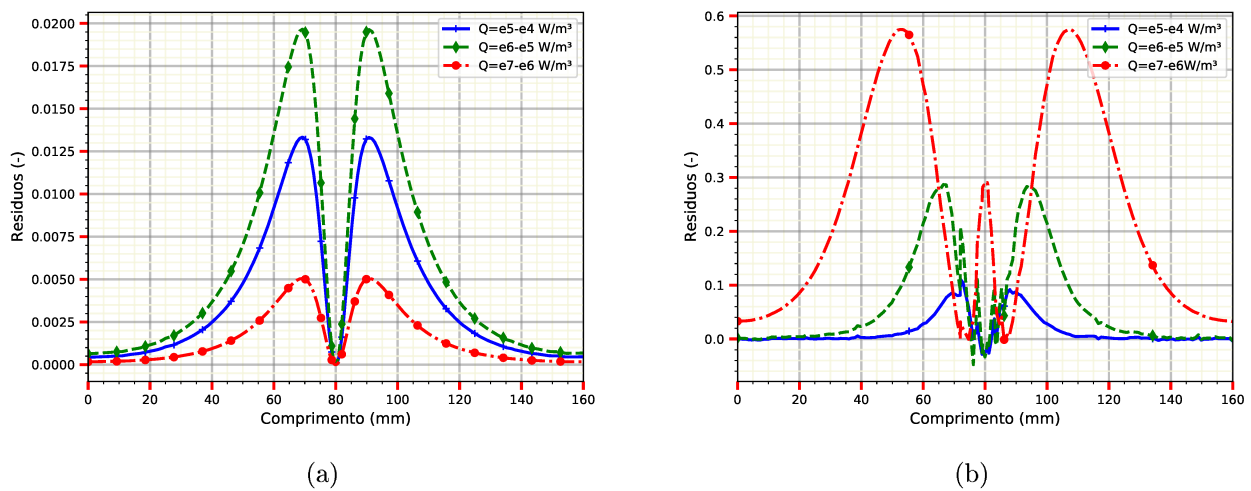
Figura 6.6: Influência do metabolismo do tumor no perfil de: (a) Temperatura; (b) Impedância, normalizados



Fonte: Autoria própria.

Esse comportamento é melhor comparado em termos de resíduos mostrados na Fig. 6.7 .

Figura 6.7: Influência do metabolismo do tumor no perfil de resíduos normalizados de: (a) Temperatura; (b) Impedância.



Fonte: Autoria própria.


Observa-se nestas figura que o valor máximo do resíduo de temperatura é de torno de 2% enquanto o valor máximo dos resíduos de impedância atinge 60%.

## 6.4 Influência da Variação do Tamanho do tumor na temperatura e impedância

Analogamente à seção anterior, serão mostrados os efeitos da variação do tamanho do tumor, no cálculo da impedância. Novamente perfis de pixels de temperatura e impedância, bem como seus resíduos são apresentados para comparação.

Apresentam-se na Figura 6.8 uma comparação da influência do tamanho do tumor no perfil de pixels na temperatura superficial e na impedância para diversos valores de  $Q$ .

Figura 6.8: Influência do tamanho do tumor no perfil de pixels na temperatura: (a)  $r = 2$  mm; (b)  $r = 4$  mm; (c)  $r = 7$  mm; (d)  $r = 10$  mm, e na impedância: (e)  $r = 2$  mm; (f)  $r = 4$  mm; (g)  $r = 7$  mm; (h)  $r = 10$  mm.

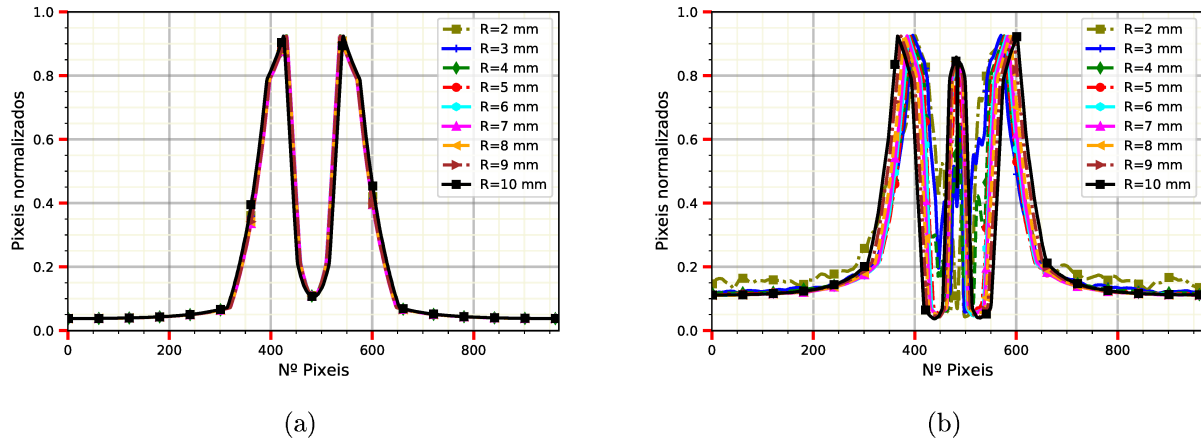


Fonte: Autoria própria.

Novamente observa-se um maior contraste e nitidez nos pixels da impedância. Entretanto, percebe-se uma menor sensibilidade em relação aquela obtida pela variação do metabolismo analisada na seção anterior.

Nas Figs. 6.9 analisam-se o efeito nos pixels normalizados. De forma análoga, observa-se a baixíssima influência da variação do tamanho do tumor no perfil de pixels normalizados de temperatura. Quanto aos pixels de impedância, percebe-se uma variação nos perfis, embora não sejam tão perceptíveis quanto na variação do metabolismo.

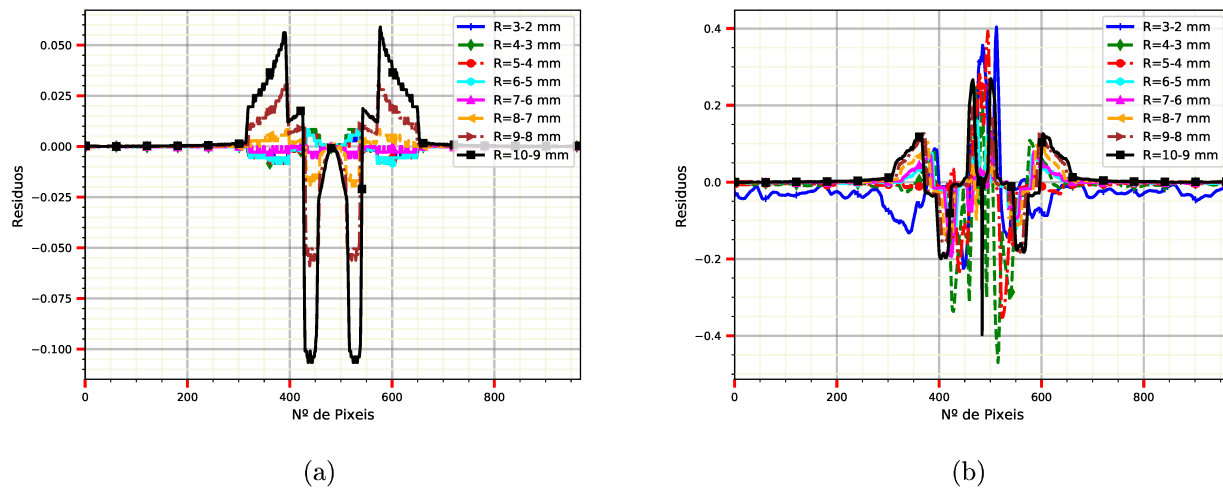
Figura 6.9: Influência do tamanho do tumor no perfil de pixels de: (a) Temperatura; (b) Impedância.



Fonte: Autoria própria.

Este comportamento é melhor observado nos perfis resíduos de temperatura e impedância normais, de temperatura e impedância normalizada e nos perfis de resíduos de temperatura e impedância normalizados, apresentados nas Figs. 6.10, 6.10 e 6.12, respectivamente.

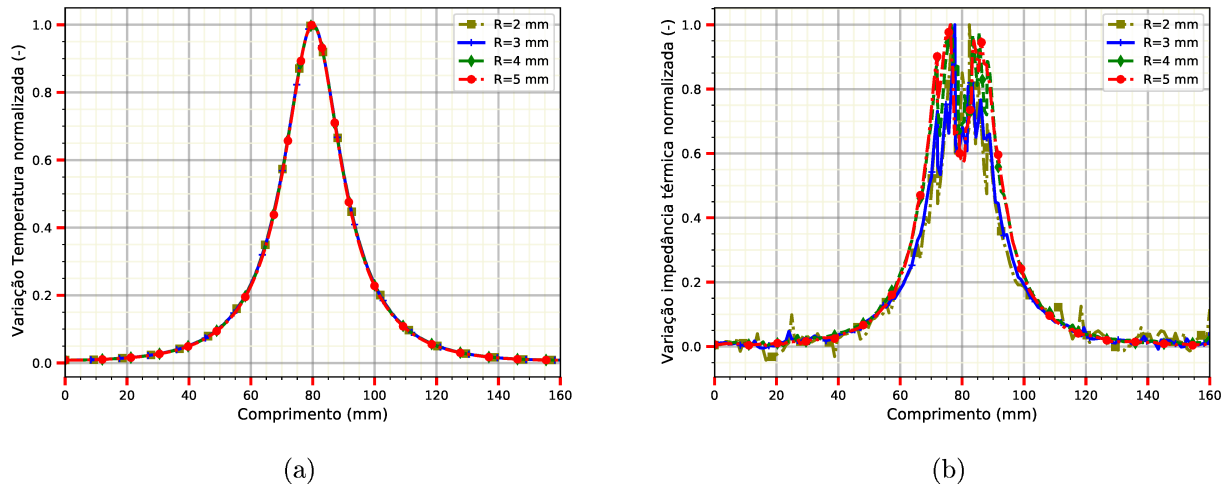
Figura 6.10: Influência do tamanho do tumor no perfil de resíduos de pixels de: (a) Temperatura; (b) Impedância.



Fonte: Autoria própria.




Figura 6.11: Influência do tamanho do tumor no perfil de: (a) Temperatura; (b) Impedância.



Fonte: Autoria própria.

Figura 6.12: Influência do tamanho do tumor no perfil de resíduos normalizados de : (a) Temperatura; (b) Impedância.



Fonte: Autoria própria.

Observa-se que embora a impedância apresente um melhor comportamento do ponto de vista da influência do diâmetro do tumor, alguma dificuldade é prevista na estimativa desse parâmetro.

No capítulo seguinte apresenta-se uma análise dos hiperparâmetros usados para o treinamento e definição da arquitetura da rede de aprendizado profunda projetada.

## Capítulo 7

# Análise da Influência dos Principais Hiperparâmetros usados Para Construção do Modelo em Deep Learning.

No estudo de aprendizado profundo existem muitos parâmetros que afetam de forma total ou parcial tanto na convergência da rede neural quanto no resultado de outros parâmetros. Esses são conhecidos como hiperparâmetros. Alguns influenciam significativamente no problema de otimização e outros não, mas mesmo os que não possuem influência significativa podem melhorar a precisão dos resultados de convergência da rede neural convolucional em que se deseja analisar.

Existem ferramentas de otimização específicas para encontrar de forma automática os hiperparâmetros usados em aprendizado profundo, porém, para que este processo seja efetivo, em alguns métodos deve-se escolher um vetor de valores para cada hiperparâmetro e deixar o computador fazer uma correlação entre todos os parâmetros e destes encontrar uma melhor configuração. Porém, para isto é necessário tempo para abranger todas as configurações possíveis e dependendo do vetor de valores escolhido, ainda existe possibilidade de não ser o melhor devido ao tempo de convergência de cada hiperparâmetro. Um dos métodos de busca automática é conhecido como otimização Bayesiana estudado por Victoria e Maragatham (2020), o qual usa um modelo probabilístico para encontrar os parâmetros desejados.

Uma segunda forma para encontrar uma boa correlação entre os hiperparâmetros e a mais usada por pesquisadores é a verificação manual dos parâmetros, método conhecido como tentativa e erro. A importância desse método é se deve a uma melhor visualização na convergência do modelo alterando-se os parâmetros um a um. Uma desvantagem deste processo, é que o mesmo demanda muito tempo. Por isso, encontrar os hiperparâmetros é uma das etapas mais importantes do processo de aprendizado profundo. De acordo com Brownlee (2020), é necessário experimentar uma variedade de configurações de hiperparâmetros e descobrir quais funcionam

melhor no banco de dados em análise. Além disso, o autor afirma que deve-se verificar quais algoritmos de otimização, funções de ativação e métodos de regularização que resulta no modelo de melhor desempenho, Deve-se testar ambos e comparar para ver qual ou quais são os melhores.

Existem dois tipos principais de hiperparâmetros. O primeiro está relacionado com as variáveis que determinam a estrutura da rede (ex: número de camadas ocultas) e o segundo refere-se as variáveis que determinam como a rede é treinada (ex: taxa de aprendizagem). Os hiperparâmetros devem ser definidos antes do treinamento da rede e possuem influência na capacidade de convergência da mesma.

Os hiperparâmetros relacionados à estrutura da rede são:

1. Inicialização dos pesos e bias.
2. Números de camadas e Número de neurônios por camada.
3. Função de ativação.
4. Otimizador.

Os hiperparâmetros relacionados as variáveis de como a rede é treinada.

1. Tamanho do lote (*batch size*).
2. Qualidade da imagem (*target size*)
3. Número de épocas (*epochs*)
4. Taxa de aprendizagem.
5. Momentum.

Para todas as análises de convergência da rede neural, foram fixados alguns hiperparâmetros e para estes, considerou-se valores mais usados na comunidade científica, Variou-se apenas um deles para se verificar a capacidade de convergência da rede neural. A Tab.7.1 apresenta os parâmetros que foram considerados para esta análise.

Tabela 7.1: Considerações feitas em relação aos hiperparâmetros no estudo de convergência da rede neural.

Hiperparâmetro	Considerações
Peso	Matriz GloriotUniform
Bias	Vetor de zeros
Função de Ativação	Relu
N° de Camadas	2
N° de Neurônios	32
Otimizador	adam
Qualidade da Imagem	$32 \times 32$
Tamanho do Lote	32
Regularizadores	-
N° Épocas	1000

Todas análises feitas neste capítulo serão esboçadas na forma de gráficos. Os principias estão relacionados a precisão dos resultados e a função perda, também conhecida como função custo ou função erro. Para essa análise, o banco de dados foi gerado a partir da mama cartesiana constituído de 898 imagens.

A precisão da previsão de uma rede neural depende dos termos vieses e pesos. O processo de melhoria da precisão da rede neural é chamado treinamento. Os valores de saída de uma rede neural na propagação direta, do inglês *forward propagation* é comparada com o valor que é conhecido como correto.

A função perda ou função custo é a diferença entre a saída real e a saída gerada pela rede neural. O objetivo do treinamento é fazer com que o custo do treinamento seja o menor possível. Para fazer isso, a rede ajusta as tendências de pesos e vieses até que a previsão corresponda à saída correta. Uma vez bem treinada, uma rede neural tem o potencial de fazer previsões precisas todas as vezes.

Estudos feitos neste capítulo abordam a capacidade da rede neural tanto em relação a precisão quanto ao erro relacionados ao conjunto de dados do treinamento. A mudança nos resultados nesse conjunto de dados afetam igualmente o conjunto de testes, tanto na melhora quanto na piora dos seus resultados.

A Tabela 7.2 mostra as configurações do computador usado nas análises apresentadas neste capítulo, sendo que um hardware importante para trabalhar-se com *Deep Learning* é a placa de vídeo, Ou seja, a rede neural está limitada a capacidade de processamento do computador e devido a quantidade de parâmetros da rede neural o processamento dos dados se torna um trabalho inviável para o processador.

Se o computador não tiver uma placa de vídeo, o processamento dos dados será feito apenas

pelo processador e o custo computacional será altíssimo, podendo até o programa não rodar dependendo dos hiperparâmetros escolhidos. Quando atribui-se a função de processamento a uma placa de vídeo de alto desempenho, o custo computacional cai consideravelmente, sendo possível analisar as mais variadas configurações de hiperparâmetros possíveis.

Tabela 7.2: Configurações do computador usado nas análises.

Hardware	Especificações
Processador	i7-9700K
Memória RAM	32 gb
Placa Mãe	ASUS TUF B360M-PLUS GAMING/B
Placa de Vídeo	RTX 2080Ti
Disco Rígido (HD)	2 Tb
Unidade em estado sólido (SSD)	480 gb

O suporte a GPUs do TensorFlow requer uma variedade de drivers e bibliotecas. Para vincular a GPU com tensorflow para que a placa de vídeo seja reconhecida pelo programa python existem requisitos de softwares que devem ser instalados em versões compatíveis. De acordo com Tuomanen (2018), seguintes softwares NVIDIA® devem ser instalados no sistema: Drivers GPU NVIDIA®, CUDA® Toolkit, CUPTI, cuDNN SDK, TensorRT.

De acordo com Sanders e Kandrot (2010), desde a estreia do CUDA, sigla para *compute unified device architecture*, software que possibilita o uso de computação paralela, que teve início em 2007, com uso notório na indústrias de aplicativos, tiveram grande sucesso ao escolher construir aplicativos com CUDA. O principal benefício inclui melhorias de desempenho pois, aplicativos executados em processadores gráficos NVIDIA possuem desempenho superior do que as implementações construídas exclusivamente em tecnologias tradicionais de processamento central.

O software *CUDA Profiling Tools Interface* (CUPTI) permite a criação de ferramentas voltadas para aplicativos CUDA, o mesmo vem incluso quando instala-se o software CUDA® Toolkit. A biblioteca NVIDIA CUDA® *Deep Neural Network* (cuDNN) é uma biblioteca de redes neurais profundas acelerada pela GPU. O software cuDNN fornece operações melhoradas para rotinas padrão, como convoluções, propagação direta, retropropagação, funções de ativação e gradiente descendente. Esta biblioteca é usada pela maioria das estruturas de redes neurais profundas que usam Tensorflow como back-end para NVIDIA GPUs. cuDNN acelera estruturas de aprendizado profundo amplamente utilizadas, incluindo Caffe2, Chainer, Keras, MATLAB, MxNet, PaddlePaddle, PyTorch e TensorFlow. TensorRT é um software opcional cuja função está relacionada a melhorar a latência e a capacidade de inferência em alguns modelos de aprendizado profundo (TUOMANEN, 2018).

Alterando-se apenas os pesos, bias função de ativação, o custo computacional para treinamento da rede foi em média de 04h30 minutos por curva gerada considerando-se os outros parâmetros fixos da Tab.7.1.

O custo computacional para fazer o treinamento da rede, como mencionado anteriormente, é fortemente dependente da capacidade de processamento do computador e se o mesmo possui placa de vídeo ou não, porém um dos hiperparâmetros que mais afetam no custo computacional é a qualidade da imagem considerada no modelo em análise. Possivelmente imagens com melhores qualidades devem gerar um treinamento da rede mais precisa, entretanto o custo computacional deve ser considerado.

Tabela 7.3: Custo computacional relativo a qualidade da imagem analisada.

Qualidade da Imagem	Tempo
$32 \times 32$	04h30m
$64 \times 64$	04h35m
$128 \times 128$	04h50m
$256 \times 256$	05h32m
$512 \times 512$	10h42m

## 7.1 Influência do Peso (*Weight*)

Conforme apresentado no Cap.3.4, existem varias maneiras de inicializar as matrizes de pesos e as mais conhecidas atualmente e usadas em aprendizado profundo foram analisadas para verificar a capacidade de convergência da rede neural convolucional.

As legendas das curvas mostradas neste capítulo são baseadas nas variações dos parâmetros em análise, em que muitas delas os gráficos gerados apresentaram muito ruído, portanto foi necessário usar a média móvel para reduzi-los com objetivo de melhorar a visualização. Nesses casos, as legendas das curvas que apresentam média móvel começam por *Ma*. As Figuras 7.1 e 7.2 são referentes as maneiras de inicialização das matrizes de peso, sendo que a letra *w* refere-se a matriz de peso, e a continuação do nome dado é referente ao tipo de inicialização dessas matrizes. A Tabela7.4 mostra as abreviações escolhidas para cada tipo de matriz.


Tabela 7.4: Tipos de Inicializações das matrizes de peso.

Matriz de Peso	Abreviação
Uniforme Glorot	GU
Normal Glorot	GN
Uniforme aleatório	RU
Normal aleatório	RN
Normal truncada	TN
Ortogonal	OR
Escalar variante	VS
Um	ON
Zeros	Z

A Fig.7.1 (a) apresenta o gráfico da precisão pelo número de épocas. Observa-se que o treinamento da rede neural com matrizes composta por elementos unitários e zeros não apresentam mudança nos resultados sendo impossível levar a um valor de convergência. Já os outros tipos de inicialização convergem de diferentes formas. Na Fig.7.1 (b) mostra o zoom do gráfico anterior, mas no final do treinamento constatou-se que a matriz de peso normal truncada apresenta melhores resultados e a uniforme Glorot os piores para o intervalo de épocas em análise.


A Fig.7.2 (a) apresenta o gráfico da função erro pelo número de épocas, observa-se aqui também que o treinamento da rede neural com matrizes um e zeros não converge. A Fig.7.2 (b) mostra o zoom do gráfico anterior porém no final do treinamento, também aplicou-se a média móvel nas curvas para reduzir o ruído, observa-se que a matriz de peso normal truncada apresenta menores valores, com isso, melhor convergência e a matriz uniforme Glorot os piores para o intervalo de épocas analisado.

Figura 7.1: Peso: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel.



Fonte: Autoria própria.

Figura 7.2: Peso: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel.



Fonte: Autoria própria.

## 7.2 Influência do Viés (*Bias*)

Além da matriz de pesos, outro parâmetro que influencia na convergência da rede neural é o parâmetro viés, do inglês *bias*, sendo que os tipos de inicialização deste parâmetro são semelhantes as usadas nas matrizes de peso, contudo é possível inicializar a rede neural sem adicionar este parâmetro.



A legenda das curvas mostradas nas Figs. 7.3 e 7.4 são referentes a inicialização dos vetores do termo bias, em que a letra b refere-se ao vetor de bias, e a continuação do nome dado para a legenda é referente ao tipo de inicialização desse parâmetro, a Tab.7.5 mostra as abreviações escolhidas para cada tipo de vetor.

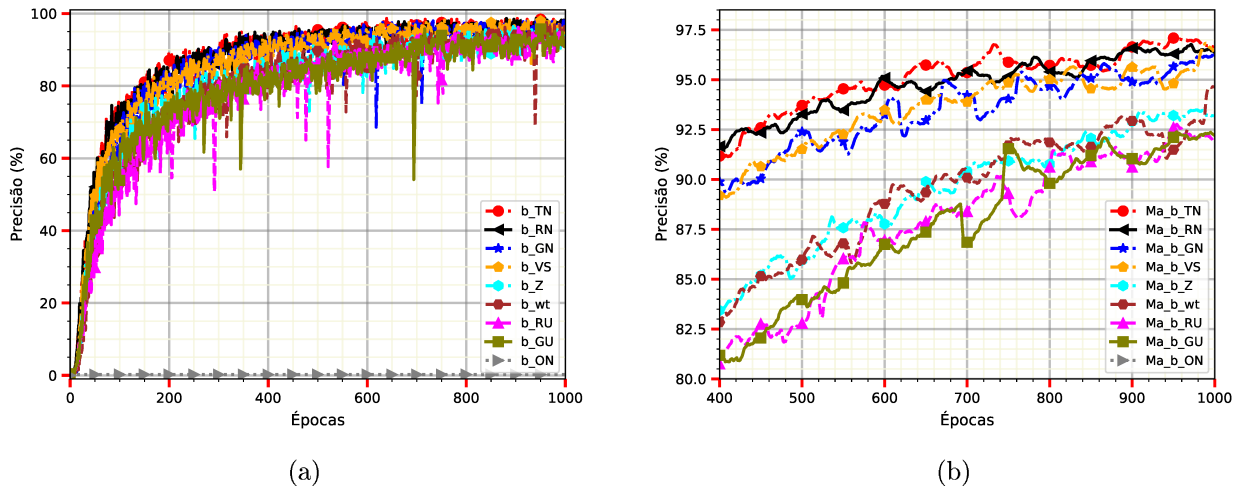
Tabela 7.5: Tipos de Inicializações dos vetores de bias.

<b>Vetor de Bias</b>	<b>Abreviação</b>
Uniforme Glorot	GU
Normal Glorot	GN
Uniforme aleatório	RU
Normal aleatório	RN
Normal truncada	TN
Sem bias	WB
Escalar variante	VS
Um	ON
zeros	Z

A Fig.7.3 (a) apresenta o gráfico da precisão pelo número de épocas, observa-se que o treinamento da rede neural com vetor de elementos zeros não apresenta convergência, já os outros tipos de inicialização convergem. A Fig.7.3 (b) mostra o zoom do gráfico anterior no final do treinamento, observa-se que o vetor normal truncado apresenta melhores resultados e a vetor uniforme Glorot os piores para o intervalo de épocas analisado.

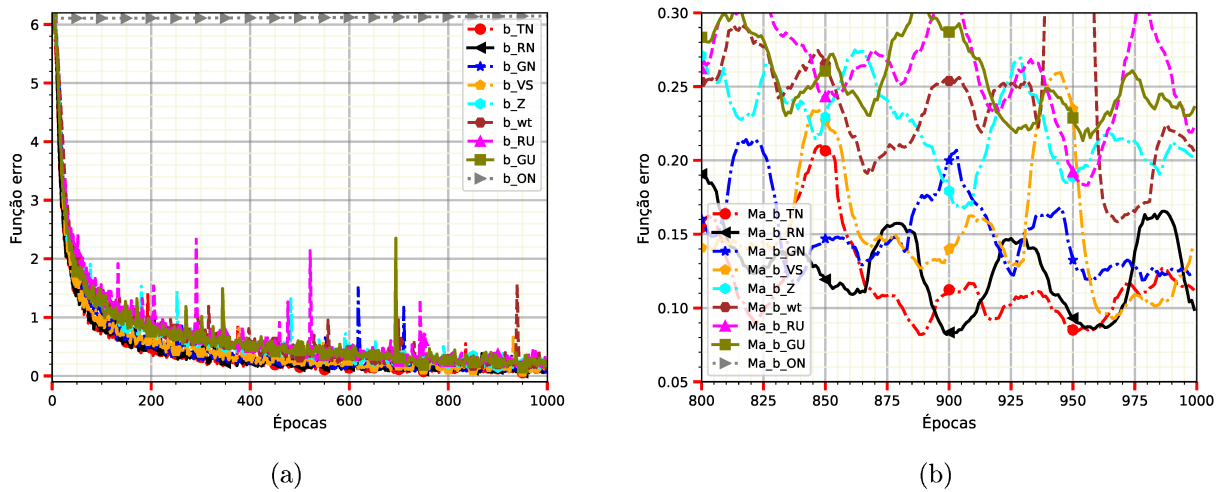
A Fig.7.4 (a) apresenta o gráfico da função erro pelo número de épocas, Nota-se aqui também que o treinamento da rede neural com vetores de elementos unitários não apresentam mudança nos resultados. A Fig.7.4 (b) mostra o zoom do gráfico anterior em que a vetor de bias normal truncado apresenta menores valores, com isso, melhor convergência e a uniforme Glorot os piores para o intervalo de épocas em análise.

Figura 7.3: Bias: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel.



Fonte: Autoria própria.

Figura 7.4: Bias: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel.



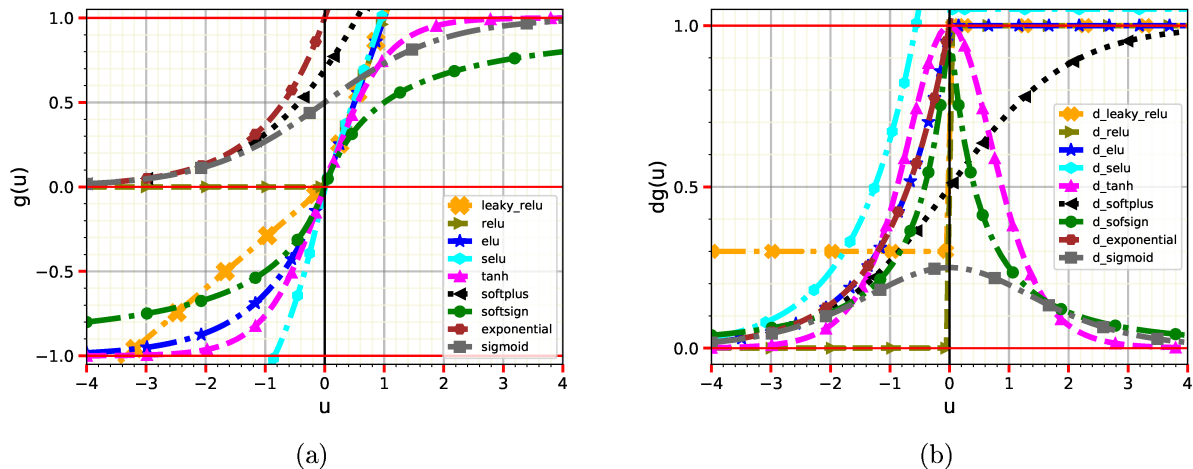
Fonte: Autoria própria.

## 7.3 Influência das Funções de Ativação

Conforme apresentado no Cap. 3.5 existem varias funções de ativações muito usadas em aprendizado profundo. A Figura 7.5 (a) apresenta uma comparação entre as mesmas para valores de entrada de  $u \in \mathbb{R} \mid -4 \leq u \leq 4$  e uma resposta  $-1 \leq g(u) \leq 1$ . Como mencionado anteriormente, essas funções tem como objetivo determinar os valores de saída do modelo de

aprendizado profundo. A Figura 7.5 (b) apresenta o resultado da derivada das funções de ativação, para o intervalo de  $-4 \leq u \leq 4$  e uma resposta  $0 \leq dg(u) \leq 1$ , a derivada da função é usada nos cálculos de atualização dos pesos da rede neural no processo chamado de retropropagação, do inglês *backpropagation*.

Figura 7.5: Funções de Ativação: (a) Função ; (b) Derivada.

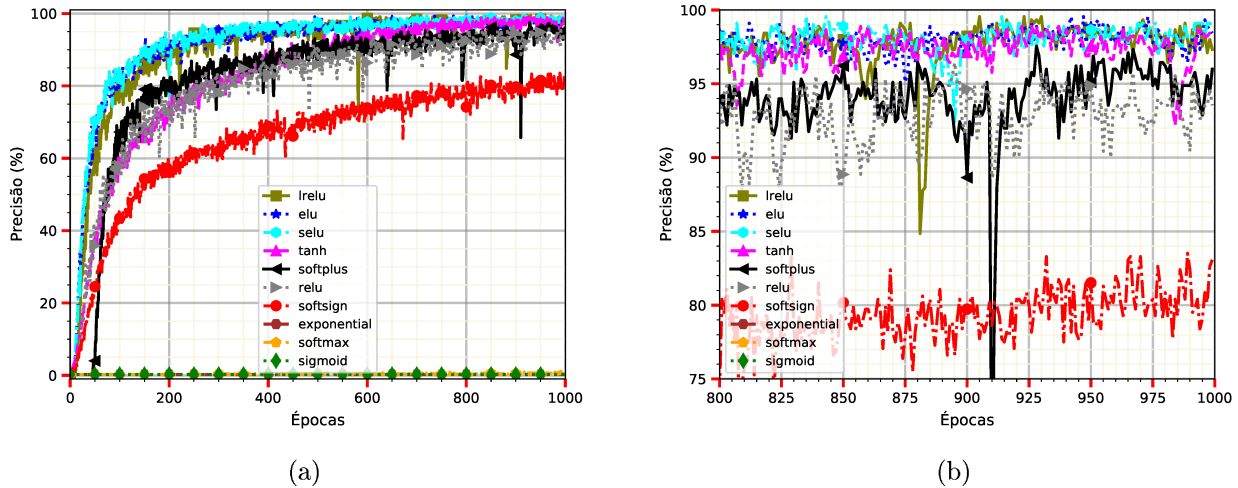


Fonte: Autoria própria.

A Figura 7.6 (a) apresenta o gráfico da precisão pelo número de épocas, observa-se que o treinamento da rede neural com funções de ativação exponencial, sigmoid e softmax não apresentam convergência, já os outros tipos de inicialização convergem, a Fig.7.6 (b) mostra o zoom do gráfico anterior no final do treinamento, nota-se que as funções de ativação lrelu, elu e selu apresentam melhores resultados, já a função softsign, mesmo após 1000 épocas apresenta precisão final em torno de 80 %.

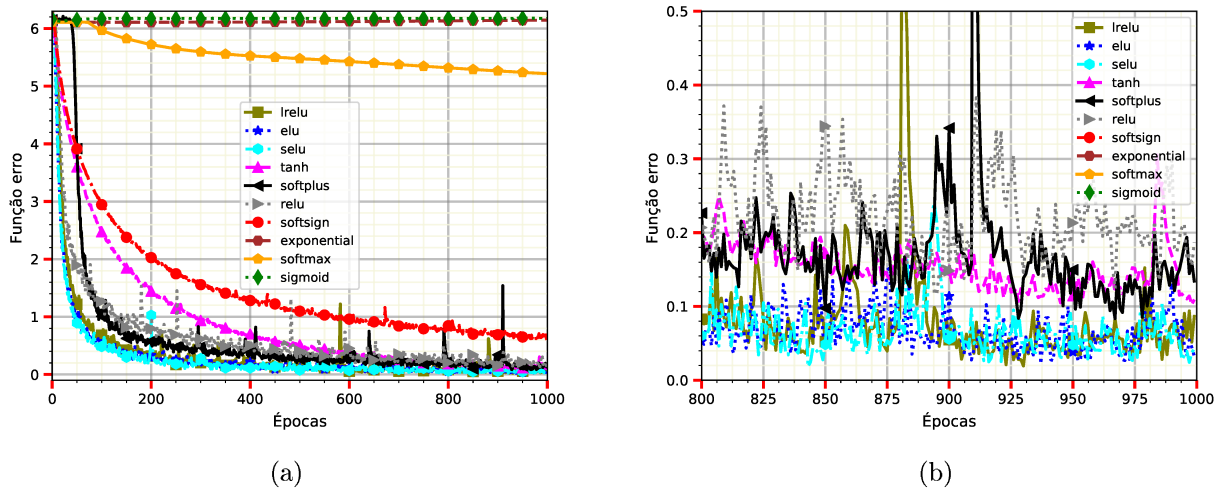
A Figura 7.7 (a) mostra o gráfico da função erro pelo número de épocas, observa-se aqui também que as funções de ativação lrelu, elu e selu convergem mais rápido. A Figura 7.7 (b) mostra o zoom do gráfico anterior no final do treinamento da rede, nota-se que as funções mencionadas chegam mais próximo do valor zero, ou seja, melhores resultados de convergência.

Figura 7.6: Função de ativação: (a) precisão ; (b) Zoom dos valores da precisão.



Fonte: Autoria própria.

Figura 7.7: Função de ativação: (a) Função erro ; (b) Zoom dos valores da função erro.



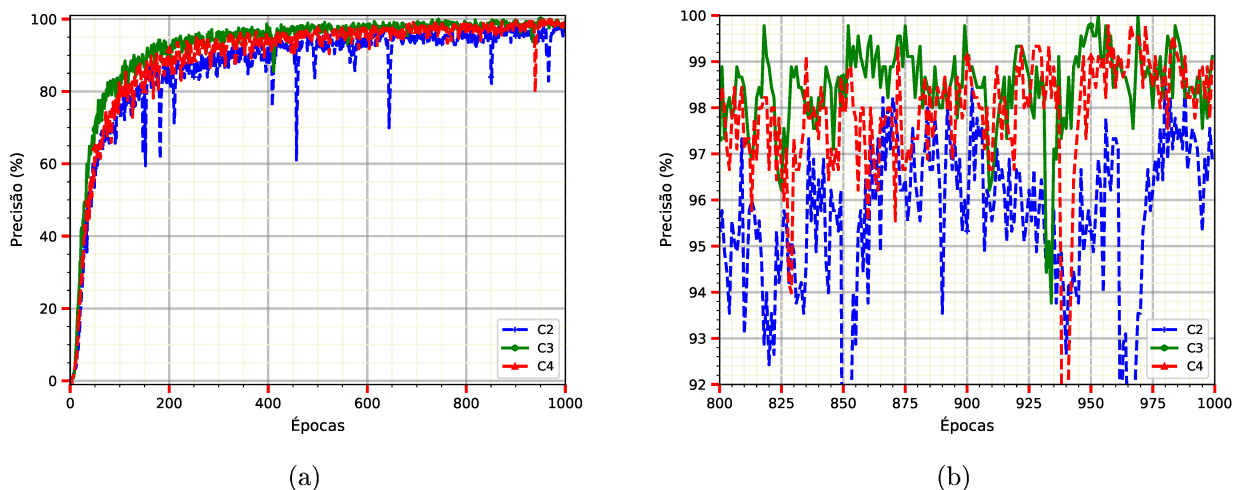
Fonte: Autoria própria.

## 7.4 Influência da Quantidade de Camadas Escondidas

De acordo com, Goodfellow, Bengio e Courville (2016), a precisão das redes neurais aumenta com o número de camadas ocultas, porém, como observado neste trabalho, este parâmetro está fortemente ligado ao conjunto de dados de treinamento, conforme Figura 7.8, nota-se que 3 camadas escondidas apresenta melhores resultados de precisão do que duas ou quatro camadas. Na Figura 7.9 observa-se que 3 camadas escondidas apresentam menores valores de função erro,

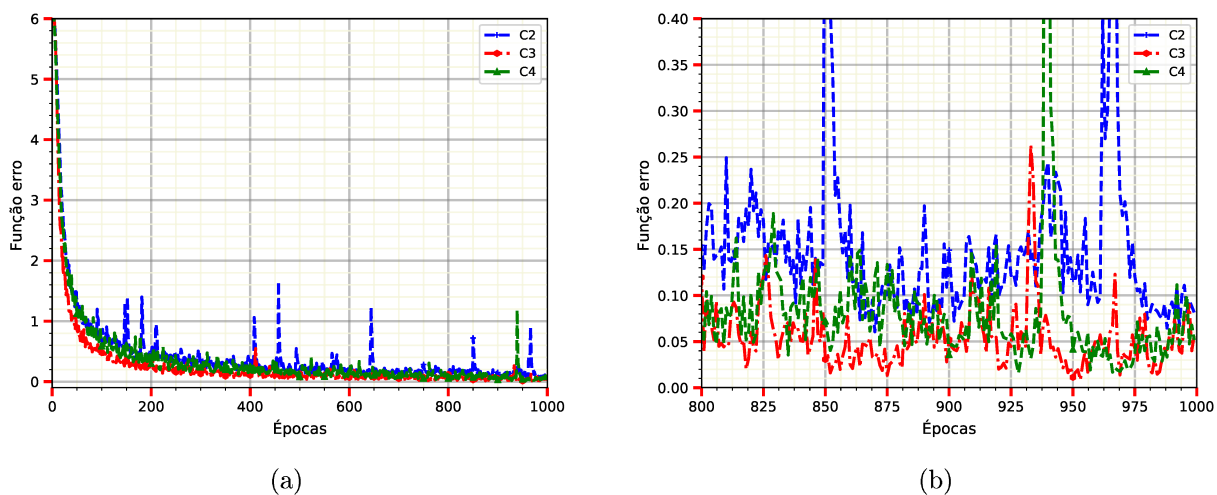
isto ocorre devido ao banco de dados possuir uma quantidade limitada de dados de entrada, não precisando-se assim de grandes quantidades de camadas escondidas para atingir bons valores de precisão.

Figura 7.8: Quantidade de Camadas Escondidas: (a) Precisão ; (b) Zoom dos valores da precisão.



Fonte: Autoria própria.

Figura 7.9: Quantidade de Camadas Escondidas: (a) Função erro ; (b) Zoom dos valores da função erro.



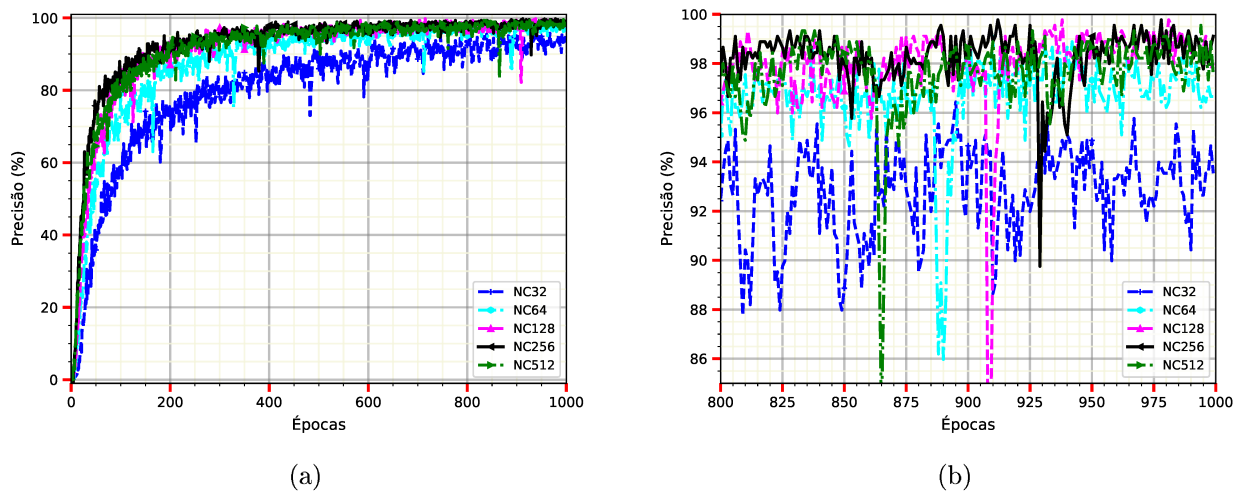
Fonte: Autoria própria.

## 7.5 Influência do Número de Neurônios Por Camada

Outro parâmetro fortemente relacionado a dimensão do banco de dados é o número de neurônios por camada, observa-se na Figura 7.10 que as curvas foram nomeadas com a abreviação NC, a qual representa os neurônios por camada e na frente desta, colocou-se a quantidade usada, nota-se na Figura 7.10 (a) que a curva azul chamada de NC32, possui 32 neurônios por camada e a mesma demora mais tempo a chegar a um patamar estável de precisão, porém as curvas NC128, NC256 e NC512, representadas pelas cores rosa, preta e verde respectivamente, atingem de maneira mais rápida essa estabilidade, melhores valores de precisão podem ser vistos na Fig. 7.10 (b) a qual apresenta os resultados para o final do treinamento e nota-se que a curva com 128 e 256 neurônios por camada apresentam resultados semelhantes e até melhores quando comparados aos da curva com 512 neurônios.


A Figura 7.11 (b) mostra que 256 neurônios por camada apresenta resultados semelhantes a curva de 512, sendo representados pelos menores valores da função erro, com isso apresentam bons resultados de convergência.

Figura 7.10: Número de Neurônios Por Camada: (a) Precisão ; (b) Zoom dos valores da precisão.



Fonte: Autoria própria.

Figura 7.11: Número de Neurônios Por Camada: (a) Função erro ; (b) Zoom dos valores da função erro.



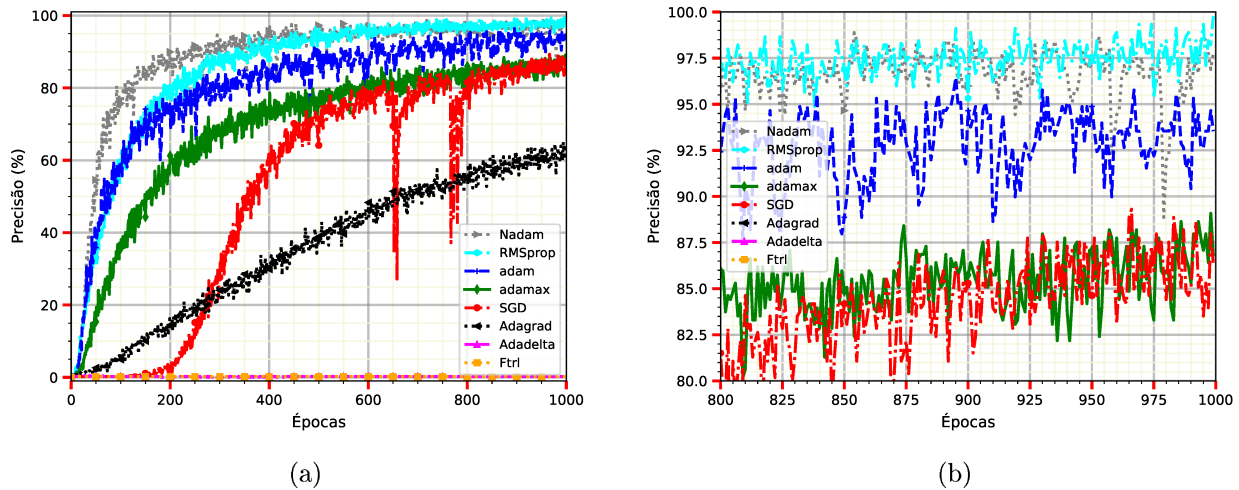
Fonte: Autoria própria.

## 7.6 Influência dos Otimizadores

Como apresentado na Cap. 3.7, existem vários otimizadores usados em aprendizado profundo. A Figura 7.12 (a) mostra o gráfico da precisão pelo número de épocas, observa-se que o treinamento da rede neural com os otimizadores Adadelta e Ftrl não apresentam alteração nos resultados de precisão conforme aumenta-se o número de épocas, o otimizador Adagrad após 1000 épocas de treinamento possui precisão em torno de 60 % com tendência ascendente, os outros tipos de inicialização apresentam melhores resultados, a Fig.7.12 (b) mostra o zoom no final do treinamento, observa-se que os otimizadores Nadam, RMSprop e Adam apresentam melhores resultados, já O SGD e Adamax, mesmo após 1000 épocas apresenta como precisão final em torno de 85 %.

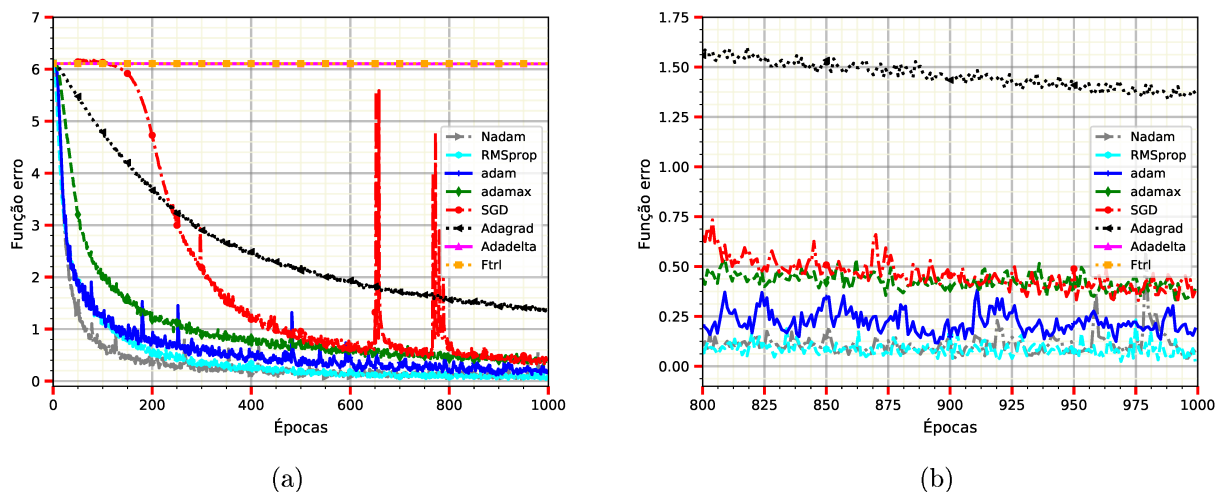
A Figura 7.13 (a) apresenta o gráfico da função erro pelo número de épocas, nota-se aqui também que os otimizadores Nadam, RMSprop e Adam convergem mais rápido. A Figura 7.13 (b) mostra o zoom do gráfico anterior, observa-se aqui também que os otimizadores mencionados chegam mais próximo do valor zero.

Figura 7.12: Otimizadores: (a) Precisão ; (b) Zoom dos valores da precisão.



Fonte: Autoria própria.

Figura 7.13: Otimizadores: (a) Função erro ; (b) Zoom dos valores da função erro.



Fonte: Autoria própria.


## 7.7 Influência da Qualidade da Imagem

Como mencionado anteriormente, a qualidade da imagem está diretamente relacionada ao tempo computacional e a capacidade do computador em realizar o processamento dos dados nas matrizes de pixels das mesmas. Foi feita análises para imagens considerando-se qualidades referentes aos números de pixels:  $32 \times 32$ ,  $64 \times 64$ ,  $128 \times 128$ ,  $256 \times 256$  e  $512 \times 512$ , observa-se na Fig. 7.14 que as curvas foram nomeadas com referência ao número de pixels das mesmas.



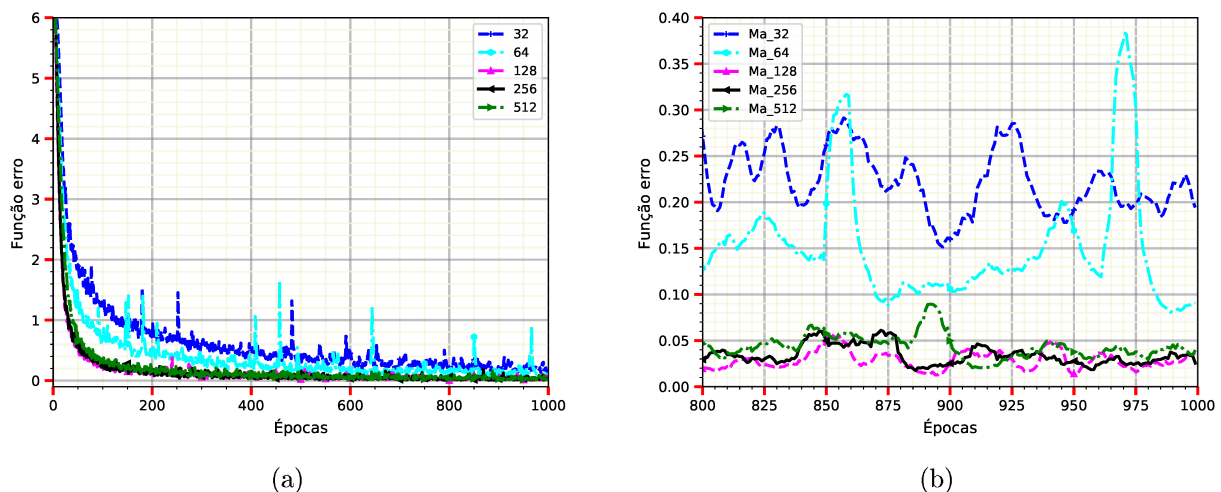
Conforme Figura 7.14 (a), nota-se que imagens com piores qualidades representadas pelas curvas 32 e 64 possuem menores valores de precisão enquanto as curvas 128, 256 e 512 convergem mais rápido. A Figura 7.14(b) mostra o zoom nos resultados no final do conjunto de treinamento, observa-se que as imagens com qualidades 128, 256 e 512 apresentam resultados semelhantes com bom comportamento no final do treinamento, percebe-se aqui, que para este banco de dados utilizar imagens 128X128 reduz o custo computacional e oferece bons resultados.

Figura 7.14: Qualidade da Imagem: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel.



Fonte: Autoria própria.

Figura 7.15: Qualidade da Imagem: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel.




Fonte: Autoria própria.

## 7.8 Influência do Tamanho do lote

Outro parâmetro analisado foi o tamanho do lote, do inglês *batch size*, existem 3 configurações para este hiperparâmetro, sendo eles: *stochastic mode*, *mini-batch mode* e *batch mode*. Na configuração *stochastic mode*, o tamanho do lote é igual a um, neste caso os parâmetros da rede neural são atualizados após cada amostra, a segunda configuração *mini-batch mode* usa o tamanho do lote maior que um, mas menor que o tamanho total do conjunto de dados e na terceira configuração *batch mode*, o tamanho do lote é igual ao conjunto de dados total, tornando os valores de iteração e épocas equivalentes (SHANMUGAMANI, 2018).


A Figura 7.16 (a) mostra a curva de precisão pelo número de épocas para valores de tamanho do lote:  $BS = 1, 32, 64, 128, 449$ , em análise dos extremos, observa-se que tamanhos menores de lotes resultam em uma precisão maior e tamanhos maiores geram valores de precisão menores nos dados de teste, a curva preta (BS1), é considerada *stochastic mode* onde o tamanho do lote em análise é igual a um e a curva verde (BS449), *batch size mode* apresenta piores resultados, e os mesmos podem ser conferidos na Fig. 7.16 (b) na qual nota-se que BS1 apresenta melhores resultados em comparação as outras curvas, porém pode-se observar que as configurações *batch mode* e *stochastic mode* são curvas mais estáveis em comparação as outras que possuem maior oscilação nos resultados.

Figura 7.16: Tamanho do lote: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel.



Fonte: Autoria própria.

Figura 7.17: Tamanho do lote: (a) Função erro ; (b) Zoom dos valores da função erro com uso da média móvel.




Fonte: Autoria própria.

## 7.9 Influência dos Regularizadores

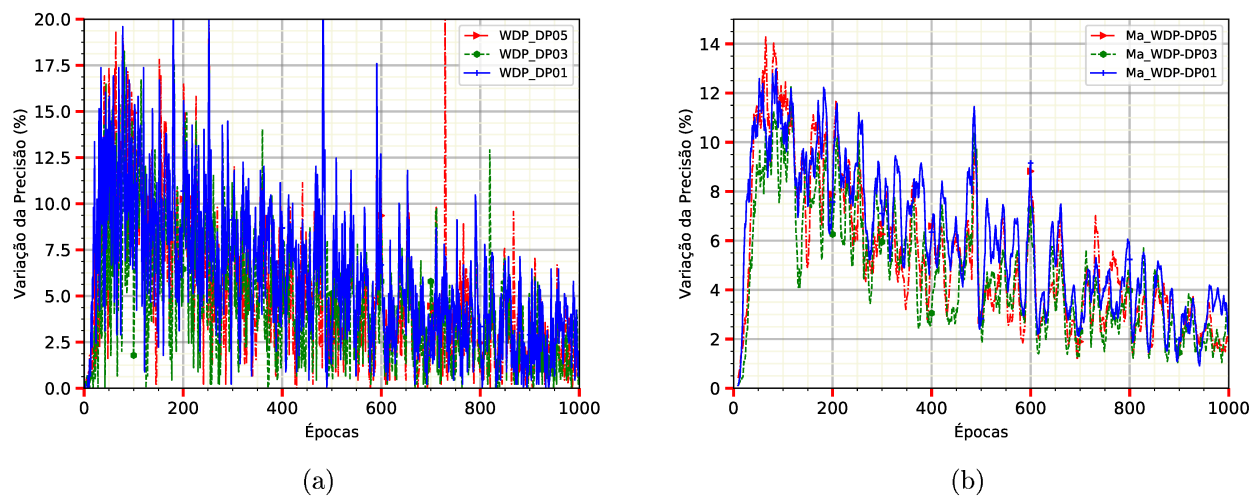
Conforme apresentado na Cap. 3.9, existem muitos métodos usados em aprendizado profundo que lidam com regularização, foi feita uma análise no método *dropout* no qual é feito a desativação aleatória de neurônios afim de minimizar os erros de convergência relacionados ao aprendizado das matrizes de peso. As curvas da Figura 7.18 foram nomeadas com abreviação DP para dropout e o restante do nome é referente a porcentagem de desativação dos neurônios, ou seja, os números 0.1, 0.3 e 0.5 representam respectivamente as porcentagens 10%, 30% e 50%, além destas nomenclaturas, fez-se uma análise sem usar a técnica de regularização e esta curva recebeu o nome de WDP. Observa-se na Figura 7.18 (a) que a curva WDP apresenta piores resultados para todo intervalo de análise e conforme Fig. 7.18 (b) a curva DP01 possui os melhores resultados e uma menor oscilação em relação as demais curvas. As Figuras 7.19 mostram a variação da precisão quando se aplica a técnica dropout e sem ela, observa-se que no início do treinamento tem-se um ganho de precisão em torno de 12 % e que após 1000 épocas essa variação cai para 2 %. A Figura 7.20 mostra que a curva DP01 possui menores valores da função erro e menor oscilação sendo a melhor taxa de desativação usada para o banco de dados em análise.

Figura 7.18: Dropout: (a) Precisão ; (b) Zoom dos valores da precisão com uso da média móvel.



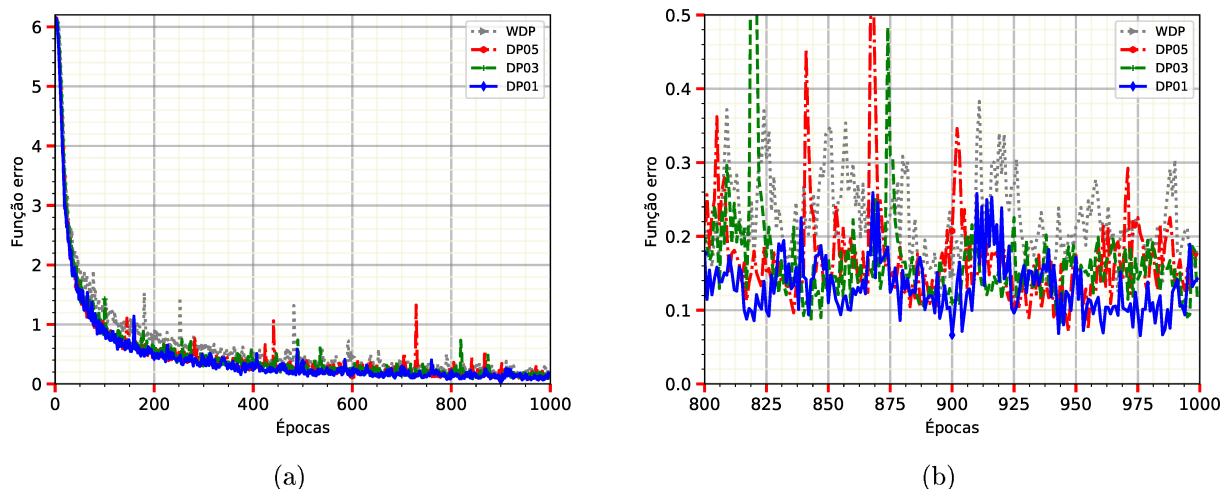
Fonte: Autoria própria.

Figura 7.19: Dropout: (a) Variação da Precisão ; (b) Média móvel da variação da precisão.



Fonte: Autoria própria.

Figura 7.20: Dropout: (a) Função erro ; (b) Zoom dos valores da função erro.



Fonte: Autoria própria.

Observa-se que de maneira geral, em praticamente todas as figuras do Cap.7 possuem picos de maneira aleatório, isso é devido ao fato que o banco de dados analisado possui poucas imagens por classe e somente nas análises com regularizadores foi possível observar a redução desse efeito. Deve ser enfatizado que os métodos de regularização são indicados para trabalhar com aprendizado profundo, principalmente quando o banco de dados é pequeno, cujo objetivo principal é a redução de overfitting.

## Capítulo 8

# Estimativa da localização de tumores em simulações numéricas com uso de imagens termográficas

Neste capítulo, são abordados os resultados numéricos da localização de tumores com uso de imagens termográficas simuladas. A lógica computacional foi toda desenvolvida no programa Python, que é uma linguagem de programação de alto nível, dinâmica, considerada atualmente uma das principais ferramentas de programação mais usadas entre profissionais da indústria tecnológicas pois possui muitas bibliotecas tornando a programação relativamente simples e de fácil compreensão. Além disso, foi usado o programa COMSOL *multiphysics* para gerar imagens termográficas simuladas para montar o banco de dados cujo interesse principal é de detectar características específicas de tumores através de imagens térmicas.

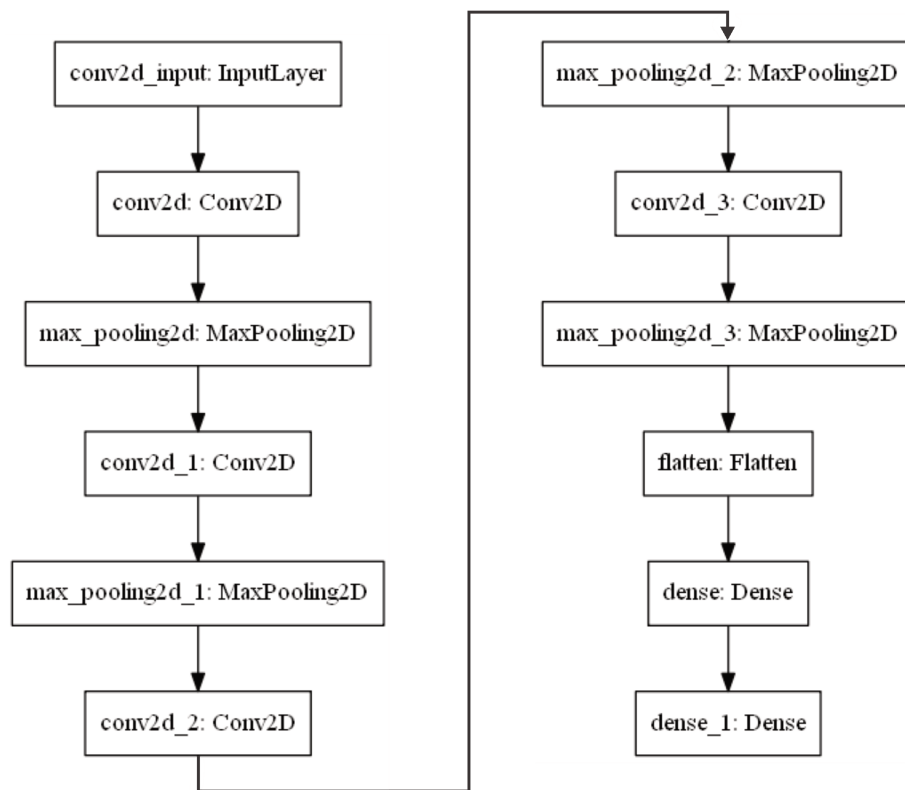
O objetivo deste capítulo é de estimar a localização de tumores fictícios usando-se imagens termográficas simuladas. Primeiramente, verificou-se a capacidade de estimativa de localização da posição de tumores fictícios, cujas localizações específicas fazem parte do banco de dados, porém foram criadas imagens infravermelhas com tumores com propriedades térmicas diferentes das conhecidas pelo banco de dados, esta análise foi chamada de problema direto. Este estudo muito importante, pois no Cap.7, verificou-se a necessidade de otimizar os parâmetros de forma a obter melhor precisão e menores valores para função erro, caso contrário a rede é incapaz de prever a profundidade correta de tumores nas posições  $x = 10$ ,  $y = 10$  pois os mesmos localizados no canto inferior esquerdo sofrem interferência na matriz de pixels devido a proximidade com as bordas esquerda e inferior.

Após resolvido o problema das bordas, verificou-se a capacidade da rede neural estimar a localização de tumores fictícios cujo posicionamento não foi passado pelo processo de aprendizado pela rede neural, esta análise foi chamada de problema inverso. Inicialmente variou-se uma

coordenada da posição de tumores fictícios localizados entre posições de tumores que passaram pelo processo de aprendizado da rede neural e verificou-se a capacidade da rede em correlacionar essas novas posições com as conhecidas pela rede neural, depois foi feita uma segunda análise na qual variou-se duas coordenadas na posição dos tumores.

A arquitetura das redes neurais convolucionais usada pode ser vista no fluxograma da Fig.8.1. Nota-se que a mesma é composta pela entrada dos dados *conv2d-input*, pelas camadas ocultas composta por *Conv2D* e *MaxPooling2D*, pela camada de achatamento dos dados *flatten* e pela camada de saída dos dados *dense*.

Figura 8.1: Arquitetura das redes neurais convolucionais usada.



Fonte: Autoria própria.

Um dos principais parâmetros que são treinados pelas redes neurais convolucionais são os pixels das imagens, como forma de comparação serão usadas imagens com pixels 128X128 e 512X512. O número de parâmetros que são treináveis pela rede neural são apresentados na Fig.8.2.

Figura 8.2: Formato imagem: (a) 128X128 ; (b) 512X512.

Model: "sequential"		
Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 126, 126, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 63, 63, 64)	0
conv2d_1 (Conv2D)	(None, 61, 61, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 30, 30, 64)	0
conv2d_2 (Conv2D)	(None, 28, 28, 64)	36928
max_pooling2d_2 (MaxPooling2D)	(None, 14, 14, 64)	0
conv2d_3 (Conv2D)	(None, 12, 12, 64)	36928
max_pooling2d_3 (MaxPooling2D)	(None, 6, 6, 64)	0
flatten (Flatten)	(None, 2304)	0
dense (Dense)	(None, 512)	1180160
dense_1 (Dense)	(None, 449)	230337
Total params: 1,523,073		
Trainable params: 1,523,073		
Non-trainable params: 0		

(a)

Model: "sequential"		
Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 510, 510, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 255, 255, 64)	0
conv2d_1 (Conv2D)	(None, 253, 253, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 126, 126, 64)	0
conv2d_2 (Conv2D)	(None, 124, 124, 64)	36928
max_pooling2d_2 (MaxPooling2D)	(None, 62, 62, 64)	0
conv2d_3 (Conv2D)	(None, 60, 60, 64)	36928
max_pooling2d_3 (MaxPooling2D)	(None, 30, 30, 64)	0
flatten (Flatten)	(None, 57600)	0
dense (Dense)	(None, 512)	29491712
dense_1 (Dense)	(None, 449)	230337
Total params: 29,834,625		
Trainable params: 29,834,625		
Non-trainable params: 0		

(b)

Fonte: Autoria própria.

Para essa análise, o banco de dados foi gerado a partir da mama cartesiana constituído de 898 imagens.

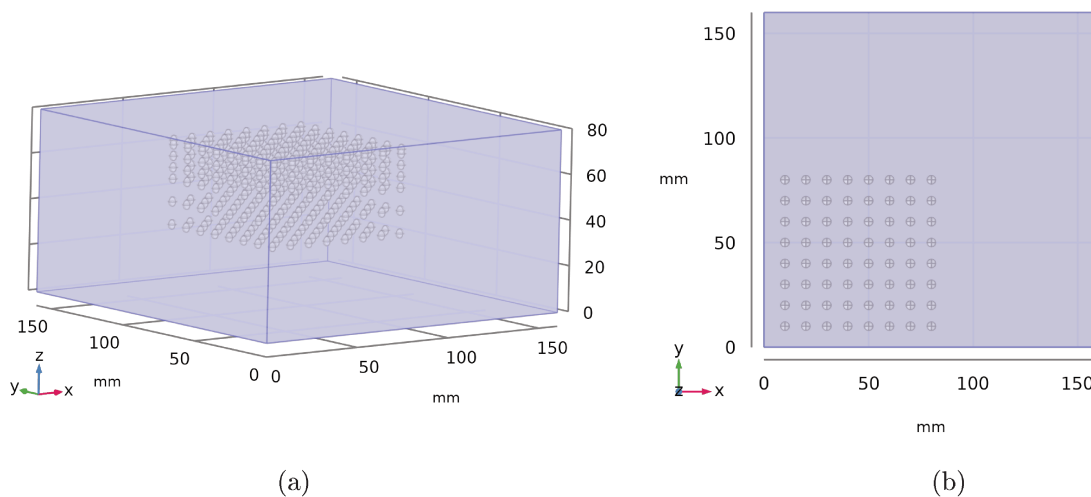


## 8.1 Problema Direto

### Modelo Cartesiana - Análise em regime permanente

Para análise do problema direto, foram adicionados tumores fictícios em posições específicas da mama cartesiana, as Figs. 8.3 e 8.4 mostram o posicionamento dos tumores que foram criados para montar o banco de dados das imagens termográficas simuladas. Em relação ao plano  $xy$ , os mesmos foram introduzidos distanciados de 10 mm cada, posicionados tanto na horizontal quanto na vertical, ou seja, variou-se suas posições no eixo  $x$ , entre  $x = 10$  mm até  $x = 80$  mm, em relação a coordenada  $y$ , entre  $y = 10$  mm até  $y = 80$  mm. A Fig. 8.3(b) mostra o posicionamento dos tumores simulados no plano  $xy$ .


Figura 8.3: Tumores simulados: (a) vista tridimensional; (b) vista superior plano  $xy$ .



Fonte: Autoria própria.


As Figuras 8.4(a) e 8.4(b) mostram, respectivamente, o posicionamento dos tumores simulados no plano  $yz$  e no plano  $xz$ , ou seja posicionamento em relação a altura, sendo que em  $z = 80$  mm representa a superfície da pele e  $z = 0$  mm é a região considerada interna da mama com temperatura constante.

Figura 8.4: Tumores simulados: (a) vista lateral direita, plano xz; (b) vista frontal, plano yz.



Fonte: Autoria própria.


Figura 8.5: Modelo Simulado: (a) Temperatura ; (b) Vista Transparente para visualização da fonte de calor metabólico.



Fonte: Autoria própria.

As Figuras 8.6 mostram imagens termográficas da superfície da mama cartesiana, cuja posição dos tumores simulados variam-se tanto no plano quanto na altura em relação a superfície da pele.

Figura 8.6: Banco de dados de imagens termográficas simuladas cuja localização  $(x,y,z)$  é dada por: (a)  $(10, 10, 77)$ ; (b)  $(80, 10, 77)$ ; (c)  $(10, 80, 77)$ ; (d)  $(80, 80, 77)$ , a variação na altura com  $(80, 80, z)$  é dada: (e)  $z = 60$  mm; (f)  $z = 65$  mm; (g)  $z = 70$  mm; (h)  $z = 75$  mm.



Fonte: Autoria própria.

Objetiva-se localizar o centro de uma fonte de calor metabólica tumoral usando apenas imagens termográficas de uma única superfície da pele da mama (superfície em  $z = H$ ).

Inicialmente verificou-se que o modelo de rede neural baseado em aprendizado profundo era incapaz de prever a profundidade correta de tumores nas posições  $x = 10$ ,  $y = 10$ , localizados no canto inferior esquerdo, percebe-se que os mesmos sofrem interferência na matriz de pixels devido a proximidade com as bordas da imagem térmica, com isso percebeu-se a necessidade de otimizar os hiperparâmetros de forma a obter melhores resultados de precisão e menores valores para função erro, pois a rede neural deve ser capaz de estimar as localizações que já foram passadas pelo aprendizado alterando-se apenas os parâmetros térmicos dos tumores.

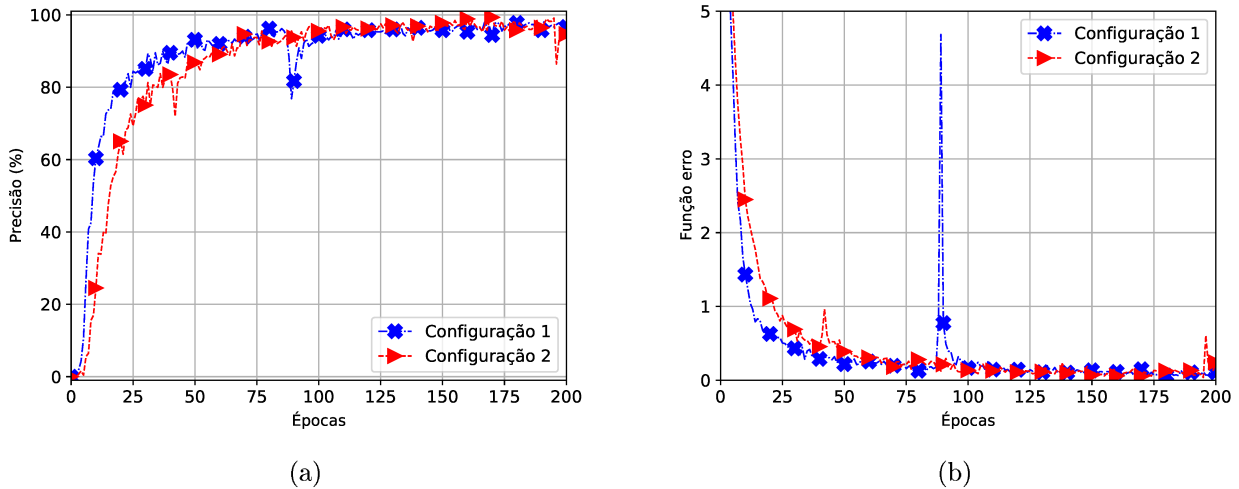
Dentre as inúmeras possibilidades de configurações de hiperparâmetros mostradas no Capítulo 7, duas configurações foram escolhidas para criar o modelo em rede neural referente ao banco de dados criado.

Configuração 1 usou-se o otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios por camada, função de ativação relu, qualidade da imagem 512X512.

Configuração 2: otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios, diferentemente usou-se a função de ativação lrelu e qualidade da imagem 128X128. As Figs. 8.7 (a) e (b) mostram, respectivamente, a precisão dos dados e a função erro. Observa-se que com a configuração 1, os dados convergem mais rápido, porém, o modelo adquire um pico de insta-

bilidade na metade do treinamento, já a configuração 2 demora um pouco mais para convergir, devido ao fato da imagem analisada ser de pior qualidade, porém na convergência, possui uma curva com maior estabilidade.

Figura 8.7: Convergência da rede neural com a imagem de temperatura da superfície da mama cartesiana: (a) Precisão ; (b) Função erro.



Fonte: Autoria própria.

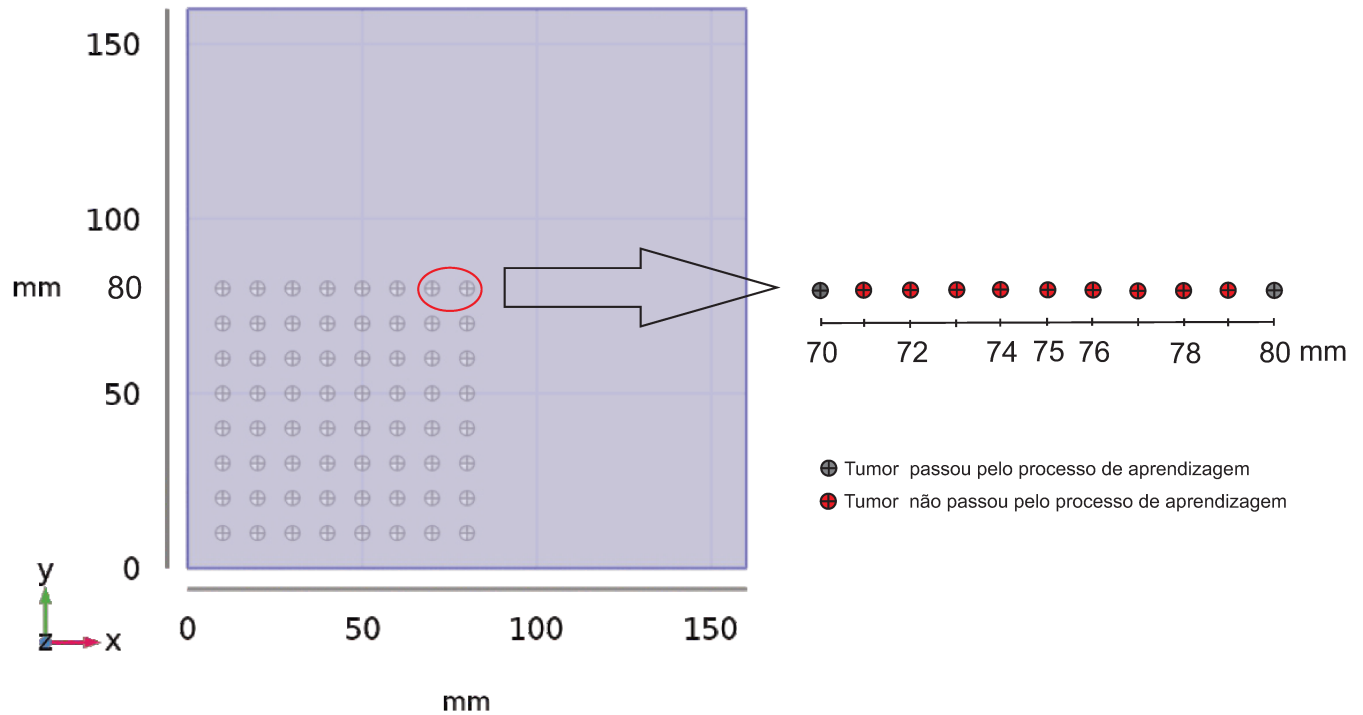
## 8.2 Problema Inverso

Variou-se o posicionamento do tumor em locais não conhecidos previamente pela rede neural, ou seja, criou-se imagens térmicas para novas fontes de calor metabólica cujas posições são diferentes das classes de tumores previamente conhecidas pela rede neural convolucional. Inicialmente analisou-se imagens térmicas simuladas com tumores posicionados entre fontes de calor metabólicas conhecidas pela rede neural, variou-se primeiramente o posicionamento dos mesmos em apenas uma coordenada da posição correta do tumor, em seguida variou-se duas coordenadas da posição dos tumores, está análise foi chamada de problema inverso.

### 8.2.1 Variação do posicionamento em uma coordenada

A Figura 8.8 mostra tumores simulados representados pela cor cinza, os quais passaram pelo processo de aprendizado na rede neural. Para verificar a capacidade de generalização da estimativa da localização do posicionamento dos mesmos, foram introduzidos vários tumores fictícios (cor vermelha), localizados em  $y = 80$  e entre as posições  $x = 70$  e  $x = 80$ . A análise também foi feita para a variação do posicionamento do tumor referente a profundidade  $z$ .

Figura 8.8: Variação em uma coordenada do posicionamento de tumores fictícios.



Fonte: Autoria própria.

## 8.2.2 Resultados

A Tabela 8.1 mostra os resultados da estimativa da posição de tumores localizados em  $y = 80$  e variou-se a posição no plano  $(x, z)$ , variou-se as coordenadas nas seguintes posições:  $x = 72, 74, 75, 76, 78$  mm e a profundidade  $z = 40, 50, 60, 65, 70, 75, 77$  mm. Observa-se que redes neurais convolucionais trabalha com classes de características, neste trabalho, essas são formadas pelas imagens térmicas da superfície da pele correlacionadas com o posicionamento de tumores na mama cartesiana, nota-se na Tab. 8.1 que a rede neural faz uma correlação da imagem térmica da posição nova com posições conhecidas previamente pela rede neural, isto de maneira lógica ela aproxima os tumores para posições mais próximas das conhecidas pela rede neural.

Com uso do otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios por camada, função de ativação relu, qualidade da imagem 512X512, resultou na Tab. 8.1. É possível observar que em quase todas análises a correlação foi feita de maneira lógica, para tumores localizados em  $x=72$  e  $x=74$  foi feita a correlação com a classe de tumor conhecida pela rede neural  $x=70$  e para quase todas valores de profundidades, as exceções são destacadas em vermelho na tabela. Tumores localizados em  $x=76$  e  $x=78$  foi feita a correlação com tumores posicionados em  $x=80$  para todas os valores de profundidade. Observa-se que tumores localizados na posição  $x = 75$ ,

ou seja entre duas fontes de calor metabólica conhecidas pela rede neural, a estimativa da localização foi em parte para posição  $x = 70$  e outra parte para  $x = 80$ , pois esse ponto encontra-se exatamente entre essas posições.

Tabela 8.1: Estimativa da Localização de tumores: variação do posicionamento em 1 coordenada, primeira configuração de hiperparâmetros.

$(x, y = 80)$	$x = 72$	$x = 74$	$x = 75$	$x = 76$	$x = 78$
$z = 40$	70	70	70	80	80
$z = 50$	70	70 ( $z=40$ )	80	80	80
$z = 60$	70	70	70	80	80
$z = 65$	70	70 ( $z=60$ )	80	80	80
$z = 70$	70	70	80	80	80
$z = 75$	70	70	70	80	80
$z = 77$	70	70	80	80	80

Uma segunda análise foi feita com o otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios, diferentemente usou-se a função de ativação lrelu e qualidade da imagem 128X128, o resultado é apresentado na Tab. 8.2. Nota-se que para esta análise usou-se imagens com pior qualidade porém usou-se uma função de ativação que gerou melhores resultados de precisão como visto no Cap. 7.3. Observa-se na Tab. 8.2 que reduziu-se o erro da profundidade dos tumores quando posicionados em  $x=74$  em relação a Tab. 8.1.

Tabela 8.2: Estimativa da Localização de tumores: variação do posicionamento em 1 coordenada, segunda configuração de hiperparâmetros.

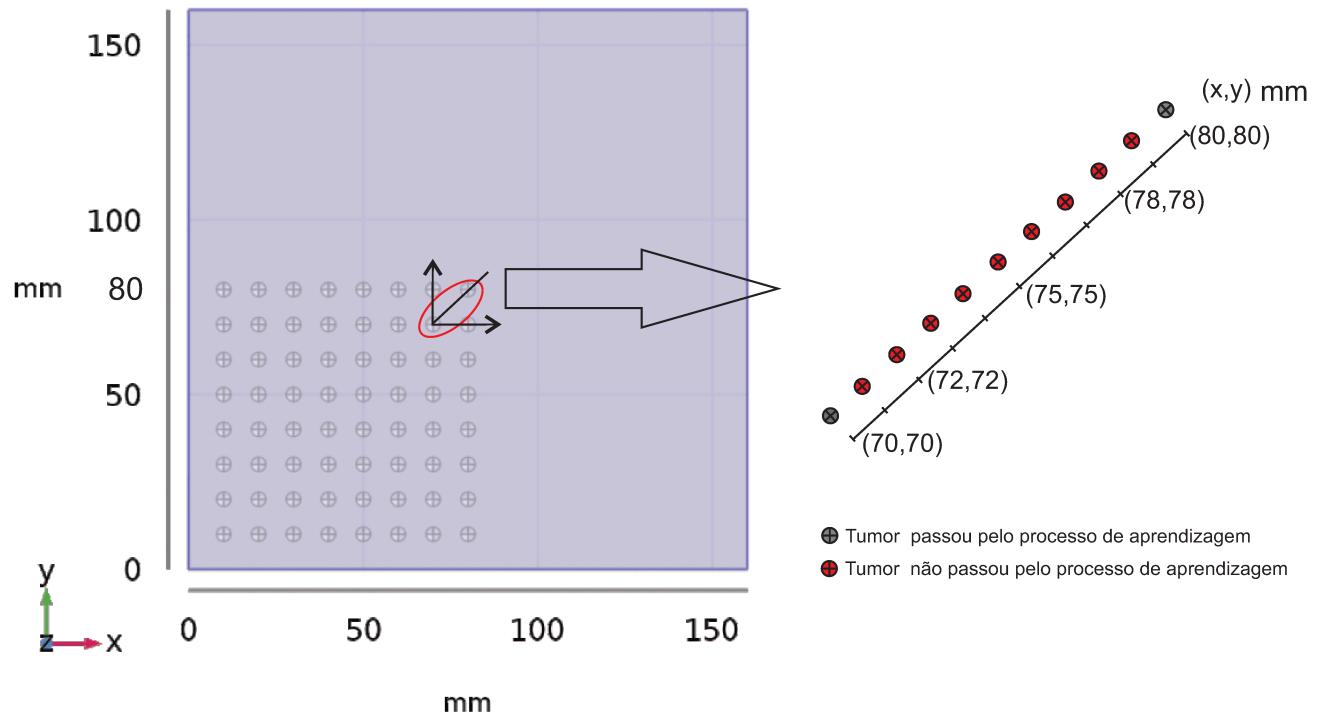
$(x, y = 80)$	$x = 72$	$x = 74$	$x = 75$	$x = 76$	$x = 78$
$z = 40$	70	70	70	80	80
$z = 50$	70	70 ( $z=40$ )	80	80	80
$z = 60$	70	80	80	80	80
$z = 65$	70	70	80	80	80
$z = 70$	70	70	70	80	80
$z = 75$	70	70	70	80	80
$z = 77$	70	70	80	80	80

### 8.2.3 Variação do posicionamento em duas coordenadas

A Figura 8.9 mostra tumores simulados representados pela cor cinza, os quais passaram pelo processo de aprendizado na rede neural. Para verificar a capacidade de estimativa da localização do posicionamento dos mesmos, foram introduzidos vários tumores fictícios (cor

vermelha), localizados entre  $y = 70$  e  $y = 80$  e entre as posições  $x = 70$  e  $x = 80$ . A análise também foi feita para todas as posições em  $z$ .

Figura 8.9: Variação em duas coordenadas do posicionamento de tumores fictícios.



Fonte: Autoria própria.

Com uso do otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios por camada, função de ativação relu, qualidade da imagem 512X512, o resultado da estimativa da localização pode ser vista na Tab. 8.3.

Tabela 8.3: Estimativa da Localização de tumores: variação em 2 coordenadas, primeira configuração de hiperparâmetros.

$(x, y)$	(72, 72)	(75, 75)	(78, 78)
$z = 40$	(70, 70)	(80, 80)	(80, 80)
$z = 50$	(70, 70)	(80, 70) $z=40$	(80, 80)
$z = 60$	(70, 70)	(80, 80) $z=65$	(80, 80)
$z = 65$	(70, 70)	(70, 70) $z=60$	(80, 80)
$z = 70$	(70, 70)	(70, 70) $z=65$	(80, 80)
$z = 75$	(70, 70)	(80, 80) $z=77$	(80, 80)
$z = 77$	(70, 70) ( $z=75$ )	(70, 70) $z=75$	(80, 80)

Observa-se pela Tab. 8.3, que a rede neural faz uma correlação da imagem térmica da

posição nova com posições conhecidas previamente pela rede neural, isso, de maneira lógica ela aproxima os tumores para posições mais próximas das conhecidas pela rede neural, nota-se na tabela que tumores posicionados entre duas posições conhecidas pela rede  $(x, y) = (70, 70)$  e  $(x, y) = (80, 80)$ , ou seja,  $(x, y) = (75, 75)$  na hora de estimar o posicionamento no plano x,y em quase todas posições alterou-se a profundidade, isso se deve pois aumentou-se o número de parâmetros variados.

Com uso do otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios por camada, função de ativação lrelu, qualidade da imagem 128X128, o resultado pode ser visto na Tab. 8.4. Observa-se que para está análise usou-se imagem com pior qualidade porém usou-se uma função de ativação que gerou melhores resultados de precisão como visto no Cap. 7.3. Nota-se na Tab. 8.4 que reduziu-se o erro em relação a profundidade nos tumores posicionados no centro entre os tumores conhecidos pela rede neural, os quais são mostrados em vermelho na tabela.

Tabela 8.4: Estimativa da Localização de tumores: variação em 2 coordenadas, segunda configuração de hiperparâmetros.


$(x, y)$	(72, 72)	(75, 75)	(78, 78)
$z = 40$	(70, 70)	(80, 70)	(80, 80)
$z = 50$	(70, 70) $z=60$	(80, 70) $z=40$	(80, 80)
$z = 60$	(70, 70)	(80, 80) $z=65$	(80, 80)
$z = 65$	(70, 70)	(70, 70) $z=60$	(80, 80)
$z = 70$	(70, 70)	(70, 80)	(80, 80)
$z = 75$	(70, 70)	(80, 80)	(80, 80)
$z = 77$	(70, 70)	(70, 80)	(80, 80)



### 8.3 Modelo Cartesiano - Análise em regime transiente

Criou-se um banco de dados da mama com geometria cartesiana de imagens termográficas simuladas em regime transiente. A Figura 8.10 mostra o modelo cartesiano, onde  $z = 0$  representa a superfície interna da mama com temperatura constante e  $z = 80$  mm é a superfície de aplicação do fluxo de calor, localizada na superfície da geometria analisada. O principal objetivo desta análise é de aumentar o banco de dados com imagens de temperatura simuladas.

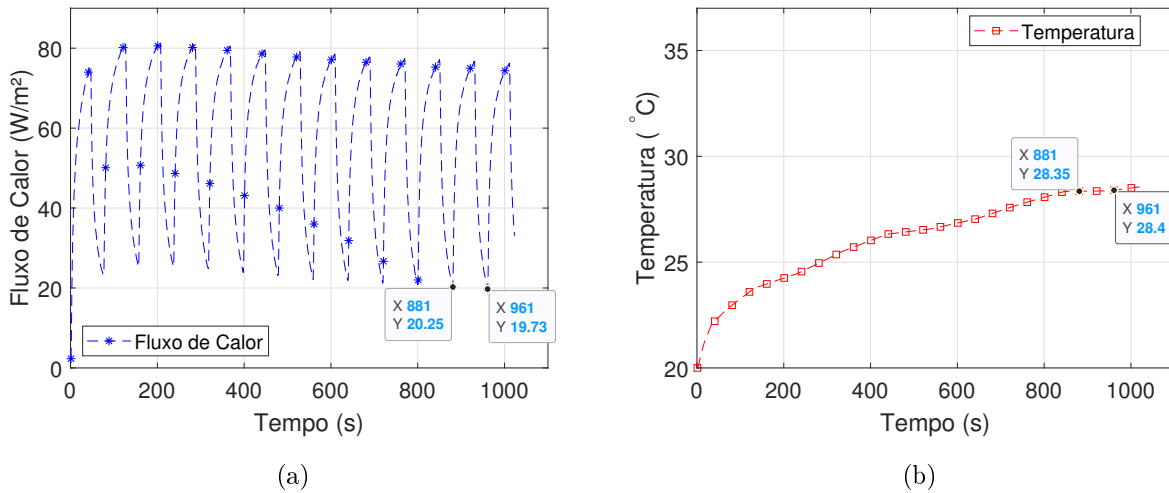
Figura 8.10: Superfície de aplicação do fluxo de calor.



Fonte: Autoria própria.

As Figuras 8.11 (a) e (b), mostram, respectivamente, o fluxo de calor periódico aplicado na superfície da mama e a variação da temperatura de um ponto localizado no centro e na superfície da mesma. Note que aplicou-se um fluxo de calor de pequena intensidade, em referência a uma possível situação real, na qual se o mesmo fosse aplicado na superfície da pele humana, não poderia gerar desconforto para o paciente. Nesse caso, através de simulação computacional, observou-se que um fluxo de calor periódico com oscilações entre 20 a 80 W/m<sup>2</sup>, ( Fig.8.11 (a)) alteraria muito pouco a temperatura da superfície da mama, conforme Fig.8.11 (b). Observa-se também nas Figs. 8.11 (a) e (b) que o banco de dados foi criado para o intervalo de tempo  $881 \leq t \leq 961$  segundos, região cuja temperatura superficial é praticamente constante.

Figura 8.11: Mama cartesiana em regime transiente: (a) fluxo de calor imposto na superfície da mama; (b) temperatura de um ponto localizado na superfície e no centro da mama, ou seja,  $(x, y, z) = (80, 80, 80)$ .



Fonte: Autoria própria.

As mesmas análises anteriores (regime permanente) foram feitas, só que neste caso, usou-se um banco de dados em regime transiente. Nesta análise realizou-se a variação do posicionamento do tumor em uma coordenada conforme Fig.8.8 e variação do posicionamento do tumor em duas coordenadas Fig.8.9. Aqui também usou-se o otimizador Nadam, modelo com 4 camadas ocultas e 512 neurônios por camada, função de ativação lrelu, qualidade da imagem 128X128.

Para estimativa da localização de tumores com variação do posicionamento em uma (1) coordenada, observa-se na Tab.8.5 que os resultados melhoraram consideravelmente em relação a análise feita em regime permanente e neste caso não gerou erro relativo ao posicionamento dos tumores em relação a profundidade.

Tabela 8.5: Estimativa da Localização de tumores: variação do posicionamento em uma (1) coordenada, segunda configuração de hiperparâmetros.

$(x, y = 80)$	$x = 72$	$x = 74$	$x = 75$	$x = 76$	$x = 78$
$z = 40$	70	70	70	80	80
$z = 50$	70	70	70	80	80
$z = 60$	70	70	70	80	80
$z = 65$	70	70	80	80	80
$z = 70$	70	70	80	80	80
$z = 75$	70	70	80	80	80
$z = 77$	70	70	80	80	80

Quando variou-se o posicionamento dos tumores em duas coordenadas, o resultado pode ser visto na Tab. 8.6. Nessa análise, é possível notar que não teve erro em relação a profundidade (na análise permanente havia erro) nos tumores posicionados no centro entre os tumores conhecidos pela rede neural.

Tabela 8.6: Estimativa da Localização de tumores: variação em 2 coordenadas, segunda configuração de hiperparâmetros.

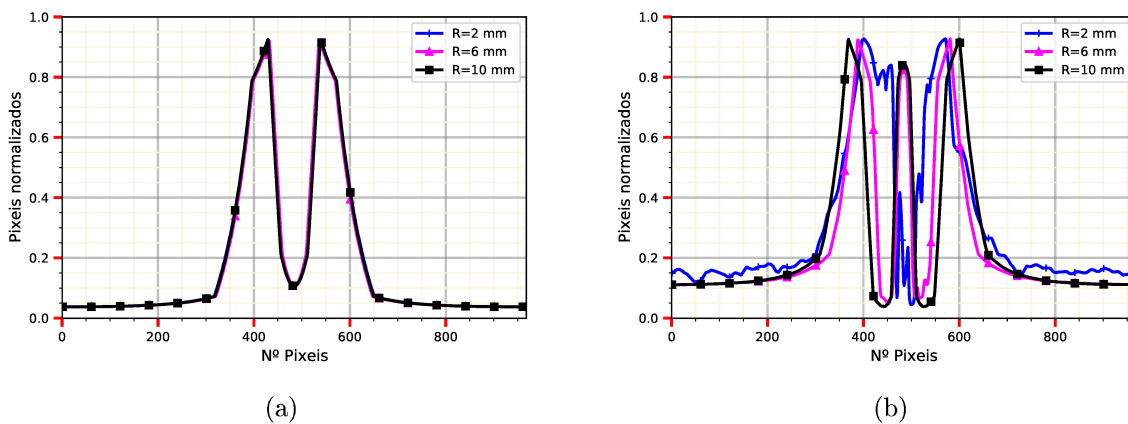
$(x, y)$	(72, 72)	(75, 75)	(78, 78)
$z = 40$	(70, 70)	(80, 70)	(80, 80)
$z = 50$	(70, 70)	(80, 70)	(80, 80)
$z = 60$	(70, 70)	(80, 80)	(80, 80)
$z = 65$	(70, 70)	(70, 70)	(80, 80)
$z = 70$	(70, 70)	(80, 80)	(80, 80)
$z = 75$	(70, 70)	(80, 80)	(80, 80)
$z = 77$	(70, 70)	(80, 80)	(80, 80)

## 8.4 Mama Cartesiana - Impedância Térmica

Nas seções anteriores usaram-se imagens de temperatura da superfície da mama tanto em regime permanente quanto em regime transiente, respectivamente. O objetivo dessa análise foi de estimar a localização de uma fonte de calor metabólica no interior do modelo. Observa-se que, as curvas dos pixels das imagens de temperatura possuem pouca sensibilidade em relação a variação do tamanho do raio e mesmo com a modificação do mesmo, as curvas terminam praticamente sobrepostas.

Como foi apresentado no capítulo 6 pôde-se observar que a imagem da impedância térmica da superfície da mama cartesiana possui grande sensibilidade em relação a variação do tamanho da fonte de calor metabólica. Esse efeito também pode ser visto na Fig.8.12 (b) na qual observa-se que quanto maior o tamanho do raio, mais aberta é a curva para os pixels de maiores valores e quanto menor o raio mais fechada é a mesma. Nesta seção, propõe-se o uso da impedância térmica da imagem para estimar além da posição do tumor, o seu tamanho.

Figura 8.12: Influência do tamanho do tumor no perfil de: (a) Temperatura; (b) Impedância.




Fonte: Autoria própria.

Foi criado um banco de dados para a mama cartesiana com tumores esféricos com raios de  $R_1 = 2$  mm,  $R_2 = 6$  mm e  $R_3 = 10$  mm, localizados a  $z = 70$  mm, ou seja, o centro dos tumores estão localizados a 10 mm da superfície da mama, como pode ser observado na Fig.8.13. Aqui também, para criação do banco de dados, considerou-se como condições de contorno: a temperatura interna constante de  $T_c = 37$  °C, a superfície superior submetida a convecção térmica e temperatura ambiente variáveis de maneira aleatória em uma faixa controlada, e as paredes laterais foram consideradas isoladas. Como condição inicial considerou-se  $T_o = 20$  °C. As propriedades termofísicas da mama foram baseadas nos valores apresentados no Capítulo 4.

Para verificar a capacidade das imagens da impedância térmica da superfície da mama em estimar o tamanho da fonte de calor metabólica, considerou-se tumores esféricos com raios:

$R_1 = 2 \text{ mm}$ ,  $R_2 = 6 \text{ mm}$  e  $R_3 = 10 \text{ mm}$ .


Figura 8.13: Variação do tamanho da inclusão: (a) vista lateral; (b) vista superior.



Fonte: Autoria própria.

Neste estudo, também usou-se o otimizador Nadam, modelo com 4 camadas ocultas e 32 neurônios por camada, função de ativação lrelu, qualidade da imagem 256X256, inicialização da matrizes de bias e pesos, foram, respectivamente, *zeros* e *glorot uniform*. A Figura 8.14 apresenta a convergência da rede neural com imagens de temperatura da superfície da mama. Observa-se que o modelo em redes neurais convolucionais usado encontra uma certa dificuldade em realizar a convergência do mesmo, visto que, os pixels das imagens de temperatura possuem baixa sensibilidade em relação a variação do tamanho da fonte de calor metabólica. Além disso, observa-se na Fig.8.14 (a) que a curva de precisão do modelo possui grande instabilidade gerando grandes oscilações nos valores de precisão.


Figura 8.14: Convergência da rede neural com a imagem de temperatura da superfície da mama: (a) Precisão ; (b) Função erro.



Fonte: Autoria própria.

A Figura 8.15 apresenta a convergência da rede neural com a imagem da impedância térmica da superfície da mama. Nessa análise também foi feita para o mesmo número de épocas do modelo de temperatura. Observa-se na Fig.8.15 (a) que o modelo converge para o número de épocas 100, também é possível observar uma curva mais estável com menos oscilações nos valores de precisão. Já na Fig.8.15 (b) nota-se que o valor da função erro tende a zero nos valores de convergência da rede neural.

Figura 8.15: Convergência da rede neural com a imagem da impedância térmica da superfície da mama: (a) Precisão ; (b) Função erro.



Fonte: Autoria própria.

A Tab.8.7 mostra a estimativa da localização de tumores com variação do posicionamento em uma (1) coordenada e a variação do tamanho do tumor. Observa-se que aqui é possível estimar o tamanho do mesmo, visto que, as imagens de impedância térmica são sensíveis a variação do tamanho da fonte de calor metabólica. Também observa-se que os resultados melhoraram consideravelmente em relação a análise feita em relação a imagens de temperatura e neste caso obteve-se um pequeno erro do posicionamento dos tumores.

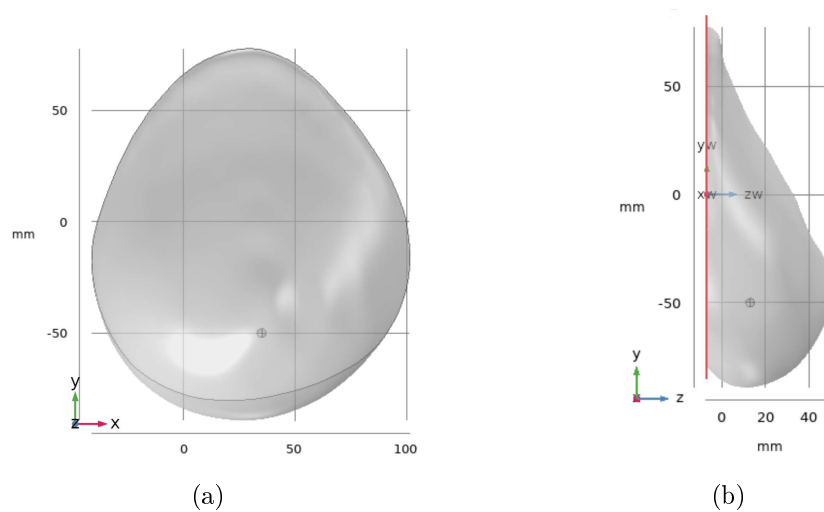
Tabela 8.7: Estimativa da Localização de tumores: variação do posicionamento em 1 coordenada, segunda configuração de hiperparâmetros.

$(x, y, z)$	(72, 80, 70)	(74, 80, 70)	(75, 80, 70)	(76, 80, 70)	(78, 80, 70)
$R_1 = 2 \text{ mm}$	(70, 80, 70)	(70, 80, 70)	(70, 80, 70)	(70, 80, 70)	(80, 80, 70)
$R_2 = 6 \text{ mm}$	(70, 80, 70)	(80, 80, 70)	(80, 80, 70)	(80, 80, 70)	(80, 80, 70)
$R_3 = 10 \text{ mm}$	(70, 80, 70)	(70, 80, 70)	(70, 80, 70)	(80, 80, 70)	(80, 80, 70)

## 8.5 Mama Anatômica - Análise em regime permanente


O modelo tridimensional escaneado da mama também foi simulado numericamente no software *COMSOL Multiphysics*. A geometria da mesma pode ser observado na Fig.8.16 (a) e (b), que mostram, respectivamente, a vista frontal e lateral da mama. A mama anatômica possui dimensões: largura de 144 mm, altura de 160 mm e espessura de 58,4 mm. As Figuras 8.17 (a) e (b) apresentam, respectivamente a malha e mama simulada sem tumor, respectivamente.

Figura 8.16: Mama Real: (a) Vista frontal; (b) Vista lateral; (c) vista inferior.



Fonte: Autoria própria.

Figura 8.17: Mama Real: (a) Malha; (b) mama sem tumor (baseline).



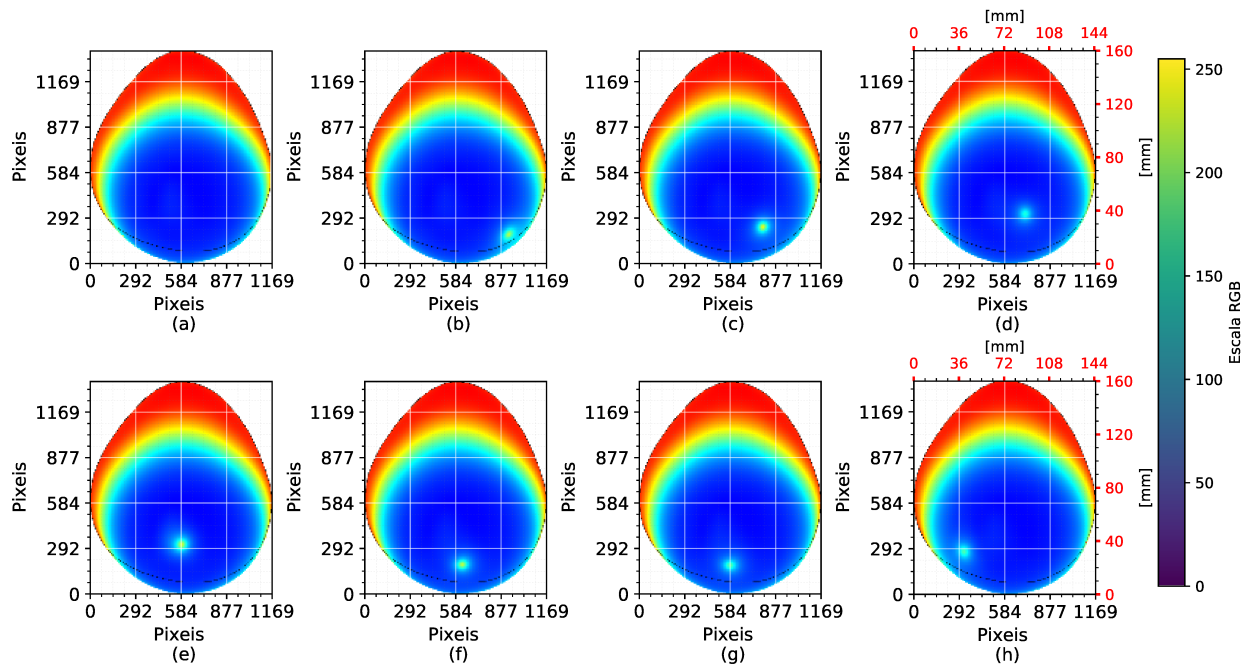
Fonte: Autoria própria.

Aqui também, para criação do banco de dados, considerou-se como condições de contorno: a temperatura interna constante de  $T_c = 37\text{ }^\circ\text{C}$ , a superfície da mama submetida a convecção



térmica e temperatura ambiente variáveis de maneira aleatória em uma faixa controlada. Como condição inicial considerou-se  $T_o = 20\text{ }^\circ\text{C}$ . As propriedades termo-físicas da mama foram baseadas nos valores apresentados no Capítulo 4. A Figura 8.18 mostra algumas das imagens de temperatura superficiais da mama com formato anatômico com inclusões inseridas em diferentes posições. Para essa análise, o banco de dados é constituído de 140 imagens.

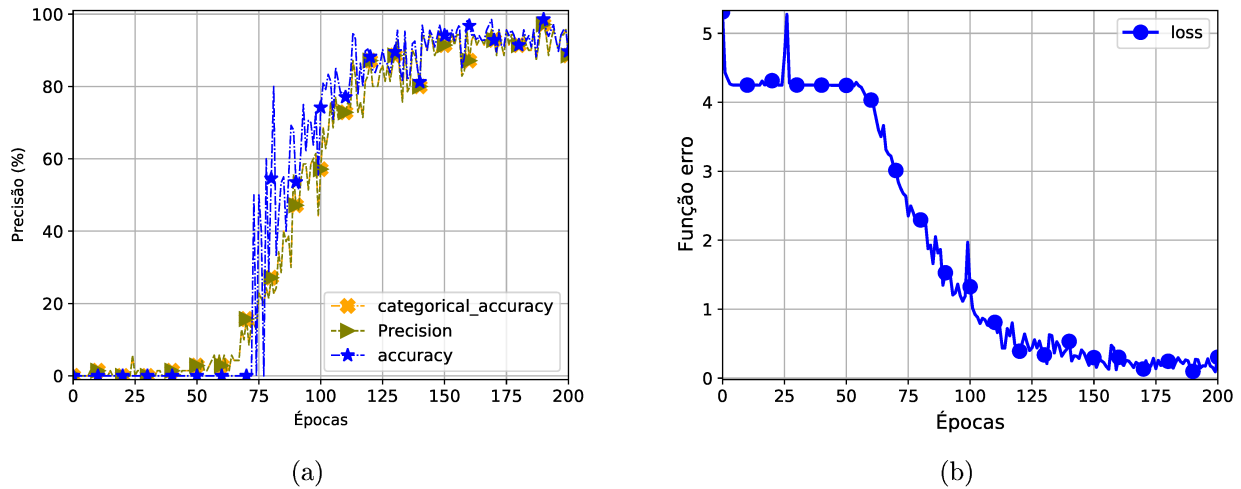
Figura 8.18: Banco de dados da mama anatômica.



Fonte: Autoria própria.

A Figura 8.19 apresenta a convergência da rede neural relativo a termografia superficial da mama com formato anatômico. Observa-se na Fig.8.15 (a) que o modelo converge para o número de épocas 175. Também é possível observar uma curva com menos oscilações nos valores de precisão. Já na Fig.8.15 (b) nota-se que o valor da função erro também tende a zero nos valores de convergência da rede neural.

Figura 8.19: Convergência da rede neural da termografia da superfície da mama real: (a) Precisão ; (b) Função erro.



Fonte: Autoria própria.

A Tab.8.8 mostra a estimativa da localização de tumores com variação do posicionamento no espaço, ou seja, variou-se o mesmo nos eixos  $x,y,z$  na mama de formato anatômico.

Tabela 8.8: Estimativa da Localização de tumores na mama real.

$(x, y, z)$	(10, -44, 41)	(43, -60, 42)	(12, -59, 39)	(57, -60, 30)	(-8, -64, 27)
$R_1 = 2 \text{ mm}$	(15, -44, 42)	(45, -60, 42)	(10, -60, 40)	(60, -65, 31)	(-10, -65, 27)

Observa-se que na Tab.8.8 a primeira linha apresentada em cor cinza são tumores que foram simulados e não passaram pela rede neural, já os resultados na segunda linha (linha em branco) representam a estimativa da localização dos tumores, em posicionamentos já conhecidos previamente pela rede neural, nota-se, aqui também o programa estimou o posicionamento para posições, de forma lógica, para localizações mais próximas de tumores já conhecidos pelo banco de dados.

# Capítulo 9

## Conclusão

Nesse projeto, propôs-se o desenvolvimento de técnicas baseadas em inteligência artificial para a estimativa da localização e do tamanho de tumores mamários.

Redes neurais foram construídas a partir de dados simulados do campo de temperatura presente nas mamas devido ao efeito da perfusão e do metabolismo. A técnica proposta foi desenvolvida com o objetivo de ser aplicada em pacientes com ou sem tumor a partir de medições de temperatura e fluxos térmicos obtidos da superfície da mama.

A metodologia para localização de tumores usando imagem térmicas, passa por etapas como a criação do banco de dados, escolha dos parâmetros detectáveis em imagens termográficas, bibliotecas de *deep learning*, treinamento da rede com uso de redes neurais convolucionais, análise dos hiperparâmetros usados no modelo para convergência e e solução do problema direto e inverso.

Verificou-se a influência das propriedades e parâmetros termofísicos nos perfis de pixels das imagens termográficas simuladas na superfície da pele da mama. Fez-se uma análise da influência dos principais hiperparâmetros usados para construção do modelo em *deep learning*.

Inicialmente, as redes neurais com aprendizado profundo foram desenvolvidas e aplicadas apenas em imagens térmicas correspondentes as temperaturas superficiais das mamas cujos dados de temperatura foram simuladas. Ou seja, resolveu-se a equação de Pennes para várias condições físicas com diversos tamanhos, localizações e posições dos tumores.

Modelos geométricos cartesianos e um modelo anatômico de uma mama usadas para treinamento de estudantes de medicina foram analisados.

A técnica desenvolvida foi capaz da estimativa da localização de vários tumores simulados, o que por si já representa uma excelente contribuição. Todavia, as imagens de temperatura não apresentaram sensibilidade boa o suficiente para que se encontra-se o tamanho dos respectivos tumores.

Com o objetivo de se obter além da localização, o tamanho do tumor, propôs-se o uso das

redes neurais a partir de dados de impedância térmica.

Desenvolveram-se assim, modelos térmicos para a obtenção da impedância superficial da mama, através da obtenção do fluxo de calor imposto e da respectiva temperatura superficial de cada nó na malha numérica. O nó representaria um determinado ponto onde se mediria a temperatura e o fluxo de calor superficial em uma mama real, usando-se para isto, sensores de temperatura e fluxo de calor superficiais.

Novamente os dados foram aplicados em dois modelos térmicos: modelo cartesiano e modelo anatômico escaneado.

Resultados apresentaram uma significativa sensibilidade das redes, permitindo a identificação da localização e do tamanho dos tumores simulados. Esses resultados foram apresentados para o modelo cartesiano.

O desenvolvimento da técnica que possibilitou a identificação da localização e tamanho de tumores na mama a partir de informações de temperatura e fluxo de calor superficiais é uma ferramenta inédita e promissora na detecção precoce do câncer de mama.

Além da técnica proposta não ser invasiva ou causar dor à paciente, ela permite o acesso a pessoas com deficiência ou baixa mobilidade e possui um baixo custo estimado.

A baixa sensibilidade aos tumores pequenos e profundos, normalmente existente em análises de temperaturas superficiais usando imagens térmicas foi contornada com o uso do conceito de impedância térmica e técnicas de inteligência artificial, como o uso de aprendizado profundo (Deep learning).

## 9.1 Propostas de trabalhos futuros

Desenvolveu-se neste trabalho a concepção teórica de uma técnica que usa impedância térmica e inteligência artificial para a identificação de tumores mamários. O próximo passo, seria a aplicação em dados experimentais de laboratório e a posterior aplicação em pacientes. Para isso algumas etapas necessitam ainda serem executadas. São elas:

1. Desenvolvimento de uma bancada experimental com um modelo anatômico. A bancada deve prever a geração de calor de uma inclusão com várias posições e tamanhos. Deve prever também sensores de fluxo de calor e temperaturas superficiais. O modelo deve ter suas propriedades térmicas bem definidas.

2. Criação de um banco de dados experimental de temperatura e fluxo de calor.

3. Uso da transformada de Hilbert nos sinais de temperatura superficiais e comparação com resultados de impedância térmica.

4. Análise e comparação de aquecimento e resfriamento para estabelecer qual a melhor excitação térmica dinâmica para o problema considerando a Impedância térmica ou a transformada de Hilbert.

## 5. Projeto e comparação de várias estruturas de IA.

# Referências Bibliográficas

- AGNELLI, J.; BARREA, A.; TURNER, C. Tumor location and parameter estimation by thermography. *Mathematical and Computer Modelling*, v. 53, n. 7, p. 1527 – 1534, 2011. ISSN 0895-7177. Mathematical Methods and Modelling of Biophysical Phenomena. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0895717710001937>.
- Arel, I.; Rose, D. C.; Karnowski, T. P. Deep machine learning - a new frontier in artificial intelligence research [research frontier]. *IEEE Computational Intelligence Magazine*, v. 5, n. 4, p. 13–18, Nov 2010. ISSN 1556-603X.
- ARORA, N.; MARTINS, D.; RUGGERIO, D.; TOUSIMIS, E.; SWISTEL, A. J.; OSBORNE, M. P.; SIMMONS, R. M. Effectiveness of a noninvasive digital infrared thermal imaging system in the detection of breast cancer. *The American Journal of Surgery*, Elsevier, v. 196, n. 4, p. 523–526, 2008.
- BENGIO; YOSHUA. Learning deep architectures for ai. *Foundations and trends® in Machine Learning*, Now Publishers, Inc., v. 2, n. 1, p. 1–127, 2009.
- BRIOSCHI, M.; TEIXEIRA, M.; SILVA, F.; COLMAN, D. Medical thermography textbook: principles and applications. *Editora e Livraria Andreoli*, 2010.
- BROWNLEE, J. *How to Reduce Generalization Error With Activity Regularization in Keras*: Machine learning mastery: Making developers awesome at machine learning. 2020. Disponível em: <https://machinelearningmastery.com/how-to-reduce-generalization-error-in-deep-neural-networks-with-activity-regularization-in-keras/>.
- BYUN, A.; XU, D.; KRISHNA, R. *Convolutional Neural Networks (CNNs/ConvNets)*: Course website: Cs321n convolutional neural networks for visual recognition. 2020. Disponível em: <https://cs231n.github.io/convolutional-networks/#pool>. Acesso em: 10-12-2020.
- CLEVERT, D.-A.; UNTERTHINER, T.; HOCHREITER, S. *Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)*. 2016.
- DAS, K.; MISHRA, S. C. Simultaneous estimation of size, radial and angular locations of a malignant tumor in a 3-d human breast—a numerical study. *Journal of thermal biology*, Elsevier, v. 52, p. 147–156, 2015.
- DUCHI, J.; HAZAN, E.; SINGER, Y. Adaptive subgradient methods for online learning and stochastic optimization. *J. Mach. Learn. Res.*, JMLR.org, v. 12, n. null, p. 2121–2159, jul. 2011. ISSN 1532-4435.

FIGUEIREDO, A. A. A. *Uso de Correlações de Temperaturas superficiais e Qualificação da Técnica de Imagens Infravermelhas para a Detecção e Localização de Tumores de Mama*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2018.

FIGUEIREDO, A. A. A.; FERNANDES, H. C.; GUIMARAES, G. Experimental approach for breast cancer center estimation using infrared thermography. *Infrared Physics & Technology*, Elsevier, v. 95, p. 100–112, 2018.

FINOCCHIO, M. A. F. *Noções de Redes Neurais Artificiais*: Apostila do curso de engenharia elétrica da universidade tecnológica federal do paraná. 2014. Disponível em: <<http://paginapessoal.utfpr.edu.br/mafinocchio/labsi-laboratorio-de-seguranca-e-iluminacao/redes-neurais-artificiais/NOCaO%20DE%20REDES%20NEURAIIS%20ARTIFICIAIS.pdf/view>>. Acesso em: 13-09-2020.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In: TEH, Y. W.; TITTERINGTON, M. (Ed.). *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*. Chia Laguna Resort, Sardinia, Italy: JMLR Workshop and Conference Proceedings, 2010. (Proceedings of Machine Learning Research, v. 9), p. 249–256. Disponível em: <<http://proceedings.mlr.press/v9/glorot10a.html>>.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In: TEH, Y. W.; TITTERINGTON, M. (Ed.). *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*. Chia Laguna Resort, Sardinia, Italy: JMLR Workshop and Conference Proceedings, 2010. (Proceedings of Machine Learning Research, v. 9), p. 249–256. Disponível em: <<http://proceedings.mlr.press/v9/glorot10a.html>>.

GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: GORDON, G.; DUNSON, D.; DUDÍK, M. (Ed.). *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*. Fort Lauderdale, FL, USA: JMLR Workshop and Conference Proceedings, 2011. (Proceedings of Machine Learning Research, v. 15), p. 315–323. Disponível em: <<http://proceedings.mlr.press/v15/glorot11a.html>>.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.

HINTON G.; SRIVASTAVA N., S. K. *Neural Networks for Machine Learning*: Lecture 6e rmsprop: Divide the gradient by a running average of its recent magnitude. 2012. Disponível em: <<https://paperswithcode.com/method/rmsprop>>.

HOSSAIN, S.; MOHAMMADI, F. A. Tumor parameter estimation considering the body geometry by thermography. *Computers in Biology and Medicine*, v. 76, p. 80 – 93, 2016. ISSN 0010-4825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010482516301688>>.

KAPOOR, P.; PRASAD, S. Image processing for early diagnosis of breast cancer using infrared images. In: IEEE. *2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE)*. [S.l.], 2010. v. 3, p. 564–566.

KINGMA, D. P.; BA, J. *Adam: A Method for Stochastic Optimization*: International conference on learning representations, pages 1-13. 2015.

KLAMBAUER, G.; UNTERTHINER, T.; MAYR, A.; HOCHREITER, S. *Self-Normalizing Neural Networks*. 2017.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436, 2015. Disponível em: <<https://doi.org/10.1038/nature14539>>.

MENEGAZ, G. L.; GUIMARÃES, G. Development of a new technique for breast tumor detection based on thermal impedance and a damage metric. *Infrared Physics & Technology*, Elsevier, v. 97, p. 401–410, 2019.

MENEGAZ, G. L.; TSURUTA, K. M.; NETO, R. M. F.; JR, V. S.; ARAUJO, C. A.; GUIMARÃES, G. Use of the electromechanical impedance method in the detection of inclusions: application to mammary tumors. *Structural Health Monitoring*, SAGE Publications Sage UK: London, England, p. 1475921718825138, 2019.

MITRA, S.; BALAJI, C. A neural network based estimation of tumour parameters from a breast thermogram. *International Journal of Heat and Mass Transfer*, Elsevier, v. 53, n. 21-22, p. 4714–4727, 2010.

NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: *Icml*. [S.l.: s.n.], 2010.

PARISKY, Y.; SARDI, A.; HAMM, R.; HUGHES, K.; ESSERMAN, L.; RUST, S.; CALLAHAN, K. Efficacy of computerized infrared imaging analysis to evaluate mammographically suspicious lesions. *American Journal of Roentgenology*, Am Roentgen Ray Soc, v. 180, n. 1, p. 263–269, 2003.

PATEL, J. L.; GOYAL, R. K. Applications of artificial neural networks in medical science. *Current clinical pharmacology*, Bentham Science Publishers, v. 2, n. 3, p. 217–226, 2007.

PHIL, K. *Matlab deep learning with machine learning, neural networks and artificial intelligence*. Apress, 2017.

ROHRER, B. *How to Convert a Picture to Numbers*: Part of course 137 signal processing techniques. 2019. Disponível em: <[https://e2eml.school/images\\_to\\_numbers.html](https://e2eml.school/images_to_numbers.html)>.

ROSENBLATT, F. *The perceptron, a perceiving and recognizing automaton Project Para*. [S.l.]: Cornell Aeronautical Laboratory, 1957.

RUDER, S. *An overview of gradient descent optimization algorithms*. 2016. Cite arxiv:1609.04747Comment: Added derivations of AdaMax and Nadam. Disponível em: <<http://arxiv.org/abs/1609.04747>>.

SABA, L.; BISWAS, M.; KUPPILI, V.; GODIA, E. C.; SURI, H. S.; EDLA, D. R.; OMERZU, T.; LAIRD, J. R.; KHANNA, N. N.; MAVROGENI, S.; PROTOGEROU, A.; SFIKAKIS, P. P.; VISWANATHAN, V.; KITAS, G. D.; NICOLAIDES, A.; GUPTA, A.; SURI, J. S. The present and future of deep learning in radiology. *European Journal of Radiology*, v. 114, p. 14



– 24, 2019. ISSN 0720-048X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0720048X19300919>>.

SANDERS, J.; KANDROT, E. *CUDA by example: an introduction to general-purpose GPU programming*. [S.l.]: Addison-Wesley Professional, 2010.

SAXE, A. M.; MCCLELLAND, J. L.; GANGULI, S. Exact solutions to the nonlinear dynamics of learning in deep linear neural networks. *arXiv preprint arXiv:1312.6120*, 2013.

SAXE, A. M.; MCCLELLAND, J. L.; GANGULI, S. *Exact solutions to the nonlinear dynamics of learning in deep linear neural networks*. 2014.

SEWAK, M.; KARIM, M. R.; PUJARI, P. *Practical Convolutional Neural Networks: Implement Advanced Deep Learning Models Using Python*. [S.l.]: Packt Publishing Ltd, 2018.

SHANMUGAMANI, R. *Deep Learning for Computer Vision: Expert techniques to train advanced neural networks using TensorFlow and Keras*. [S.l.]: Packt Publishing Ltd, 2018.

SREE, S. V.; NG, E. Y.-K.; U, R. A.; TAN, W. Breast imaging systems: a review and comparative study. *Journal of Mechanics in Medicine and Biology*, World Scientific, v. 10, n. 01, p. 5–34, 2010.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, JMLR.org, v. 15, n. 1, p. 1929–1958, jan. 2014. ISSN 1532-4435. Disponível em: <<https://dl.acm.org/doi/10.5555/2627435.2670313>>.

TOMPSON, J.; GOROSHIN, R.; JAIN, A.; LECUN, Y.; BREGLER, C. Efficient object localization using convolutional networks. *CoRR*, abs/1411.4280, 2014. Disponível em: <<http://arxiv.org/abs/1411.4280>>.

TUOMANEN, B. *Hands-On GPU Programming with Python and CUDA: Explore high-performance parallel computing with CUDA*. [S.l.]: Packt Publishing Ltd, 2018.

VICTORIA, A. H.; MARAGATHAM, G. Automatic tuning of hyperparameters using bayesian optimization. *Evolving Systems*, Springer, p. 1–7, 2020.

WANG, Z.-L.; ADACHI, Y. Property prediction and properties-to-microstructure inverse analysis of steels by a machine-learning approach. *Materials Science and Engineering: A*, v. 744, p. 661 – 670, 2019. ISSN 0921-5093. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0921509318317283>>.

WASON, R. Deep learning: Evolution and expansion. *Cognitive Systems Research*, v. 52, p. 701 – 708, 2018. ISSN 1389-0417. Disponível em: <<https://doi.org/10.1016/j.cogsys.2018.08.023>>.

XU, B.; WANG, N.; CHEN, T.; LI, M. *Empirical Evaluation of Rectified Activations in Convolutional Network*. 2015.

ZEILER, M. D. *ADADELTA: An Adaptive Learning Rate Method*. 2012.