

**UNIVERSIDADE NOVE DE JULHO – UNINOVE  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO  
CONHECIMENTO**

**EDWARD NETZER**

**ABORDAGEM COMPUTACIONAL DE ESTIMATIVA DE TEMPERATURA POR  
IMAGENS TÉRMICAS PARA USO EM NEONATOLOGIA**

São Paulo

2023

**EDWARD NETZER**

**ABORDAGEM COMPUTACIONAL DE ESTIMATIVA DE TEMPERATURA POR  
IMAGENS TÉRMICAS PARA USO EM NEONATOLOGIA**

Dissertação apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento da Universidade Nove de Julho – UNINOVE, como requisito parcial para obtenção do grau de Mestre em Informática e Gestão do Conhecimento.

Prof. Peterson Adriano Belan, Dr. - Orientador

São Paulo

2023

Netzer, Edward.

Abordagem computacional de estimativa de temperatura por imagens térmicas para uso em neonatologia. / Edward Netzer. 2023. 105 f.

Dissertação (Mestrado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2023.

Orientador (a): Prof. Dr. Peterson Adriano Bel.

1. Visão computacional. 2. Redes neurais. 3. Infravermelho. 4. Temperatura de pele. 5. Temperatura corporal. 6. Termografia. 8. Recém-nascido

I. Bel, Peterson Adriano. II. Título.

CDU 004

**ATA DE DEFESA DA DISSERTAÇÃO**

Ao vigésimo sexto dia do mês de junho de dois mil e vinte e três, às 15h30, do programa de Pós-Graduação, desta Universidade, reuniu-se em sessão pública a Comissão Julgadora da dissertação de Mestrado de Edward Netzer sob o título "ABORDAGEM COMPUTACIONAL DE ESTIMATIVA DE TEMPERATURA POR IMAGENS TÉRMICAS PARA USO EM NEONATOLOGIA".

Integraram a comissão os professores: Prof. Dr. Peterson Adriano Belan (UNINOVE), o Prof. Dr. Alessandro Pereira da Silva (UMC), e o Prof. Dr. Cleber Gustavo Dias sob a presidência do primeiro, orientador da dissertação. A banca examinadora, tendo decidido aceitar a dissertação, passou à arguição pública do candidato. Encerrados os trabalhos, os examinadores deram parecer final sobre a dissertação.



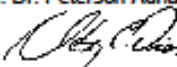

	Parecer
Prof. Dr. Peterson Adriano Belan	Aprovado
Prof. Dr. Alessandro Pereira da Silva	Aprovado
Prof. Dr. Cleber Gustavo Dias	Aprovado

**Parecer:**

Aluno aprovado.

Em conclusão, o candidato foi considerado Aprovado, no grau de Mestre em Informática e Gestão do Conhecimento. E, para constar, eu, Prof. Dr. André Felipe Henriques Librantz, diretor do Programa de Mestrado e Doutorado em Informática e Gestão do Conhecimento, lavrei a presente ata que assino juntamente com os membros da banca examinadora.

São Paulo, 26 de junho de 2023.

 _____ Prof. Dr. Peterson Adriano Belan	 _____ Prof. Dr. Alessandro Pereira da Silva
 _____ Prof. Dr. Cleber Gustavo Dias	 _____ Prof. Dr. André Felipe Henriques Librantz

Assinado de forma digital por Alessandro Pereira da Silva  
Dados: 2023.06.26 17:29:46 -03'00'

Dedico este trabalho à minha amada esposa, que tem sido minha fonte de inspiração e apoio ao longo dessa jornada.

## **AGRADECIMENTOS**

Gostaria de agradecer a Deus, que sempre nos orienta no momento em que mais precisamos.

Ao Professor Dr. Peterson Adriano Belan, meu orientador, sou imensamente grato por sua orientação. Sua experiência e apoio foram fundamentais para o meu crescimento acadêmico. Agradeço por sua dedicação em me auxiliar a alcançar meus objetivos.

Ao Professor Dr. Sidnei Alves de Araújo, agradeço por compartilhar seu vasto conhecimento em algoritmos de visão computacional. Suas aulas foram verdadeiramente enriquecedoras. Sou grato por suas contribuições para a minha formação.

Ao Professor Dr. Cleber Gustavo Dias, expresso minha gratidão pelos conhecimentos compartilhados sobre lógica fuzzy. Suas aulas foram inspiradoras e despertaram meu interesse nesse campo fascinante.

À minha esposa Lúcia, aos meus pais Edna e Arthur, meus irmãos e familiares, por todo incentivo que vocês me proporcionaram para conseguir manter foco e dedicação frente às iniciativas.

Agradeço à Universidade Nove de Julho e aos professores do PPGI pelo ambiente propício à pesquisa científica e pelo excepcional trabalho em prol da ciência no Brasil.

Por fim, expresso meu profundo agradecimento ao Sr. Djalma Luiz Rodrigues, cuja vasta expertise em neonatologia e sua contribuição significativa para o desenvolvimento dessa área no Brasil, especialmente no uso de tecnologia, foram inestimáveis.

## RESUMO

Berços aquecidos por calor radiante são equipamentos que auxiliam na termorregulação de recém-nascidos em unidades de tratamento intensivo, produzindo calor necessário e medindo a temperatura por meio de sensores de contato direto com a pele do paciente. Entretanto, o monitoramento preciso da temperatura destes pacientes críticos trazem desafios por conta da necessidade de fixação dos sensores na pele do recém-nascido, assim como o deslocamento destes sensores e fios condutores durante a movimentação do paciente. O estudo apresenta uma abordagem computacional para medir a temperatura de recém-nascidos de maneira não-invasiva e sem contato com a pele do paciente utilizando imagem térmica infravermelha. A abordagem faz o uso de visão computacional para análise e tratamento de imagens térmicas, possibilitando a extração de valores numéricos de temperatura usando conhecimento adquirido por meio do estudo da escala de pseudo-cores da câmera infravermelha. Também são aplicados algoritmos de correção de variações de medida características da câmera utilizada no estudo incluindo o uso de redes neurais artificiais. A abordagem proposta possibilitou medições mais precisas proporcionando redução no erro de medida de mais de 2°C para um erro médio de 0,1°C com erro máximo de 0,7°C. Espera-se que os resultados deste trabalho contribuam para a melhoria dos cuidados neonatais sugerindo uma técnica para se medir a temperatura de maneira não invasiva, dispensando o uso de sensores de contato físico com o paciente para o monitoramento de Recém-Nascidos posicionados em berços aquecidos por calor radiante.

**Palavras-chave:** Visão Computacional, Redes Neurais, Infravermelho, Temperatura de pele, Temperatura Corporal, Termografia, Recém-nascido.

## ABSTRACT

Infant radiant heat warmers are devices that assist in the thermoregulation of newborns in intensive care units, providing the necessary warmth and measuring the patient temperature through sensors in direct contact with the patient's skin. However, precise monitoring of the temperature of these critical patients poses challenges due to the need for sensor attachment to the newborn's skin, as well as the displacement of these sensors and wires during patient movement. This study presents a computational approach to non-invasively and contactlessly measure the temperature of newborns using infrared thermal imaging. The approach employs computer vision for analysis and processing of thermal images, enabling the extraction of numerical temperature values using knowledge acquired from studying the pseudo-color scale of the infrared camera. Correction algorithms are also applied to address measurement variations inherent to the camera used in the study, including artificial neural networks. The proposed approach allowed for more accurate measurements, reducing error from over 2°C to an average error of 0.1°C with a maximum error of 0.7°C. It is expected that the results of this work will contribute to the improvement of neonatal care by suggesting a technique for non-invasive temperature measurement, eliminating the need for physical contact sensors with the patient skin for monitoring newborns positioned in radiant heat warmers.

**Keywords:** Computer Vision, Neural Networks, Infrared, Skin Temperature, Cutaneous Temperature, Body Temperature, Thermography, Newborn

## LISTA DE ILUSTRAÇÕES

Figura 1 - Termograma por Sir John Herschel em 1840.....	13
Figura 2 - Portal da CAPES – palavras-chave “infrared” e “skin temperature” .....	17
Figura 3 - Portal da CAPES – inclusão de palavra-chave “algorithm” nos filtro de busca.....	18
Figura 4 - Portal da CAPES – inclusão de palavras-chave.....	18
Figura 5 - Tipos de termistores em monitoramento clínico.....	27
Figura 6 - Comparação entre comprimentos de onda diferentes.....	28
Figura 7 - Espectro de ondas eletromagnéticas .....	29
Figura 8 - Componentes de um sistema de processamento de imagens .....	34
Figura 9 - Etapas de um sistema de processamento de imagens .....	35
Figura 10 - Matriz de pixels de uma imagem digital .....	36
Figura 11 - Efeito da redução na resolução espacial.....	37
Figura 12- Diferentes profundidades de imagem (b=3, b=2 e b=1) .....	38
Figura 13 - Modelos de cores (a) aditivo; (b) subtrativo.....	40
Figura 14 - Modelo RGB e espaço de cores representado por um cubo .....	41
Figura 15 - Diagrama do espaço de cores CIELAB .....	41
Figura 16 - Modelos não lineares de um neurônio .....	46
Figura 17 - Influência do bias na saída do combinador linear e campo local induzido .....	47
Figura 18 - Outro modelo não-linear de um neurônio.....	48
Figura 19 - Grafo de representação de um neurônio artificial .....	48
Figura 20 - Grafo de representação de uma rede neural.....	49
Figura 21 - Funções de ativação Limiar, Linear por partes e Sigmóide.....	50
Figura 22 - Arquitetura de um percéptron de múltiplas camadas com duas camadas ocultas.....	52
Figura 23 - Percéptron de múltiplas camadas - Fluxos dos sinais funcionais e sinais de erro .....	52
Figura 24 - Câmera térmica Minipa modelo MTV-2010.....	55
Figura 25 - Termômetro de referência utilizado no estudo.....	56
Figura 26 - Diagrama da metodologia proposta .....	57
Figura 27 - Exemplo da imagem .BMP capturada .....	60
Figura 28 - Normalização dos níveis de cinza para as bandas RGB da imagem .BMP .....	61
Figura 29 - Interface da câmera – paleta “cores metálicas” .....	62
Figura 30 - Escala em cores e separada por níveis de cinza das bandas RGB.....	62
Figura 31 - Níveis de cinza para as bandas RGB da escala em cores.....	63
Figura 32 - Imagem de teste para posicionamento de cursor e coleta de valores RGB .....	64
Figura 33 - Distribuição de níveis de cinza para cada banda RGB (escala de 31°C a 40°C).....	66
Figura 34 - Escala considerando mesmos coeficientes angulares para RGB .....	69
Figura 35 - Gráfico dos níveis de RGB com escala térmica variável.....	70
Figura 36 - Temperatura em função dos níveis de cinza RGB.....	73
Figura 37 - Diagrama em blocos e fluxograma – Controle de temperatura do corpo negro.....	75
Figura 38 - Fluxograma para a conversão do valor RGB do pixel em °C .....	76
Figura 39 - Temperatura das amostras de imagens.....	78
Figura 40 - Erro de medida de temperatura das amostras de imagens.....	78
Figura 41 - Exemplo de uma imagem com as ROIs selecionadas.....	80
Figura 42 - Imagens térmicas de Crianças (3a10m e 1m23d) .....	84
Figura 43 - Imagem térmica de corpos negros sobre o leito de berço aquecido .....	84
Figura 44 - Faces de pessoas - erro de medida de temperatura aumenta com o tempo.....	86
Figura 45 - Tendência de aumento de erro da câmera térmica.....	86

Figura 46 - Diferença de temperatura indicada (câmara térmica e termômetro de referência) .....	87
Figura 47 - Imagens térmicas – temperaturas corrigidas com base no corpo negro.....	88
Figura 48 - Imagens térmicas de bebê – temperaturas corrigidas com base no corpo negro .....	89
Figura 49 - Medidas de temperatura (com correção, referência e sem correção).....	90
Figura 50 - Valor real × Predição da RNA de 4 entradas .....	91
Figura 51 - Erro de predição da temperatura pela RNA.....	92
Figura 52 - Valor real × Predição da RNA de 7 entradas .....	93
Figura 53 - Erro de predição da temperatura pela RNA.....	93
Figura 54 - Valor real × Predição da RNA com 10 entradas .....	94
Figura 55 - Erro de predição da temperatura pela RNA.....	95
Figura 56 - Valor real × Predição da RNA com 10 entradas com função GridSearch.....	96
Figura 57 - Erro de predição da temperatura pela RNA.....	96

## LISTA DE TABELAS

Tabela 1 - Trabalhos associados com medição de temperatura por termografia .....	21
Tabela 2 - Especificações da câmera térmica utilizada no estudo .....	55
Tabela 3 - Especificações do termômetro de referência .....	56
Tabela 4 - Propriedades da imagem BMP da câmera Térmica .....	60
Tabela 5 - Tabela de Regras para cálculo da temperatura.....	74
Tabela 6 - Modelo da estrutura da base de dados.....	81
Tabela 7 - Teste com corpos negros em berço aquecido.....	85
Tabela 8 - Erro entre temperatura de referência e temperatura medida pela câmera térmica .....	87
Tabela 9 - Resultado da correção a partir da temperatura do corpo negro.....	88
Tabela 10 - Resultado da correção a partir da temperatura do corpo negro.....	89

## LISTA DE ABREVIATURA E SÍMBOLO

a*	Crominância vermelho-verde
b*	Crominância amarelo-azul
Bin_B	Binarização da banda B
Bin_G	Binarização da banda G
Bin_R	Binarização da banda R
Bit	Unidade binária (Binary unit)
BMP	Mapa de Bits (Bitmap)
CIE	Comissão Internacional de Iluminação
CIELab*	Luminância e Crominância determinado pela CIE
IR	Infravermelho
L*	Luminância
LCD	Display de Cristal Líquido
LWIR	IR de ondas longas
MWIR	IR de ondas médias
n <sub>B</sub>	Nível de cinza da banda B
n <sub>G</sub>	Nível de cinza da banda G
NIR	IR próximo
n <sub>R</sub>	Nível de cinza da banda R
nRGB	Nível de cinza de RGB
NTC	Coeficiente negativo de temperatura
RDT	Resistor Dependente de Temperatura
RGB	Vermelho Verde Azul
RN	Recém-Nascido
RNA	Rede Neural Artificial
ROI	Região de Interesse
SWIR	IR de ondas curtas
T1	Sensor de Temperatura 1
T2	Sensor de Temperatura 2
t <sub>BL</sub>	Temperatura calculada pela banda B do primeiro intervalo
t <sub>BH</sub>	Temperatura calculada pela banda B do último intervalo
temp	Temperatura
t <sub>G</sub>	Temperatura calculada pela banda G
t <sub>máx</sub>	Limite superior da escala térmica
t <sub>min</sub>	Limite inferior da escala térmica
t <sub>R</sub>	temperatura calculada pela banda R
UTI	Unidade de Tratamento Intensivo
VLSI	Integração de Escala Muito Alta
VLWIR	IR de ondas muito longas

## SUMÁRIO

1 INTRODUÇÃO .....	12
1.1 CONTEXTUALIZAÇÃO E CONSIDERAÇÕES INICIAIS .....	12
1.2 REVISÃO DE LITERATURA .....	14
1.3 JUSTIFICATIVA, LACUNAS E QUESTÃO DE PESQUISA .....	17
1.3.1 REVISÃO BIBLIOMÉTRICA .....	17
1.3.2 JUSTIFICATIVA DA PESQUISA.....	19
1.3.3 LACUNAS DE PESQUISA E PERGUNTA DE PESQUISA .....	20
1.4 OBJETIVOS.....	23
1.4.1 OBJETIVO GERAL.....	23
1.4.2 OBJETIVOS ESPECÍFICOS.....	23
1.5 LIMITAÇÃO DO TEMA .....	24
1.6 MÉTODOS E TÉCNICAS DE PESQUISA .....	24
1.7 ORGANIZAÇÃO DA DISSERTAÇÃO .....	24
2. FUNDAMENTAÇÃO TEÓRICA.....	25
2.1 TERMORREGULAÇÃO NEONATAL.....	25
2.1.1 BERÇOS AQUECIDOS POR CALOR RADIANTE .....	26
2.1.2 SENSORES DE TEMPERATURA T1 E T2 .....	26
2.2 RADIAÇÃO ELETROMAGNÉTICA INFRAVERMELHA .....	28
2.2.1 ESPECTRO ELETROMAGNÉTICO .....	28
2.2.2 EMISSIVIDADE E CORPO NEGRO.....	30
2.2.3 RADIAÇÃO INFRAVERMELHA E EMISSIVIDADE DA PELE HUMANA ..	30
2.3 PROCESSAMENTO DE IMAGEM TÉRMICA.....	32
2.3.1 TERMOGRAFIA POR INFRAVERMELHO .....	32
2.3.2 PROCESSAMENTO DE IMAGENS.....	33
2.3.3 IMAGEM DIGITAL MONOCROMÁTICA.....	36
2.3.4 IMAGEM DIGITAL MULTIBANDA OU MULTIESPECTRAL .....	38
2.3.5 MODELOS E ESPAÇOS DE CORES.....	39
2.3.6 ESPAÇO DE CORES RGB .....	40
2.3.7 ESPAÇO DE CORES CIE Lab* E TONS DE PELE.....	41
2.4 REDES NEURAIS ARTIFICIAIS .....	42
2.4.1 PROPRIEDADES DAS REDES NEURAIS.....	43
2.4.2 MODELOS DE UM NEURÔNIO ARTIFICIAL.....	45
2.4.3 FUNÇÕES DE ATIVAÇÃO DE UM NEURÔNIO.....	49
2.4.4 PROCESSOS DE APRENDIZAGEM.....	50

2.4.5 PERCÉPTRON DE MÚLTIPLAS CAMADAS .....	51
2.4.6 ALGORITMO DE RETROPROPAGAÇÃO .....	53
3. MATERIAIS E MÉTODOS.....	55
3.1 EQUIPAMENTOS .....	55
3.2 METODOLOGIA PROPOSTA.....	57
3.3 PROPRIEDADES DA IMAGEM .....	59
3.3.1 ARQUIVOS REGISTRADOS PELA CÂMERA .....	59
3.3.2 PALETA DE CORES DA IMAGEM TÉRMICA .....	61
3.4 EXTRAÇÃO DE TEMPERATURA DA IMAGEM.....	65
3.4.1 FUNÇÕES DE TEMPERATURA POR PSEUDO-CORES.....	65
3.4.2 FUNÇÕES DE TEMPERATURA COM ESCALA VARIÁVEL .....	70
3.4.3 TEMPERATURA EM FUNÇÃO DA COMPOSIÇÃO RGB DO PIXEL.....	73
3.5 CORPO AQUECIDO COM TEMPERATURA CONTROLADA.....	74
3.6 DETERMINAÇÃO DE TEMPERATURA POR PSEUDO-CORES.....	76
3.7 BANCO DE IMAGENS.....	77
3.8 CORREÇÃO DE MEDIDA DE TEMPERATURA POR REDE NEURAL .....	79
4. RESULTADOS E DISCUSSÃO.....	83
4.1 ALGORITMO DE PSEUDO-CORES.....	83
4.1.1 TESTES INICIAIS EXPLORATÓRIOS .....	83
4.1.2 MEDIDAS EM BERÇO AQUECIDO .....	84
4.1.3 ERRO DE MEDIDA DE TEMPERATURA.....	85
4.1.4 CORREÇÃO DE ERRO DE <i>OFFSET</i> .....	88
4.1 CORREÇÃO DA MEDIDA DE TEMPERATURA POR REDES NEURAI.....	91
4.1.1 REDE NEURAL COM 4 ENTRADAS.....	91
4.1.2 REDE NEURAL COM 7 ENTRADAS.....	93
4.1.3 REDE NEURAL COM 10 ENTRADAS.....	94
4.1.4 REDE NEURAL COM FUNÇÃO GRIDSEARCH .....	96
5. CONCLUSÕES .....	98
Referências .....	100

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO E CONSIDERAÇÕES INICIAIS

Bebês Recém-Nascidos (RNs) podem apresentar dificuldade em manter sua temperatura corporal, principalmente quando são pré-termos, ou seja, nascidos antes de completar 37 semanas de gestação (SEGRE et al., 2015, p. 653 e p. 640; OMS, 2020, p. 31). Incubadoras e berços aquecidos por calor radiante são equipamentos comumente usados em unidades de tratamento intensivo (UTIs) de neonatologia para auxiliar no tratamento destes bebês (ABBAS, A. K. et al., 2012, p. 85).

Além de proporcionar controle térmico seguro, esses equipamentos também monitoram a temperatura do RN por meio de sensores com fios que são firmemente fixados na pele do bebê (ABBAS, A. K. et al., 2012, p. 85).


Em geral, o sistema de monitoramento de temperatura deve ser seguro e não deve interferir com outros equipamentos vitais necessários para o atendimento ao paciente. Além disso, deve ser o menos invasivo possível para evitar qualquer estresse ao RN (ABBAS, A. K. et al., 2012, p. 102).

A temperatura está diretamente atrelada à emissão de radiação infravermelha. Qualquer corpo físico que apresenta uma determinada temperatura, tem a característica de emitir ondas eletromagnéticas em uma faixa de frequência classificada como radiação infravermelha (ABBAS, A. K. et al., 2012, p. 95).

A maior parte transferência de calor do corpo humano acontece por meio da radiação infravermelha, cuja existência física foi identificada 1800, quando Sir William Herschel realizou um experimento para medir o calor além do espectro de luz visível. (RING, 2006, p.3).

Posteriormente, seu filho, John Herschel realizou experimentos usando radiação solar focalizada com uma lente suspensa sobre partículas de carbono e álcool, o que resultou na formação de uma imagem que foi por ele denominada Termografia. Atualmente, este tipo de radiação pode ser visualizado por meio de imagens térmicas eletrônicas (RING, 2006, p.4).

Figura 1 - Termograma por Sir John Herschel em 1840



Fonte: (RING, 2006, p. 4).

Lloyd Williams (1964) apresentou termografia infravermelha como ferramenta para pesquisa na área médica por meio de um sistema de escaneamento térmico para medição da temperatura. Posteriormente, Watmough & Oliver (1969) apresentaram possíveis efeitos na medida da emissividade (valor característico para emissão de radiação) da pele e na detecção de pontos quentes aplicados na termografia clínica.

Mais adiante, Steketee (1973), indicou um valor constante de  $0,98 \pm 0,01$  como sendo o valor da emissividade da pele humana, independentemente do comprimento de onda. Clark & Stothers (1980) e Hanssler & Breukmann (1992) apresentaram o uso de termografia para medir a temperatura de recém-nascidos.

Posteriormente, mais pesquisas foram feitas. Christidis et. al. (2003) investigaram a temperatura da superfície da pele de recém-nascidos na primeira hora após o parto. Abbas et. al. (2011) apresentaram a possibilidade de monitorar a frequência respiratória do RN com base na análise do perfil de temperatura da narina anterior associada às fases de inspiração e expiração sucessivamente.

Abbas & Leonhardt (2014) apresentaram uma proposta de detecção de temperatura do RN. Knobel et. al. (2017) apresentaram a viabilidade de capturar a temperatura do RN dentro de uma incubadora utilizando uma câmera infravermelha.

Já nos últimos anos, técnicas de visão computacional tem contribuído com estudos envolvendo termografia. Lozano (2019) apresentou um método de segmentação da região da testa. Em seguida, Negishi et. al. (2020) e Yang et. al. (2022) apresentaram propostas com abordagens computacionais para monitoramento de sinais vitais utilizando termografia.

Embora os últimos anos apresentem trabalhos que abordem termografia e métodos computacionais, mais estudos destas áreas de conhecimento voltadas para a neonatologia precisam ser desenvolvidos para viabilizar uma forma de se medir a temperatura dos RNs sem estabelecer contato com a pele.

## 1.2 REVISÃO DE LITERATURA

ABBAS *et. al.* (2011) descreveu o monitoramento da respiração espontânea do recém-nascido com base na análise do perfil de temperatura na região das narinas associado às fases de inspiração e expiração, usando imagens de termografia infravermelha em uma incubadora. Pelo conhecimento dos autores, esta é foi a primeira vez que a análise do sinal de respiração por termografia infravermelha foi aplicada para monitorar recém-nascidos. De acordo com os autores, tanto o dispositivo de imagem IR quanto o próprio método ainda enfrentavam problemas de desvio devido à variação na temperatura de fundo (outras fontes de calor no ambiente), demandando melhorias no processamento de imagem e detecção de limites da região nasal separada do restante do cenário de imagem (por exemplo, parede interna da incubadora, colchão e outras regiões faciais).

Knobel *et. al.* (2017) fizeram o uso da termografia infravermelha para medir a temperatura de recém-nascidos prematuros. O estudo demonstrou que foi possível capturar a temperatura corporal de bebês em uma incubadora por meio de uma câmera infravermelha FLIR SC640. Apesar de os resultados apresentarem diferença de temperatura de  $\pm 2^{\circ}\text{C}$  entre o valor medido pelo sensor de pele e o valor medido pela imagem térmica, o benefício do trabalho está associado à identificação de variação de fluxo sanguíneo por meio da termografia em bebês prematuros.

BERKSOY *et. al.* (2018) realizaram medidas de temperatura a partir da radiação infravermelha na região da face e testa de crianças em sala de triagem. Apesar de fazer medida por infravermelho, o estudo contempla o uso de termômetro infravermelho e não utiliza termografia.

A partir de 2019 foram encontrados estudos que utilizam termografia combinada com visão computacional e outras técnicas de inteligência artificial para estimar sinais vitais como frequência respiratória ou temperatura do corpo humano.

Ornek *et. al.* (2019) utilizaram termografia infravermelha para identificar o estado de saúde de bebês recém-nascidos. Os autores indicam que, segundo Knobel *et. al.* (2011), doenças e infecções causam mudanças térmicas nas regiões afetadas da pele, resultando em assimetria térmica na superfície da pele do paciente. Este foi o primeiro estudo a aplicar Termografia Infravermelha e Redes Neurais Convolucionais para detectar o estado de saúde de neonatos (Ornek *et. al.*, 2019, p.1.).

Lozano *et. al.* (2019) apresentaram um método para segmentar a região da testa, possibilitando extrair a média de temperatura desta área. O método desenvolvido é relevante porque é capaz de fazer a segmentação de forma invariante à posição da face mesmo com a presença de objetos externos.

Ammer & Ring (2019) apresentaram um guia para uso da termografia incluindo desenvolvimento de sistemas de imagem, aplicações médicas e na área biológica.

Negishi *et. al.* (2020) apresentaram um sistema de medição de sinais vitais para teste de triagem clínica em pacientes com gripe. Apesar de não focar em pacientes recém-nascidos, o trabalho apresenta a medição de frequência cardíaca, frequência respiratória e temperatura corporal utilizando processamento de imagens térmicas e imagens RGB. Dentre as duas versões desenvolvidas, a segunda executa a medição da frequência respiratória e temperatura corporal a partir da termografia. A proposta para temperatura apresentou erro de medida entre  $-0,45^{\circ}\text{C}$  e  $2,56^{\circ}\text{C}$  em relação ao medidor de referência. Foi possível fazer a triagem dos pacientes porque, além do sistema considerar outros sinais vitais, as médias das temperaturas faciais de pacientes gripados e pacientes saudáveis foram de  $37,3^{\circ}\text{C}$  e  $35,5^{\circ}\text{C}$ , respectivamente.

Rassels & French (2021) propuseram uma técnica para medir a temperatura corporal dos recém-nascidos em uma incubadora a partir de termo imagem, isolando e eliminando fatores externos indesejados e realizando a medição contínua de uma região de interesse. Durante o experimento, os autores destacaram que, para compensar o erro de offset da medida pela imagem térmica, foi necessário incluir uma medida de temperatura adicional feita por meio de um sensor de PT100 preso a um corpo negro, em alumínio, posicionado no ambiente próximo ao paciente (região das portinholas da incubadora).

JADDOA *et. al.* (2021) utilizaram visão computacional para localizar a região dos olhos de bovinos para a medida de temperatura por meio de termografia. Apesar de não apresentar aplicação em neonatologia, o trabalho considera a região dos olhos como sendo a melhor região para a medida de temperatura por infravermelho.

Wang *et. al.* (2021) estruturaram um sistema para medir temperatura de bovinos utilizando termografia infravermelha (IRT), anemômetro e um medidor de umidade para compensar fatores ambientais (velocidade do vento, temperatura ambiente e umidade). De forma semelhante ao que foi argumentado anteriormente, apesar de não apresentar aplicação em neonatologia, o trabalho indica que fatores ambientais podem interferir na medição da temperatura por infravermelho.

Com o objetivo semelhante ao trabalho de Negishi *et. al.* (2020), Yang *et. al.* (2022), apresentaram um sistema que utiliza algoritmos de visão computacional em imagens térmicas de pessoas adultas (24 e 35 anos de idade) para a medição de temperatura corporal na região da testa e frequência respiratória na região inferior das vias respiratórias. Também foi proposta a medida de frequência cardíaca, buscando a região da testa a partir de imagem RGB. O trabalho faz uso de técnicas de visão computacional para o tratamento das imagens e redes neurais convolucionais para detecção da face e identificação das regiões de interesse. O Trabalho não apresentou dados detalhados do erro de medida da temperatura, mas informaram que os valores medidos mostram apenas uma diferença sutil de menos de 0,5°C em comparação com termómetro portátil de testa.


### 1.3 JUSTIFICATIVA, LACUNAS E QUESTÃO DE PESQUISA

#### 1.3.1 REVISÃO BIBLIOMÉTRICA

A busca de artigos sobre o tema com as palavras chave “*infrared*” e “*skin temperature*” retornou um total de 2209 artigos publicados desde os primeiros estudos iniciados na década de 80 até os dias atuais.

A figura 2 apresenta a evolução na quantidade de publicações do portal da CAPES que contemplam as palavras chave “*infrared*” e “*skin temperature*”. É possível notar que a quantidade de publicações dobra a cada década. Também é possível notar que as publicações dos últimos 3 anos ultrapassaram a metade da quantidade de publicações da última década.

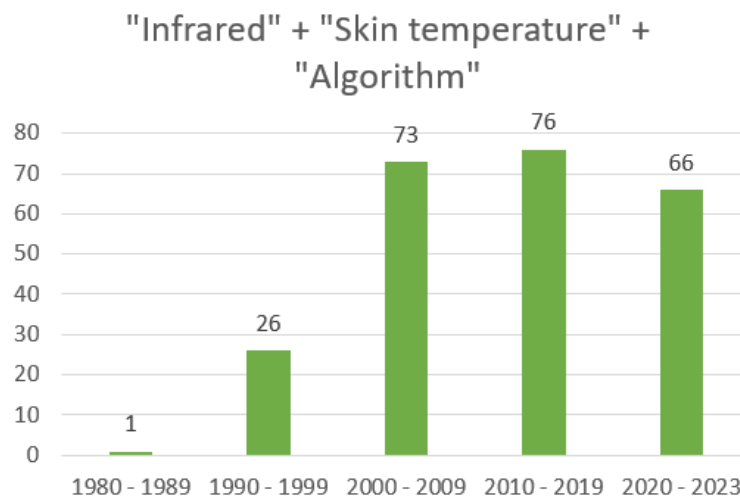
Figura 2 - Portal da CAPES – palavras-chave “*infrared*” e “*skin temperature*”



Fonte: Autor

Em seguida, a figura 3 mostra resultados depois de incluir a palavra-chave “*algorithm*” nos filtros de busca. Os gráficos apresentados mostram uma grande concentração de publicações nos últimos 20 anos

Figura 3 - Portal da CAPES – inclusão de palavra-chave “algorithm” nos filtro de busca




Fonte: Autor

A inclusão da palavra “*algorithm*” reduziu a quantidade de publicações para 242. Apesar de certa estabilidade nas publicações das duas últimas décadas com 73 e 76 publicações respectivamente, os três últimos anos já foram suficientes para chegar próximo a esta quantidade de publicações

A figura 4 apresenta o gráfico das publicações que combinam as palavras-chave “*infrared*” e “*skin temperature*” com “*artificial intelligence*” e “*computer vision*”, com 22 e 10 publicações, respectivamente.

Figura 4 - Portal da CAPES – inclusão de palavras-chave



Fonte: Autor

Apesar da quantidade reduzida de artigos por conta da inclusão das palavras chave “*computer vision*” e “*artificial intelligence*”, é possível notar crescimento significativo nas publicações sobre o tema. Existe grande concentração de publicações nos últimos 3 anos em comparação com os 20 anos anteriores.

### 1.3.2 JUSTIFICATIVA DA PESQUISA

Atualmente, os profissionais de UTI de neonatologia enfrentam desafios pragmáticos quanto à fixação e monitoramento do sensor de temperatura na fina pele do RN. Além da preocupação com o posicionamento dos fios sobre o corpo RN, que geralmente são fixados na região abdominal ou na região axilar, estes componentes também demandam cuidado no manuseio, operação, manutenção, limpeza e desinfecção do produto (SOLLAI *et al.*, 2016, p. 1, JOSEPH *et al.*, 2017, p. 116).

O posicionamento correto do sensor é fundamental para garantir a precisão da medida de temperatura e a segurança do paciente. Na aplicação com recém-nascidos, a escolha do sensor pode ser limitada pelas condições físicas do paciente. Um exemplo disso é a escolha de uso de um sensor retal, que, além de ser invasivo e desconfortável, pode apresentar riscos de lesão intestinal (SEGRE *et al.*, 2015, p. 643) (ABBAS, A. K. *et al.*, 2012, p. 85) (JOSEPH *et al.*, 2017, p. 114).

Outro aspecto importante a considerar é que o monitoramento da temperatura incorreto ou impreciso pode trazer riscos adicionais e desconforto ao RN, sendo importante reconhecer a importância da experiência e habilidade do profissional na execução desta atividade (ANTINK *et al.*, 2020, p. 3049-3050).

Outros fatores, como a movimentação ou agitação do recém-nascido, também podem afetar o contato térmico dos sensores de pele com o corpo, comprometendo a precisão da medida da temperatura (ABBAS, A. K. *et al.*, 2012, p. 100-102). Nesse sentido, Antink (2020) acrescenta que, além do desconforto ao RN, sensores em contato com a pele implicam no risco de lesões como “lesões de pele relacionadas a adesivos médicos” (*medical adhesive-related skin injuries – MARS*), o que é um sério problema para pacientes prematuros com pele frágil e vulnerável.

Além dos desafios e riscos associados aos sensores convencionais, existe também a limitação de medir a temperatura em apenas um ponto específico, o que pode afetar a precisão da medida de temperatura devido a possíveis alterações no fluxo de sangue quente na região de contato (ABBAS, A. K. et al., 2012, p. 100).

Dessa forma, diante da criticidade desses desafios e riscos associados aos sensores de temperatura, a combinação de visão computacional e técnicas de inteligência artificial com a termografia surge como uma alternativa promissora. Por meio da imagem térmica, é possível, realizar a medida da temperatura em várias regiões ao longo do corpo, apresentando o gradiente de temperatura entre a região central e os membros, o que pode auxiliar em muitos diagnósticos médicos (ABBAS, A. K. et al., 2012, p. 101).

Ao adotar essa abordagem para o monitoramento de temperatura em neonatologia e considerar os riscos associados ao uso de sensores de contato, espera-se fornecer subsídios que contribuam para uma solução segura e não invasiva para a medida da temperatura dos Recém-Nascidos.

### 1.3.3 LACUNAS DE PESQUISA E PERGUNTA DE PESQUISA

O primeiro estudo sobre Termografia Infravermelha neonatal foi realizado por Clark e Stothers em 1980, que observaram a distribuição da temperatura na pele de recém-nascidos com imagens térmicas e termopares. Apesar dos estudos com infravermelho e temperatura de pele terem início a mais de 40 anos com resultados promissores, não houve nenhum grande estudo prospectivo nesta área que examine seus benefícios e barreiras na sua aplicação prática (ORNEK *et. al.*, 2019, p.2.) (TOPALIDOU *et. al.*, 2019, p.3).

Topalidou *et. al.* (2019), com o objetivo de examinar a utilidade potencial do uso de imagens térmicas em cuidados neonatais, realizou uma pesquisa bibliográfica para identificar estudos até 2017. A pesquisa foi executada em bases de dados internacionais como EMBASE (de 1974 a 1º de agosto de 2017), MEDLINE (de 1946 a agosto de 2017 semana 1) e Maternity & Infant Care Database – MIDIRS (de 1971 a julho de 2017).

Dentre 442 resultados, 21 atenderam aos critérios de inclusão e foram selecionados na revisão. Dentre eles, nove foram publicados nos últimos anos, sugerindo crescente interesse pelo tema. Todos os estudos foram estudos observacionais (TOPALIDOU *et. al.*, 2019, p.3).

Em busca no portal da CAPES, foram filtrados artigos desde o ano de 2010 que tenham mais proximidade com o tema. A tabela a seguir apresenta os trabalhos associados com medição de temperatura por termografia.

Tabela 1 - Trabalhos associados com medição de temperatura por termografia

Autor /Escopo	Observação
ABBAS <i>et. al.</i> (2011) Monitoramento da respiração espontânea do recém-nascido	Influência de outras fontes de calor no ambiente, demandando melhorias no processamento de imagem
Knobel <i>et. al.</i> (2011) Termografia IR para medir a temperatura corporal de RNs e investigar condições patológicas.	Comparação entre temperatura média do abdômen e tórax. Não aborda exatidão da medida de temperatura em si.
ABBAS <i>et. al.</i> (2012) Termografia IR para medir a temperatura corporal de RNs focado em calibração, compensação de erros em diferentes cenários, incluindo berço aquecido	Apresenta fontes de erro que ficam entre 0,85 e 1,2°C sob diversas condições ambientais Sem abordagem computacional
Knobel <i>et. al.</i> (2013) Uso de oximetria de pulso, termistores e termografia para medir temperatura corporal e perfusão periféria em RNs.	Teste com 3 pacientes com erros de medida de temperatura entre 0,2 e 1°C. Informa sobre aumentar amostragem.
ABBAS & LEONHARDT (2014) Abordagem computacional para identificar ROIs na imagem do RN para fins de medição de temperatura.	Foco na identificação das ROIs para medição de temperatura. Não aborda exatidão da medida de temperatura em si.
SHARMA & YADAV (2017) Abordagem computacional usando algoritmo Viola-Jones de detecção de faces para medição de temperatura.	Foco na identificação das ROIs para medição de temperatura. Não aborda exatidão da medida de temperatura em si.
Knobel <i>et. al.</i> (2017) Termografia infravermelha para medir a temperatura de RNs prematuros.	Erros de medida de +2°C Não aborda formas para diminuição do erro

Tabela 1 (continuação) - Trabalhos associados com medição de temperatura por termografia

Autor /Escopo	Observação
Negishi et. al. (2020) Sistema de medição de sinais vitais para teste de triagem clínica em pacientes com gripe.	Estudo aplicado em adultos Erro de medida entre $-0,45^{\circ}\text{C}$ e $2,56^{\circ}\text{C}$ . Não aborda formas para diminuição do erro
Rassels & French (2021) Proposta para medir temperatura de RN por termografia eliminando fatores externos que causam erro de medição	Foco tratamento das fontes de erro e abre espaço para uso de IA na redução do erro de medida de temperatura.
Yang et. al. (2022), Medição de temperatura e frequência respiratória usando termografia	Estudo aplicado em adultos. Informa erro de menos de $0,5^{\circ}\text{C}$ . Não foram encontrados detalhes sobre o erro de medida de temperatura
ASANO et. al. (2022) Abordagem computacional para segmentar ROIs que viabilizem a medida de temperatura por termografia em RNs.	Foco na identificação das ROIs para medição de temperatura. Não aborda exatidão da medida de temperatura em si.
HAMADA et. al. (2022) Compensação do erro usando um corpo negro de referência com aplicação em Neonatologia	Para 2 de 3 casos estudados, o erro médio absoluto foi menor que $0,1^{\circ}\text{C}$ . Usa corpo negro para compensar erros de medida Não usa abordagem computacional para redução do erro
LYRA et. al (2022) Abordagem para extração de temperatura em Regiões de Interesse em RNs para extração da temperatura a partir da imagem térmica.	Erro máximo de medida de $0,98^{\circ}\text{C}$ . Calcula o erro com base em um parâmetro GT (Ground Truth) que também é extraído da imagem térmica. Não usa um termômetro de referência independente da imagem térmica

Apesar de terem sido encontrados estudos relevantes a respeito da medição de temperatura por termografia, é possível perceber a carência de pesquisas que explorem o uso de Redes Neurais Artificiais (RNAs) na redução do erro de medida de temperatura em RNs

Os autores pesquisados apresentaram estudos relevantes para a medida de sinais vitais usando termografia. Dentre eles, Rassels & French (2021) e Hamada (2022), que apresentam propostas que não utilizam abordagem computacional mas apresentam variáveis que podem ser mapeadas para melhorar a precisão da medida da temperatura por termografia na área de neonatologia.

Dessa forma o trabalho busca responder à seguinte questão: De que maneira a combinação de visão computacional, técnicas de inteligência artificial e termografia pode ser abordada para realizar o monitoramento preciso e não invasivo da temperatura de forma que viabilize sua aplicação em berços aquecidos por calor radiante?

## 1.4 OBJETIVOS

### 1.4.1 OBJETIVO GERAL

Desenvolver abordagem computacional para estimar a temperatura corporal por meio do processamento de imagens térmicas para que possa ser utilizada na medida da temperatura de bebês recém-nascidos posicionados em berços aquecidos por calor irradiante.

### 1.4.2 OBJETIVOS ESPECÍFICOS

- Capturar imagens térmicas de pessoas, coletando suas respectivas temperaturas utilizando um termômetro de contato de referência;
- Desenvolver abordagem computacional que converta dos valores RGB de pixels selecionados na imagem térmica em valores numéricos de temperatura para que possam ser comparados com o valor do termômetro de contato de referência;
- Estudar o erro da medida de temperatura usando um corpo negro com uma temperatura controlada de referência na imagem;
- Desenvolver solução para a correção do erro da medida de temperatura usando Redes Neurais Artificiais (RNA);
- Apresentar os valores de temperatura medidos a partir da imagem térmica (sem nenhuma compensação de erro) e seus respectivos valores usando RNA como forma de compensação de erro, bem como seus respectivos erros de medida em relação ao termômetro de contato de referência.

## 1.5 LIMITAÇÃO DO TEMA

O estudo foca em bebês termicamente estabilizados e atendidos por berços aquecidos. Os pacientes que são submetidos a estes equipamentos ficam situados em unidades de tratamento intensivo (UTIs) dos hospitais e maternidades. Devido à criticidade destes pacientes, o corpo clínico e os responsáveis pela gestão do hospital tendem a apresentar restrições de acesso do estudo aos recém-nascidos na área de UTI, justamente por terem preocupações associadas à exposição do paciente a riscos ambientais.

Por conta da dificuldade de acesso ao ambiente de estudo, os esforços do trabalho ficaram mais concentrados em fazer o estudo com recursos, equipamentos e dados de temperatura e imagens térmicas cedidos por uma empresa da área de neonatologia.

## 1.6 MÉTODOS E TÉCNICAS DE PESQUISA

A pesquisa realizada é classificada como estudo quantitativo com investigação experimental porque seus resultados são obtidos a partir do desenvolvimento de modelos computacionais e testes aplicados em imagens térmicas capturadas para este fim.

O resultado do experimento é a comparação dos valores de temperatura de referência com seus respectivos valores de temperatura estimados a partir da imagem térmica.

## 1.7 ORGANIZAÇÃO DA DISSERTAÇÃO

O Capítulo 2 contempla a fundamentação teórica sobre Termorregulação Neonatal, Radiação eletromagnética Infravermelha, Processamento da imagem térmica e Redes Neurais Artificiais.

No Capítulo 3, são apresentados os materiais e métodos utilizados na pesquisa, incluindo a abordagem computacional desenvolvida.

O Capítulo 4 apresenta os resultados e discussões acerca do experimento cuja conclusão é apresentada no capítulo 5.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 TERMORREGULAÇÃO NEONATAL

Durante a vida intrauterina, o feto produz calor derivado de seu intenso metabolismo. A maior parte desse calor é liberada via circulação placentária. No momento do nascimento, o RN é exposto ao ambiente externo ao útero, o que provoca uma grande perda de calor por convecção e evaporação. Se nenhuma medida for tomada para evitar essa perda, a temperatura corporal do RN pode cair com uma velocidade entre 0,2 a 1,0°C por minuto. Como resposta, o RN chora e inicia movimentos ativos, ocorrendo a termogênese da gordura marrom para produção de calor. A taxa metabólica pode aumentar de 2 a 3 vezes, resultando em um aumento no consumo de oxigênio. Em algumas horas, as reservas do RN para produção de calor podem ser esgotadas se a perda de calor não for interrompida imediatamente (SEGRE et al., 2015, p. 650).

A exposição a situações de instabilidade térmica pode acarretar efeitos fisiológicos adversos, incluindo aumento no consumo de oxigênio, acidose metabólica, hipoglicemia, risco de estresse de frio e hipotermia. Por este motivo, o gerenciamento da termorregulação neonatal é algo crítico para a sobrevivência de bebês (KOH & YU, 2016, p. 197).

Para garantir um desempenho nutricional adequado e o crescimento do recém-nascido (RN), é necessário reduzir a necessidade de produção de calor, o que pode ser indicado pela diminuição do consumo de oxigênio. O ambiente ideal para o RN ainda não é conhecido, mas existe uma faixa de temperatura chamada de Ambiente Térmico Neutro que, no mínimo, deve garantir uma taxa metabólica mínima e uma temperatura corporal normal para o RN. A temperatura corporal normal para recém-nascidos varia entre 36,5 e 37,5°C (JOSEPH et al., 2017, p. 114; SEGRE et al., 2015, p. 640; ALTIMIER, 2012, p. 51).

### 2.1.1 BERÇOS AQUECIDOS POR CALOR RADIANTE

Algumas medidas são adotadas para prevenir a perda de calor do RN, tais como secá-lo e envolvê-lo em campos aquecidos, além de posicioná-lo contra o tórax da mãe, entre as mamas, logo após o nascimento. Se intervenções adicionais forem necessárias, como aspiração e oxigenação, o RN deve ser colocado em um equipamento chamado berço aquecido de calor radiante (SEGRE et al., 2015, p. 650).

Berços aquecidos de calor radiante são equipamentos utilizados para auxiliar na termorregulação do RN. Esses equipamentos normalmente contam com dois sensores de temperatura, T1 (sensor principal) e T2 (sensor auxiliar), o que permite que se tenha maior segurança no monitoramento da temperatura do RN a partir de dois pontos diferentes do corpo do paciente. Esses sensores dependem fortemente de um bom contato térmico com o paciente e, por esse motivo, necessitam de acompanhamento frequente e muita atenção por parte do enfermeiro (SOLLAI et al., 2016, p. 1).

Esse equipamento também possui um sistema de servo-controle que se baseia na temperatura dos sensores presos à pele do paciente, fornecendo calor regulado de acordo com a demanda térmica do recém-nascido (JOSEPH et al., 2017, p. 114).


### 2.1.2 SENSORES DE TEMPERATURA T1 E T2

Termopares, RDTs (Resistores Dependentes da Temperatura) e termistores são os sensores de temperatura comumente pesquisados. O uso de um ou outro tipo de sensor apresenta vantagens e desvantagens na área médica (SYAMIMI & YAHUD, 2021).

Os sensores T1 e T2, também denominados sensores de pele, são compostos por um termistor (elemento resistivo sensível à temperatura), dentro de um invólucro cujos terminais são soldados a fios que são conectados aos painéis de equipamentos eletromédicos, como berços aquecidos e incubadoras (ABBAS et al., 2012, p. 100-101).

A Figura 5 apresenta quatro diferentes tipos de sensores para monitoramento em uma unidade de tratamento intensivo de neonatal. Cada tipo de sensor apresentado é adequado para uma determinada região do corpo do paciente e todos fazem uso de termistores como elemento transdutor de temperatura, sendo (a) termistor retal, (b) termistor de pele, (c) termistor axilar, (d) termistor de pé (ABBAS *et. al.* 2012 p.101)

Figura 5 - Tipos de termistores em monitoramento clínico



Fonte: ABBAS *et. al.* 2012 p. 101.

Para a equipe de enfermagem da UTI neonatal, o monitoramento da diferença de temperatura entre os sensores T1 e T2 é útil porque fornece a temperatura medida em duas regiões diferentes do corpo do RN. O sensor T1 (sensor principal) é posicionado na parte central do corpo do paciente. Já o sensor T2 (sensor auxiliar) é colocado em partes mais periféricas do corpo, como membros, pés e mãos. A diferença de temperatura entre T1 e T2 pode ser usada para avaliação clínica, como identificação de vasoconstrição periférica, por exemplo. (SEGRE *et al.*, 2015, p. 645 e p. 1150)

A temperatura medida a partir do sensor de temperatura de pele deve ter uma exatidão de  $\pm 0,3^{\circ}\text{C}$ . A Faixa de temperatura exibida deve ser pelo menos de  $30^{\circ}\text{C}$  a  $40^{\circ}\text{C}$  (ABNT NBR IEC 60601-2-21:2019)

## 2.2 RADIAÇÃO ELETROMAGNÉTICA INFRAVERMELHA


### 2.2.1 ESPECTRO ELETROMAGNÉTICO

A radiação eletromagnética, assim como a luz, é gerada pela vibração de partículas eletricamente carregadas, como partes de moléculas "aquecidas" (por exemplo, em um filamento de lâmpada incandescente). A luz visível ao olho humano é a radiação eletromagnética pertencente a uma parte do "espectro eletromagnético", que também inclui outras faixas de valores de radiação eletromagnética categorizados (JUNG et. al. 2008, p. 10).

O espectro eletromagnético começa com faixas identificadas como raios  $\gamma$  (gama) e raios X, passa por raios ultravioleta e é seguido pela faixa de espectro de luz visível (iniciando pela cor violeta e terminando na cor vermelha). Logo depois da faixa de luz vermelha (última cor do espectro visível), começam as faixas de radiação infravermelha, seguida pela faixa de micro-ondas, ondas curtas e médias de rádio (que incluem faixas de FM e AM) e terminando em ondas longas de rádio. (JUNG et. al. 2008, p. 10).

A radiação é emitida por parcelas discretas de energia chamadas fótons, que possuem natureza dual - partícula e onda. O principal parâmetro para distinguir as faixas do espectro eletromagnético é chamado comprimento de onda, que corresponde à distância entre os picos sucessivos da energia irradiada (ondas). Os níveis de energia dos fótons são determinados a partir do seu comprimento de onda, representado pela letra grega lambda ( $\lambda$ ) e expresso em unidades de comprimento (m). Das duas ondas apresentadas na Figura 6, a da esquerda apresenta comprimento de onda duas vezes maior que a da direita (JUNG et. al. 2008, p. 10).

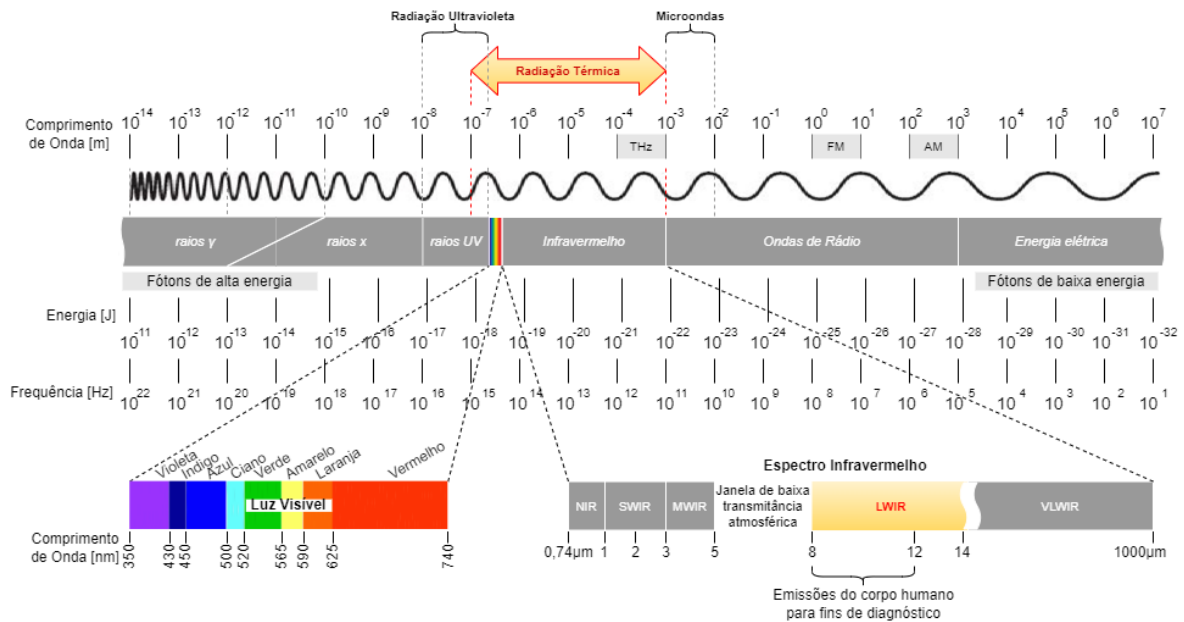
Figura 6 - Comparação entre comprimentos de onda diferentes



Fonte: JUNG et. al. 2008, p. 11

A Figura 7 apresenta uma imagem com o espectro de ondas eletromagnéticas identificando as faixas categorizadas.

Figura 7 - Espectro de ondas eletromagnéticas



Fonte: Autor (Modificado de: ABBAS, A. K. et. al., 2012, p. 95)

Na parte esquerda da imagem, é possível observar que os fótons de alta energia apresentam comprimentos de onda mais curtos e frequências mais elevadas. Já na parte direita da imagem, observa-se que os fótons de baixa energia apresentam comprimentos de onda mais longos e frequências mais baixas. Na região intermediária, ao centro da imagem, é possível identificar a faixa de radiação térmica que começa envolvendo parte dos raios ultravioleta, todo o espectro de luz visível e a faixa do espectro infravermelho.

Abaixo e à esquerda, o espectro da luz visível é detalhado, apresentando as faixas de comprimento de onda para cada intervalo de cores. Abaixo e à direita, o espectro Infravermelho é detalhado com um destaque para a faixa LWIR (*Long Wave Infrared* ou Infravermelho de ondas longas) com comprimentos de onda entre  $8\mu\text{m}$  e  $14\mu\text{m}$ . Esta faixa inclui o intervalo de  $8\mu\text{m}$  a  $12\mu\text{m}$  que, segundo ABBAS (2012), contempla as emissões do corpo humano que são tradicionalmente medidas para fins de diagnóstico (ABBAS, A. K. et. al., 2012, p. 93).

Berços aquecidos por calor radiante também fazem da radiação infravermelha em seus atuadores de potência. Estes equipamentos utilizam lâmpadas especiais de radiação infravermelha para produção de calor que é direcionado para o paciente. Esta luz invisível aos olhos humanos incide sobre o corpo do bebê posicionado no berço contribuindo na termorregulação do recém-nascido (ALTIMIER, 2012, p. 53).

### 2.2.2 EMISSIVIDADE E CORPO NEGRO

A pele humana, assim como qualquer objeto físico emite ondas eletromagnéticas em um espectro de comprimentos de onda conhecido como radiação infravermelha quando está a uma determinada temperatura. Dessa forma, a pele humana emite radiação infravermelha que é proporcional à sua temperatura (ABBAS, A. K. et al., 2012, p. 94).

A distribuição de comprimento de onda da radiação infravermelha emitida por um objeto depende tanto da sua temperatura quanto da sua emissividade espectral  $\epsilon(\lambda)$ . A emissividade espectral é uma propriedade dos materiais e superfícies que indicam a eficiência de emissão de radiação cujo valor é normalizado em relação um corpo negro, que é um corpo ideal absorvedor perfeito e radiador perfeito. O valor máximo da emissividade espectral de um corpo negro é igual a 1, o que significa que ele absorve e emite o máximo de energia infravermelha possível a uma dada temperatura, sem perdas de energia para o ambiente ao seu redor ( $\epsilon = 1$ ). Isso faz com que o corpo negro sirva como padrão de referência para a emissividade espectral de outros materiais e superfícies (ABBAS, A. K. et al., 2012, p. 94).

### 2.2.3 RADIAÇÃO INFRAVERMELHA E EMISSIVIDADE DA PELE HUMANA

Do ponto de vista da radiação eletromagnética, as radiações infravermelhas emitidas pelo corpo humano ocupam uma faixa de 8 a 12  $\mu\text{m}$  (ABBAS, A. K. et al., 2012, p. 93).

BERNARD (2013) indica que um corpo que não absorve toda a radiação incidente (também conhecido como um corpo cinza) emite menos energia que um corpo negro e é caracterizado por uma emissividade,  $\epsilon < 1$ . No caso da emissividade de 0,98 da pele humana, a reflexão de radiação infravermelha proveniente de uma outra fonte de calor no ambiente é mínima (BERNARD et al., 2013, p.584 e p.589).

A emissividade pode ser considerada constante para a propagação da onda eletromagnética em até 45° do ângulo normal à superfície do objeto observado. Entretanto, caso este ângulo de observação seja aumentado, a emissividade deixará de ser constante e pode haver acréscimo no erro de medida. Isso pode tornar necessária a criação de algum tipo de compensação (RASSELLS & FRENCH, 2021, p.5.).

A pele humana é um radiador quase perfeito, já que sua emissividade de 0,98 é resultado de muitos estudos feitos durante um período de 30 anos com um valor muito preciso de  $0,98 \pm 0,01$  determinado por STEKETEE (1973). Esse valor é muito próximo à emissividade de um corpo negro, o que confirma o efeito mínimo de reflexão de radiação. (TOPALIDOU, A. *et. al.*, 2019, p. 2; BERNARD *et. al.*, 2013, p. 584 e p. 589).

Apesar da pele humana ter um valor definido de emissividade, o efeito das diferentes pigmentações da pele nesse valor não é conhecido. CHARLTON *et. al.* (2020) realizaram um estudo para investigar a influência de diferentes pigmentações da pele na emissividade térmica em 65 voluntários adultos (CHARLTON, M. *et. al.* 2020, p. 1). O estudo concluiu que não há diferenças significativas na emissividade entre os participantes quando agrupados por pigmentação da pele. Isso sugere que a pigmentação da pele não afeta a emissividade térmica da pele usando imagens infravermelhas térmicas (CHARLTON, M. *et. al.* 2020, p. 1).

O valor resultante da temperatura do corpo medido pode ser afetado pela radiação refletida fornecida pela temperatura ambiente, ou seja, pelas ondas eletromagnéticas refletidas da área analisada, cujo comprimento de onda corresponde à temperatura dos objetos circundantes e do fundo. Isso pode ser chamado de "temperatura refletida" (BERNARD *et. al.*, 2013, p.584).

Segundo BERNARD (2013), é possível desconsiderar a temperatura refletida pela pele humana devido ao seu alto valor de emissividade, o que garante a mínima reflexão da temperatura ambiente. Porém, é necessário corrigir a temperatura da superfície em casos de pele tratada topicamente com pomada, gel ou alguma solução, devido a possíveis mudanças de emissividade. Se esta informação não for considerada, existe o risco de obter dados com grande margem de erro em situações

em que a temperatura ambiente refletida difere substancialmente da temperatura do tecido medido (BERNARD *et. al.*, 2013, p. 590).

## 2.3 PROCESSAMENTO DE IMAGEM TÉRMICA

### 2.3.1 TERMOGRAFIA POR INFRAVERMELHO

Embora a radiação infravermelha não seja visível ao olho humano, é possível de ser detectada e exibida na forma de imagens por meio de câmeras de termografia por infravermelho. Esses dispositivos oferecem uma maneira eficaz de determinação qualitativa da temperatura da superfície de um corpo. Entretanto, é importante observar que medições absolutas de temperatura podem ser desafiadoras, dependendo do tipo da câmera, ambiente e objeto que se deseja obter a medida de temperatura (ABBAS, A. K. *et. al.*, 2012, p. 95).

As câmeras termográficas convertem a radiação infravermelha em sinais elétricos que são convertidos em termogramas por uma unidade de processamento. Os termogramas, que contemplam valores de temperatura e representação térmica, têm sido amplamente utilizados em vários estudos ambientais, industriais e médicos. A imagem térmica, também chamada de termografia infravermelha, tem sido utilizada em estudos médicos nas áreas de termorregulação, detecção de câncer de mama, monitoramento neonatal, urologia e doenças vasculares (ORNEK *et. al.*, 2019, p. 1.).

A termografia por infravermelho é única porque oferece uma maneira não invasiva e sem contato de medir a temperatura do RN. Por este motivo, tem sido utilizada em medicina e para medidas experimentais científicas (KNOBEL *et. al.* 2017, p.118, BERNARD *et. al.*, 2013, p. 583).

Deve-se enfatizar que, na termografia, é necessário considerar diversas influências que podem afetar significativamente os valores de temperatura medidos. Em primeiro lugar, é preciso considerar as propriedades físicas da superfície examinada, como emissividade ou transparência, bem como fatores ambientais externos, como a temperatura ambiente. Também é necessário levar em consideração as fontes externas presentes de radiação infravermelha e o fundo de radiação (BERNARD *et. al.*, 2013, p. 584).

Na área de neonatologia, a termografia por infravermelho possibilitou a realização do mapeamento da distribuição de temperatura do recém-nascido durante o tratamento “mamãe canguru” (técnica de termorregulação pele a pele do bebê com a mãe). A termografia também tornou possível a realização do monitoramento da frequência respiratória a partir da temperatura na região nasal do paciente (temperatura na região das vias respiratórias diminui no momento da inspiração e aumenta no momento da expiração) (ABBAS, A. K. *et al.*, 2012, p. 107).

Quanto à medição da temperatura do corpo humano, a imagem térmica oferece uma boa oportunidade de mitigar riscos e desconforto associados ao sensor de pele. Também torna possível a busca, na imagem térmica, pela região que melhor represente a temperatura corporal do paciente (ANTINK *et al.*, 2020, p. 3050).

Por exemplo, por meio do processamento da imagem térmica é possível realizar a medida da temperatura em várias regiões ao longo do corpo, apresentando o gradiente de temperatura entre a região central e os membros, o que pode auxiliar em muitos diagnósticos médicos (ABBAS, A. K. *et al.*, 2012, p. 101).

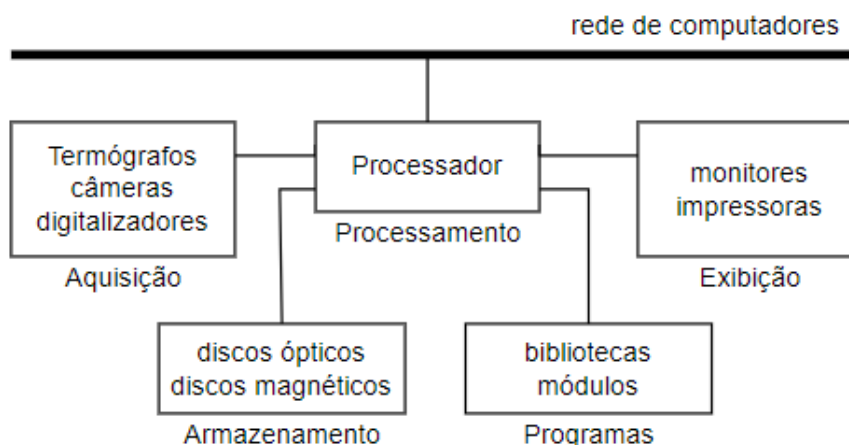
A termografia por infravermelho é uma técnica promissora na medicina, especialmente no contexto de monitoramento de recém-nascidos e de pacientes em condições críticas. No entanto, é fundamental que as limitações e influências que podem afetar a precisão da medida sejam consideradas, a fim de que a interpretação dos dados seja adequada e confiável. (ABBAS, A. K. *et al.*, 2012, p. 107, BERNARD *et al.*, 2013, p. 584, ANTINK *et al.*, 2020, p. 3050).

### 2.3.2 PROCESSAMENTO DE IMAGENS

Para o processamento das informações contidas nas imagens com o auxílio de computador, é necessário fazer o uso do conceito de visão computacional, que auxilia na resolução de problemas complexos, buscando imitar a cognição humana e a habilidade do ser humano de tomar decisões de acordo com as informações contidas na imagem. Este conceito é dividido entre processamento de imagens (baixo nível de abstração) e análise de imagens (alto nível de abstração) (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 03).

Um sistema de processamento digital de imagens é constituído por um conjunto de etapas capazes de produzir um resultado a partir do domínio do problema (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 03). Este sistema inclui componentes de aquisição, armazenamento, processamento, transmissão e exibição de imagens conforme apresentado na Figura 8 (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 05).

Figura 8 - Componentes de um sistema de processamento de imagens



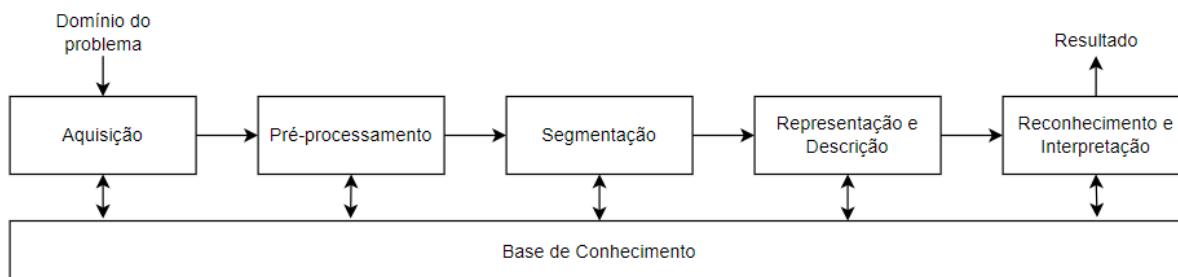
Fonte: PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 05

Pedrini & Schwartz (2008) também detalham as etapas do processamento de imagens que estão detalhadas a seguir:

- **Aquisição:** Captura da imagem por meio de um dispositivo ou sensor convertendo-a em uma representação adequada para o processamento subsequente;
- **Pré-processamento:** Melhoria da qualidade da imagem por meio da atenuação de ruído, correção de contraste ou brilho;
- **Segmentação:** Extração das regiões de interesse da imagem;
- **Representação e Descrição:** Manipulação dos atributos que identificam os objetos na imagem e extração destes atributos em valores numéricos, formando um vetor de características;
- **Reconhecimento e Interpretação:** Atribuição de uma identificação com base no vetor de características e atribuição de um significado aos objetos reconhecidos.
- **Base de conhecimento:** parte do sistema de processamento de imagens que possui o conhecimento sobre o domínio do problema.

A Figura 9 apresenta um diagrama com as etapas de um sistema de processamento de imagens.

Figura 9 - Etapas de um sistema de processamento de imagens



Fonte: PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 04

A análise de imagens é, tipicamente, baseada na forma, na textura, nos níveis de cinza ou nas cores dos objetos presentes nas imagens (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 01).

Para que uma imagem seja processada em um computador, primeiro ela deve ser digitalizada e convertida em um formato adequado. Uma representação comum de imagens para processamento de baixo nível de abstração é uma matriz retangular com elementos correspondendo a valores de brilho da imagem. (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 02).

Cada elemento desta matriz é chamado de pixel (acrônimo do inglês *Picture element*) e possui um valor de intensidade chamado de nível de cinza. Uma convenção comum é de se atribuir o nível de cinza mais escuro (cor preta) ao valor 0 e o nível de cinza mais claro (cor branca) ao valor 255. (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15).

Em uma imagem colorida, as cores visíveis pelo olho humano podem ser representadas como uma combinação de três cores primárias vermelha (*Red*), verde (*Green*) e azul (*Blue*). Cada representação de cor é identificada como sendo uma banda da imagem, ou seja, uma imagem colorida utiliza três bandas R (para banda vermelha), G (para banda verde) e B (para banda azul) (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 21 e 22).

ABBAS indica que a região da testa e supra nasal é uma boa região para fazer a estimativa da temperatura interna do paciente (ABBAS, A. K. *et. al.*, 2012, p. 101).

### 2.3.3 IMAGEM DIGITAL MONOCROMÁTICA

Uma imagem digital é obtida por meio de um processo denominado digitalização, que é dividido em duas etapas: Amostragem e Quantização (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15).

A Amostragem consiste em formar uma matriz de pontos, organizados lado-a-lado, denominados *pixels* com coordenadas x y de identificação. Cada pixel da matriz é identificado como um valor  $f(x,y)$  de intensidade do pixel (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15).

A Quantização consiste em gerar, para cada pixel de uma imagem monocromática, um valor L de nível de cinza (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15).

A figura 10 apresenta uma matriz M pixels na horizontal e N pixels na vertical para representar uma imagem digital (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15).

Figura 10 - Matriz de pixels de uma imagem digital

$$f(x, y) \approx \begin{bmatrix} f(0,0) & f(1,0) & \dots & f(M-1,0) \\ f(0,1) & f(1,1) & \dots & f(M-1,1) \\ \vdots & \vdots & \ddots & \vdots \\ f(0,N-1) & f(1,N-1) & \dots & f(M-1,N-1) \end{bmatrix}$$

Fonte: PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15

Cada pixel  $f(x,y)$  da matriz possui um valor L de nível de cinza dentro de um intervalo  $[L_{\min} - L_{\max}]$  que é denominado escala de cinza. Por convenção, a escala de cinza começa com o nível de cinza mais escuro ( $L_{\min} = 0$ ) representado pela cor preta, passando por valores de níveis de cinza intermediários e mais claros de maneira incremental, até atingir o nível de cinza mais claro ( $L=255$ ) representado pela cor branca (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 15).

É usual, em processamento digital de imagens, assumir que, tanto as dimensões quanto os níveis de cinza da imagem sejam potências inteiras de 2, ou seja,  $L=2^b$  (sendo  $L$  = Número de níveis de cinza e  $b$ = quantidade de bits – *binary units*). Um caso específico em que se tenha apenas dois níveis de cinza em uma imagem é chamado de imagem binária (sendo  $b=1$  e, conseqüentemente,  $L=2$ ). Esse tipo específico de imagem tem grande importância prática porque podem ser manipuladas por operadores lógicos disponíveis nas instruções de computadores (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 18).

Uma boa imagem digital depende fundamentalmente da quantidade de informação contida na imagem e do grau de detalhes dessa informação. Essas variáveis estão atreladas ao tamanho da matriz de pixels ( $M \times N$ ) e os níveis de cinza  $L$  associados a cada pixel. Esses parâmetros formam indicadores de resolução espacial e profundidade da imagem (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 18).

Resolução espacial está associada à densidade de pixels de uma imagem. Quanto maior a densidade de pixels, maior será a resolução da imagem. A figura 11 a seguir apresenta uma imagem com resolução de 128x128 pixels, seguido de outras duas imagens com resoluções menores, sendo 64x64 pixels e 32x32 pixels, respectivamente. As dimensões das imagens foram as mesmas para evidenciar a perda de detalhes (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 18).


Figura 11 - Efeito da redução na resolução espacial



Fonte: PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 20

A profundidade de imagem está associada à quantidade de bits necessários para os níveis de cinza da imagem armazenada. Por exemplo, para uma imagem em que cada pixel pode assumir valores de nível de cinza entre 0 e 255, o valor de L será 256. Então:  $L = 256 = 2^b = 2^8 \rightarrow b=8$  bits. Logo, a imagem, neste caso, terá profundidade de 8 bits por pixel. A figura 12 apresenta três imagens com resolução de 512x512 pixels. A primeira imagem possui profundidade de 3 bits por pixel ( $b=3$ ), seguida de uma imagem com profundidades de 2 bits por pixel ( $b=2$ ) e uma imagem binária de 1 bit por pixel ( $b=1$ ) (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 18).

Figura 12- Diferentes profundidades de imagem ( $b=3$ ,  $b=2$  e  $b=1$ )



Fonte: PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 21

#### 2.3.4 IMAGEM DIGITAL MULTIBANDA OU MULTIESPECTRAL

Em uma imagem digital monocromática, o valor do pixel é atrelado um escalar entre  $L_{min}$  e  $L_{máx}$ . Imagens multibandas ou multiespectrais podem ser interpretadas como imagens nas quais cada pixel tem associado um valor vetorial  $f(x,y) = (L_1, L_2, \dots, L_n)$ , onde  $L_{min} \leq L_i \leq L_{máx}$  e  $i= 1,2,\dots,n$ . Em geral,  $L_i$  pode representar grandezas diferentes, tais como temperatura, pressão ou frequência amostradas em pontos  $(x,y)$  (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 19).

Uma imagem espectral também pode ser interpretada como uma sequência de  $n$  imagens monocromáticas, tal que cada imagem é conhecida como banda (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 19 - 20).

Imagens multiespectrais são muito utilizadas em sensoriamento remoto, cujos sensores operam em diferentes faixas do espectro eletromagnético. Dependendo do objeto a ser monitorado, a interação da radiação eletromagnética no sensor produz maior ou menor resposta espectral, cujo valor está associado à posição de um pixel da banda em particular (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 20 - 21).

Uma imagem colorida é uma imagem multibanda ou multiespectral, em que a cor em cada ponto (x,y) é definida por meio de três grandezas: Luminância (associada ao brilho da luz), matiz (associado ao comprimento de onda dominante) e saturação (grau de pureza do matiz) (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 21).

A maioria das cores visíveis pelo olho humano pode ser representada como uma combinação das bandas das cores vermelha (R, *red*), verde (G, *green*) e azul (B, *blue*). Uma imagem colorida comumente utiliza três bandas R, G, e B com profundidade de 1byte por pixel, ou seja, 24 bits por pixel (8 bits para cada banda) (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 21-22).

Uma imagem colorida também pode ser armazenada por meio de uma imagem monocromática e um mapa de cores. Desta forma, o valor de cinza de cada pixel na imagem é um índice para uma entrada do mapa de cores, que por sua vez contém os valores RGB referentes à cor do referido pixel. A quantidade de entradas do mapa de cores determina o número de cores utilizadas para representar a imagem (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 22).

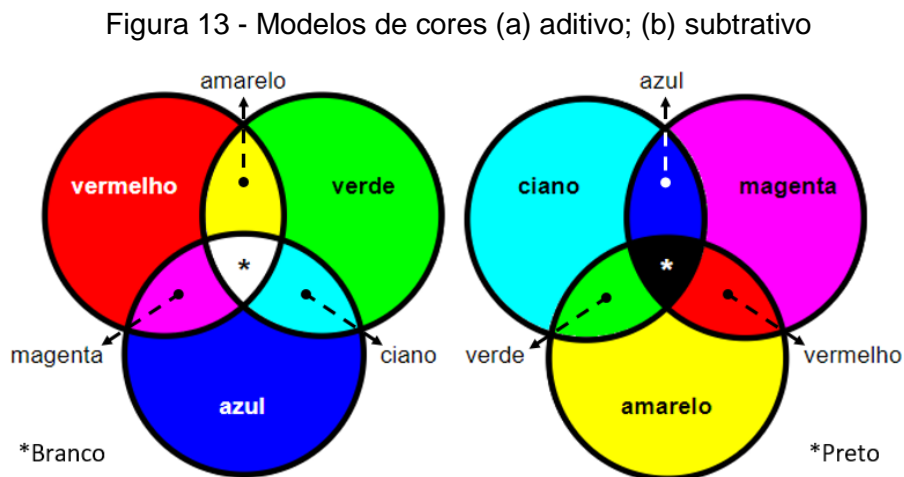
### 2.3.5 MODELOS E ESPAÇOS DE CORES

Um modelo de cor é essencialmente uma representação tridimensional em que cada cor é especificada por um ponto em um sistema de coordenadas tridimensionais (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 469).

Espaço de cores é o universo de cores que podem ser reproduzidas por um modelo. Como nenhum modelo é único a ponto de descrever todos os aspectos referentes às cores, diferentes modelos são utilizados para especificar as características das cores (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 469).

Os modelos podem ser aditivos ou subtrativos. Em um modelo aditivo RGB, por exemplo, a cor branca é gerada pela adição das cores primárias vermelha (R, *red*), verde (G, *green*) e azul (B, *blue*) assim como a ausência dessas cores indica a cor preta (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 469).

Já em um modelo subtrativo, a cor preta é gerada pela combinação das cores primárias ciano, magenta e amarelo e a cor branca corresponde à ausência destas cores primárias. A figura 13 apresenta os exemplos dos modelos aditivo e subtrativo (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 470).

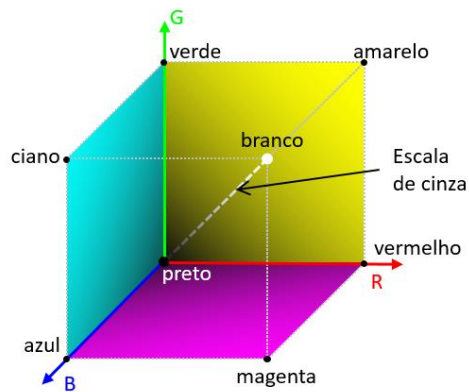


Fonte: Adaptado de PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 470

### 2.3.6 ESPAÇO DE CORES RGB

Este modelo de cores é baseado em um sistema de coordenadas cartesianas representado pelos eixos RGB (*red, green, blue*, respectivamente), em que o espaço de cores é um cubo. O vértice de origem dos três planos RG, GB e RB é representado pela cor preta, enquanto que, os demais vértices opostos à origem são representados pelas cores amarelo (para o plano RG), ciano (para o plano GB) e magenta (para o plano RB). A diagonal que apresenta o mesmo ângulo em relação aos três eixos corresponde à escala de cinza que inicia com preto (na origem) e chega no branco (na extremidade oposta do cubo). A figura 14 apresenta a ilustração do modelo RGB e o espaço de cores representado pelo cubo (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 471).

Figura 14 - Modelo RGB e espaço de cores representado por um cubo




Fonte: Adaptado de PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 472

### 2.3.7 ESPAÇO DE CORES CIE Lab\* E TONS DE PELE

Também conhecido como espaço de cores CIE Lab\*, o modelo apresentado na figura 15 foi definido pela Comissão Internacional de Iluminação (CIE, do francês *Comission Internationale de l'Clairage*) e é dividido em 3 componentes:  $L^*$  que corresponde à luminância, enquanto que  $a^*$  e  $b^*$  correspondem à informação de cromaticidade (PEDRINI, H., & SCHWARTZ, W. R., 2008, p. 468 e 478, LY, *et. al.*, 2020, p.5).

Figura 15 - Diagrama do espaço de cores CIELAB



Fonte: LY, *et. al.*, 2020, p.5

No diagrama, O valor  $L^*$  é representado verticalmente com valores de 0 (preto) a 100 (branco). O valor  $a^*$  indica o componente vermelho-verde de uma cor, onde valores positivos representam vermelho e valores negativos representam verde. Os componentes amarelo e azul são representados no eixo  $b^*$  com valores positivos e negativos, respectivamente. No centro do plano está o ponto neutro ou acromático. A distância do eixo central representa a croma ( $C^*$ ), ou saturação da cor. O ângulo nos eixos de cromaticidade representa o matiz ( $h^\circ$ ) (LY, *et. al.*, 2020, p.5).

De acordo com Ly (2020), os valores  $L^*$ ,  $a^*$  e  $b^*$  podem ser convertidos em parâmetros dermatológicos. O valor  $L^*$  está relacionado ao nível de pigmentação da pele, o valor  $a^*$  mede o eritema cutâneo (vermelhidão da pele causada por dilatação de vasos sanguíneos) e é influenciado pela composição de melanina e fluxo sanguíneo cutâneo e o valor  $b^*$  está relacionado à pigmentação constitucional do indivíduo e sua capacidade de bronzear, especificamente, a mudança nos carotenoides, síntese de melanina e oxidação após exposição aos raios ultravioleta (LY, *et. al.*, 2020, p.5-12).

## 2.4 REDES NEURAIS ARTIFICIAIS

O estudo em Redes Neurais Artificiais (RNAs) é motivado pelo reconhecimento de que o cérebro humano processa informações de forma diferente de um computador digital convencional. O cérebro é um Sistema de processamento de informação altamente complexo, não-linear e paralelo (HAYKIN 2007, p. 27).

O cérebro humano tem uma estrutura que permite a criação de regras de resposta na interação do indivíduo com o ambiente. Essas regras são usualmente denominadas de “experiências” que são acumuladas e desenvolvidas com o tempo e interação com o ambiente (HAYKIN 2007, p. 27-28).

Um neurônio em “desenvolvimento” é o que permite que o sistema nervoso seja desenvolvido e se adapte ao seu meio ambiente. Essa característica é denominada de plasticidade (HAYKIN 2007, p. 28).

De maneira análoga ao cérebro humano, RNA é uma estrutura computacional de células computacionais simples denominadas “neurônios” interligadas em uma cadeia, possibilitando a realização de um processo denominado “aprendizagem” (HAYKIN 2007, p. 28).

De acordo com Haikin (2007), uma RNA pode ser vista como uma máquina adaptativa e que tenha a seguinte definição:

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidos como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido”

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem e tem a função de modificar os pesos sinápticos da rede de forma ordenada para alcançar um objetivo desejado (HAYKIN 2007, p. 28).

#### 2.4.1 PROPRIEDADES DAS REDES NEURAIS

Segundo Haikin (2007), é importante reconhecer que um longo caminho deve ser percorrido antes de construir uma arquitetura computacional que mimetize o cérebro humano. Entretanto, o uso de redes neurais oferece as seguintes propriedades úteis e capacidades:

1. Não-linearidade: Um neurônio artificial pode ser linear ou não linear. Uma rede neural composta de neurônios não-lineares forma uma RNA não-linear. Esta propriedade é muito importante, principalmente se o sinal de entrada da rede for inerentemente não-linear (sinal de voz, por exemplo)
2. Mapeamento de Entrada-Saída: Amostras de treinamento com resposta desejada correspondente são apresentadas à rede para que os pesos sinápticos (parâmetros livres) sejam modificados para minimizar o erro (diferença entre a resposta esperada e a resposta da rede). O treinamento da rede é executado para muitos exemplos do conjunto de amostras até que a rede alcance um estado estável, onde não haja modificações significativas nos pesos sinápticos

3. Adaptabilidade: Capacidade de adaptar pesos sinápticos frente às modificações do ambiente. É importante que uma RNA seja adaptativa para ter um bom desempenho quando este submetida a um ambiente não-estacionário (que muda dinamicamente com o tempo). Entretanto, é necessário ponderar adaptabilidade com estabilidade. Constantes de tempo pequenas podem causar respostas mais rápidas causando instabilidade frente a perturbações espúrias. Por isso é importante fazer um bom ajuste das constantes de tempo para que a RNA consiga ser robusta frente às perturbações espúrias e, ao mesmo tempo, consiga responder frente às mudanças significativas no ambiente. Este problema é descrito como o dilema da estabilidade-plasticidade.
4. Resposta a evidências: Em um contexto de classificação de padrões, uma RNA pode ser projetada para indicar qual padrão deve ser selecionado. A RNA também pode indicar o nível de confiança da escolha feita.
5. Informação contextual: A informação contextual é tratada naturalmente pela rede neural porque cada neurônio da rede é potencialmente afetado pela atividade de todos os neurônios da rede, ou seja, o conhecimento relacionado ao contexto do sistema é representado pela própria estrutura da rede neural.
6. Tolerância a Falhas: Se um neurônio ou suas conexões são danificados, por exemplo, a recuperação de um padrão armazenado é prejudicada em termos de qualidade. Entretanto, pela natureza distribuída da informação armazenada na rede, o dano precisa ser extenso a ponto de degradar a qualidade da resposta global da rede. Este tipo de situação pode acontecer em redes neurais implementadas com hardware.
7. Implementação em Integração em escala muito grande (VLSI – *Very-Large-Scale-Integration*): A característica paralela da RNA a torna potencialmente rápida para computação de certas tarefas, o que viabiliza a implementação de integrações em larga escala (em uma estrutura hierárquica, dividindo o problema em partes menores), possibilitando meios de se obter comportamentos complexos de forma altamente hierárquica

8. Uniformidade de Análise: RNAs são vistas como processadores de informação no sentido de que a mesma notação é utilizada em todos os domínios da aplicação de RNAs. Esta característica se manifesta de diferentes modos:
  - a. Os neurônios representam um componente comum a todas as RNAs
  - b. Esta uniformidade possibilita o compartilhamento de teorias e algoritmos de aprendizagem em aplicações diferentes de RNAs
  - c. Redes modulares podem ser construídas através de uma integração homogênea de módulos
9. Analogia Neurobiológica: Neurobiólogos olham para as RNAs como ferramenta de pesquisa para interpretação de fenômenos neurobiológicos. Por outro lado, Engenheiros olham para a neurobiologia procurando novas ideias para resolver problemas mais complexos do que aqueles baseados em técnicas convencionais por conexões fixas.


#### 2.4.2 MODELOS DE UM NEURÔNIO ARTIFICIAL

Um neurônio é uma unidade de processamento de informação que possui três elementos básicos: Conjunto de sinapses ou elos de conexão, um elemento somador e uma função de ativação (HAYKIN 2007, p. 36-37).

1. Conjunto de sinapses ou elos de conexão: Cada sinal de entrada  $x$  do neurônio é submetido a um peso sináptico  $w$  que pode possuir valores positivos ou negativos (HAYKIN 2007, p. 36).
2. Elemento Somador: todos os sinais de entrada ponderados pelos pesos sinápticos são somados formando um combinador linear (HAYKIN 2007, p. 37).
3. Função de ativação: Também referida como função restritiva, visto que limita o intervalo de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado  $[0,1]$  ou alternativamente  $[-1,1]$  (HAYKIN 2007, p. 37).

A figura 16 apresenta duas representações visuais de neurônio considerando os três elementos descritos anteriormente

Figura 16 - Modelos não lineares de um neurônio



Fonte: HAYKIN 2007 p. 36

Observando os modelos acima, é possível observar a presença de um *bias* ( $b_k$ ) que tem o efeito de aumentar (*bias* positivo) ou diminuir (*bias* negativo) a entrada líquida da função de ativação (HAYKIN 2007, p. 37).

Nos desenhos acima, as entradas são representadas por  $x$ ,  $w$  representa os pesos sinápticos,  $k$  identifica o neurônio,  $v$  representa o resultado da soma calculada pela junção aditiva,  $b$  representa o *bias* e  $y$  é a saída da função de ativação  $\varphi$  (HAYKIN 2007, p. 37).

As equações a seguir descrevem um neurônio em termos matemáticos (HAYKIN 2007, p. 37):

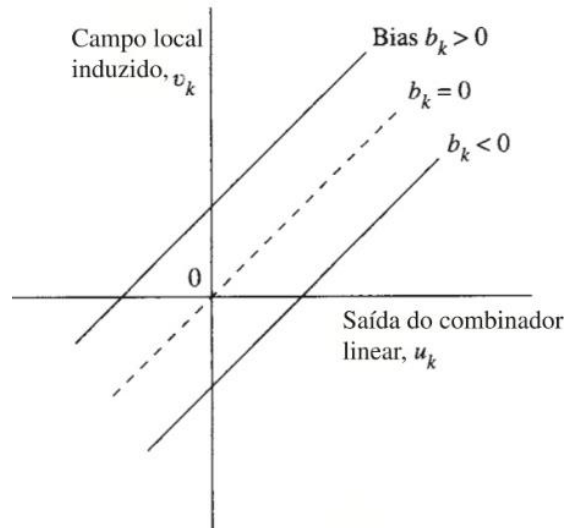
$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

$$v_k = u_k + b_k \quad (3)$$

O gráfico da figura 17 ilustra que o bias influencia na saída do combinador linear ( $u_k$ ) e, conseqüentemente no potencial de ativação do neurônio ( $v_k$ ), também chamado de “campo local induzido” (HAYKIN 2007, p. 37).

Figura 17 - Influência do bias na saída do combinador linear e campo local induzido



Fonte: HAYKIN 2007

Considerando o *bias* como sendo um parâmetro externo do neurônio artificial e recombinação as equações já apresentadas, temos então:

$$v_k = \sum_{j=0}^m w_{kj}x_j \quad (4)$$

$$y_k = \varphi(v_k) \quad (5)$$

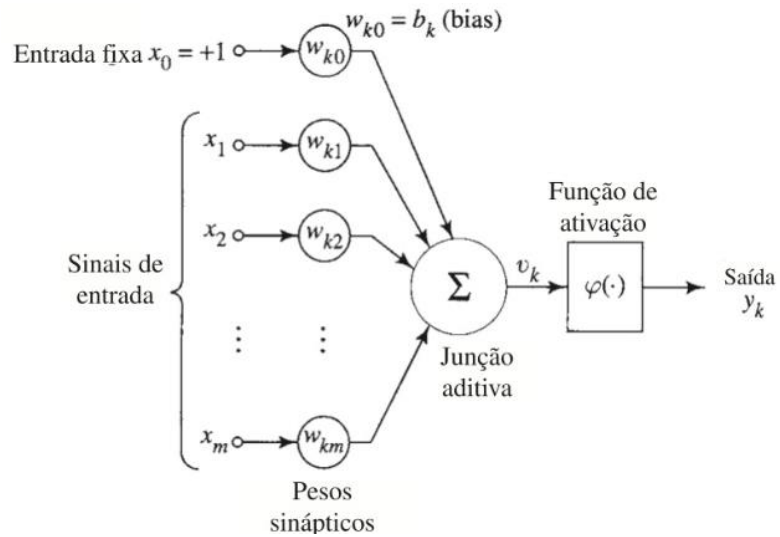
$$x_0 = +1 \quad (6)$$

$$w_{k0} = b_k \quad (7)$$

Com a reformulação acima, o neurônio passou a ter uma nova sinapse  $x_0$ , o *bias* passa a ser um peso sináptico  $w_{k0}$ , a junção aditiva inclui, também o *bias* como uma entrada sináptica (uma vez que agora, inicia  $j = 0$ ) e a saída é o resultado da função de ativação considerando o resultado da junção aditiva ( $v_k$ ) (HAYKIN 2007, p. 37).

Com este rearranjo de variáveis, o modelo do neurônio pode ser representado pela imagem da figura 18 (HAYKIN 2007, p. 37).


Figura 18 - Outro modelo não-linear de um neurônio



Fonte: HAYKIN 2007 p. 38


Um neurônio artificial também pode ser apresentado na forma de grafo. Da mesma forma, o grafo pode ser usado para apresentar a interconexão entre dois ou mais neurônios, formando uma rede neural. A figura 19 e 20 apresentam os grafos de um neurônio e de uma rede neural, respectivamente (HAYKIN 2007, p. 44 p. 48)

Figura 19 - Grafo de representação de um neurônio artificial



Fonte: HAYKIN 2007 p. 44

Figura 20 - Grafo de representação de uma rede neural



Fonte: HAYKIN 2007 p. 48

### 2.4.3 FUNÇÕES DE ATIVAÇÃO DE UM NEURÔNIO

A função de ativação define a saída de um neurônio a partir do campo induzido  $v$ . Os três modelos básicos de funções de ativação são identificados como (HAYKIN 2007, p. 38-40):

1. Função limiar, também referida como função de Heavyside
2. Função linear por partes, que pode ser interpretada como uma aproximação de um amplificador não linear
3. Função Sigmóide que apresenta um gráfico em forma de "s" e é a função mais comumente usada na construção de redes neurais.


A Figura 21 apresenta a representação das três funções de ativação e respectivas formas gráficas

Figura 21 - Funções de ativação Limiar, Linear por partes e Sigmóide

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (8)$$

$$\varphi(v) = \begin{cases} 1, & v \geq +1/2 \\ v, & +1/2 > v > -1/2 \\ 0, & v \leq -1/2 \end{cases} \quad (9)$$

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (10)$$



Fonte: HAYKIN 2007 p. 39-40

#### 2.4.4 PROCESSOS DE APRENDIZAGEM

A principal propriedade de uma rede neural é a sua habilidade de aprender a partir do seu ambiente e melhorar seu desempenho por meio da aprendizagem. Este processo acontece por meio de uma medida pré-estabelecida e também depende do tempo de interação da rede com o seu ambiente para viabilizar os ajustes nos pesos sinápticos e níveis de bias (HAYKIN 2007, p. 75).

HAYKIN (2007) definiu aprendizagem, no contexto de redes neurais, como sendo um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre. Tal definição implica na seguinte sequência de eventos:

1. A rede neural é estimulada por um ambiente
2. A rede neural sofre modificações em seus parâmetros livres como resultado desta estimulação
3. A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas em sua estrutura interna.

Algoritmo de aprendizagem é o nome dado ao conjunto preestabelecido de regras bem-definidas para a solução de um problema de aprendizagem. Os algoritmos de aprendizagem apresentam diferenças entre si pela forma de ajuste do peso sináptico de um neurônio (HAYKIN 2007, p. 76).

## 2.4.5 PERCÉPTRON DE MÚLTIPLAS CAMADAS

Percéptrons de múltiplas camadas é o nome dado a uma rede neural de múltiplas camadas, sendo: uma camada de entrada composta por um conjunto de unidades sensoriais conhecidas como nós de fonte, uma ou mais camadas ocultas de nós computacionais e uma camada de nós computacionais de saída. O sinal de entrada se propaga pela rede, camada por camada (HAYKIN, 2007 p. 182).

Um percéptron de múltiplas camadas tem três características distintivas (HAYKIN, 2007 p. 183):

1. Cada neurônio da rede possui uma função de ativação “suavemente” não-linear, ou seja, diferenciável em qualquer ponto. A função normalmente utilizada para este fim é a não linearidade sigmoide definida pela função logística:


Onde:

- $v_j$  é o campo local induzido (soma ponderada de todas as entradas sinápticas acrescidas do *bias*) do neurônio  $j$
  - $y_j$  é a saída do neurônio
2. A rede contém uma ou mais camadas de neurônios ocultos, que não pertencem à entrada e nem à saída da rede. Essa camada de neurônios ocultos possibilitam a rede a aprender tarefas complexas extraindo características dos vetores (padrões) de entrada
  3. A rede possui alto grau de conectividade. Modificação na conectividade da rede requer mudança na população das conexões sinápticas ou nos pesos sinápticos

Embora o poder computacional do percéptron de múltiplas camadas seja derivado das características acima citadas juntamente com a habilidade de aprender por meio de treinamento, essas características também trazem dificuldades e limitações a respeito do nosso conhecimento sobre o comportamento da rede. Além da presença dos neurônios ocultos dificultarem a visualização do processo de aprendizagem, a distribuição da não linearidade e sua alta conectividade dificulta a análise teórica de um percéptron de múltiplas camadas (HAYKIN, 2007 p. 183).

A figura 22 apresenta a arquitetura de um percéptron de múltiplas camadas com duas camadas ocultas e uma camada de saída (HAYKIN, 2007 p. 185).

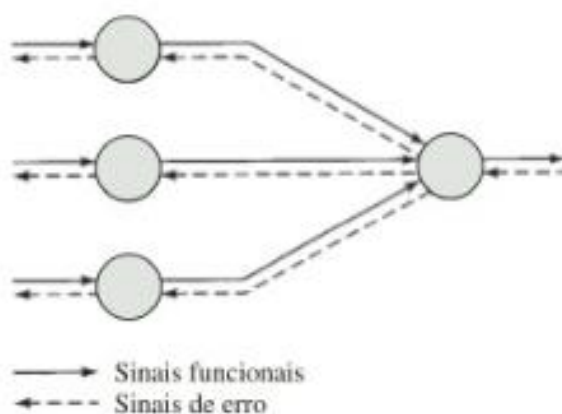
Figura 22 - Arquitetura de um percéptron de múltiplas camadas com duas camadas ocultas



FONTE: HAYKIN (2007) p. 185.

Separando uma parte do percéptron de múltiplas camadas, podemos identificar os sinais funcionais, que avançam na rede em direção ao sinal de saída e os sinais de erro, que fluem do sinal de saída em direção ao sinal de entrada. A figura 23 apresenta o detalhamento dos fluxos dos sinais funcionais e sinais de erro (HAYKIN, 2007 p. 185).

Figura 23 - Percéptron de múltiplas camadas - Fluxos dos sinais funcionais e sinais de erro



FONTE: HAYKIN (2007) p. 185.

Também denominado sinal de entrada, o sinal funcional é um estímulo que é aplicado na entrada da rede, se propaga ao longo da rede, neurônio por neurônio e se apresenta como sinal de saída (HAYKIN, 2007 p. 185).

Um sinal de erro é originário da saída da rede que se propaga para trás ao longo da rede, camada por camada (HAYKIN, 2007 p. 186).

Cada neurônio oculto ou de saída realiza dois cálculos (HAYKIN, 2007 p. 186):

1. Cálculo do sinal funcional de saída do neurônio, expresso como um função não-linear do sinal de entrada e dos pesos sinápticos
2. Cálculo e estimativa do vetor gradiente (gradientes da superfície de erro em relação aos pesos conectados às entradas de um neurônio), que é necessário para a retropropagação da rede.

#### 2.4.6 ALGORITMO DE RETROPROPAGAÇÃO

O algoritmo de retropropagação, apesar de não ser possível afirmar que consiga fornecer uma solução ótima para todos os problemas solucionáveis, fornece um método computacional eficiente para o treinamento de percéptrons de múltiplas camadas (HAYKIN, 2007 p. 183).

O treinamento da rede acontece de forma supervisionada por um algoritmo denominado retropropagação de erro (algoritmo *back-propagation*) e consiste de dois passos através das camadas da rede (HAYKIN, 2007 p. 182):

- Passo para frente, a propagação, em que um vetor de entrada é aplicado aos nós sensoriais e seu efeito se propaga através da rede, camada por camada, produzindo um resultado em um conjunto de saídas como resposta real da rede. Durante a propagação, os pesos sinápticos estão todos fixos.

- Passo para trás, em que os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. O sinal de erro é o resultado da subtração entre a resposta real da rede e a resposta desejada (alvo). Então esse sinal de erro é propagado ao longo da rede em sentido contrário em relação à direção das conexões sinápticas. Daí o nome de retropropagação de erro (HAYKIN, 2007 p. 182).

Para o método de atualização sequencial dos pesos sinápticos da rede o algoritmo *back-propagation* circula através da amostra de treinamento seguindo as etapas a seguir (HAYKIN, 2007 p. 199-201):

1. Inicialização: Assumindo ausência de qualquer informação prévia, retire os pesos sinápticos e limiares de uma distribuição uniforme cuja média seja nula e variância seja escolhida de forma que o desvio padrão dos campos locais induzidos dos neurônios fiquem na transição entre as regiões linear e saturada da função de ativação sigmoide
2. Apresentação dos exemplos de treinamento: Apresente uma época de exemplos de treinamento à rede. Para cada exemplo, realize a sequência de computações para frente (*propagation*) e para trás (*back-propagation*), descritas nas etapas 3 e 4, respectivamente
3. Computação para frente (*propagation*): Calcule os campos locais induzidos e os sinais funcionais da rede, camada por camada até à camada de saída. Em seguida, calcule o sinal de erro para que seja possível fazer a computação para trás (*back-propagation*) descrita na etapa 4
4. Computação para trás (*back-propagation*) calcule os gradientes locais da rede e ajuste os pesos sinápticos da rede nas camadas anteriores, de acordo com a taxa de aprendizagem.
5. Iteração: Itere computações para frente e para trás (conforme descritas nas etapas 3 e 4), apresentando novas épocas de exemplos de treinamento para a rede até satisfazer um critério de parada estabelecido.

### 3. MATERIAIS E MÉTODOS

#### 3.1 EQUIPAMENTOS

A captura de imagens foi realizada com o uso da câmera térmica de modelo MTV-2010 do fabricante Minipa. Este modelo foi escolhido porque já estava disponível para o estudo, dispensando a necessidade de locação de um outro modelo de câmera. A Figura 24 apresenta a imagem ilustrativa da câmera e a Tabela 2 apresenta as especificações gerais extraídas de seu manual de instruções.

Figura 24 - Câmera térmica Minipa modelo MTV-2010



Fonte: Manual de Instruções do produto (2011)

Tabela 2 - Especificações da câmera térmica utilizada no estudo

Atributo	Especificação
Interface de usuário	<ul style="list-style-type: none"><li>• Display de 3,5" LCD colorido</li><li>• Sobreposição entre imagem visível e Imagem térmica com níveis diferentes (100%, 75%, 50%, 25%, 0%)</li></ul>
Armazenamento	<ul style="list-style-type: none"><li>• Mais de 1000 imagens em cartão de memória micro SD</li><li>• Imagem padrão BMP</li><li>• Imagem visível e imagem térmica lado a lado</li></ul>
Condições ambientais	<ul style="list-style-type: none"><li>• Temperatura de operação: -5°C a +45°C</li><li>• Umidade relativa do ar para operação: 10% a 90%</li></ul>
Termografia	<ul style="list-style-type: none"><li>• 8 paletas de cores</li><li>• Faixa de temperatura: -10°C a +350°C</li><li>• Precisão: <math>\pm 2^{\circ}\text{C}</math></li><li>• Resolução: 0,1°C</li><li>• Resposta espectral: 8<math>\mu\text{m}</math> a 12<math>\mu\text{m}</math></li><li>• Matriz de pixels: 47x47</li><li>• Faixa de foco: 0,5m a infinito</li><li>• Emissividade: Opção de seleção entre 0,10 a 1,00 com compensação de reflexão da temperatura ambiente</li></ul>
Alimentação elétrica	<ul style="list-style-type: none"><li>• Bateria de íon de lítio com autonomia de 6 horas</li><li>• Fonte externa de 12V</li></ul>

Um termômetro de contato, popularmente conhecido como termômetro de testa foi empregado como um dispositivo para a coleta da temperatura de referência de comparação com a medida feita por meio da imagem térmica. A Figura 25 apresenta a imagem ilustrativa do termômetro.

Figura 25 - Termômetro de referência utilizado no estudo



Fonte: Manual de instruções do produto (2021)

A Tabela 3 apresenta as especificações gerais coletadas a partir do manual de instruções do produto:

Tabela 3 - Especificações do termômetro de referência

Atributo	Especificação
Interface de usuário	<ul style="list-style-type: none"> <li>• Display de 4 dígitos e ícones especiais</li> <li>• 2 Modos de medição (ouvido e testa)</li> </ul>
Armazenamento	<ul style="list-style-type: none"> <li>• Indicação automática da última temperatura medida</li> <li>• Armazenamento de 12 resultados de leituras</li> </ul>
Condições ambientais	<ul style="list-style-type: none"> <li>• Temperatura de operação: 16°C a +40°C</li> <li>• Umidade relativa do ar para operação: 15% a 95%</li> </ul>
Medida de temperatura	<ul style="list-style-type: none"> <li>• Faixa de temperatura (ouvido): 0°C a 100°C</li> <li>• Faixa de temperatura (testa): 34°C a 42,2°C</li> <li>• Resolução: 0,1°C</li> <li>• Precisão: <math>\pm 0,2^\circ\text{C}</math></li> </ul>
Alimentação elétrica	<ul style="list-style-type: none"> <li>• Bateria 3V CR2132</li> <li>• Autonomia: aproximadamente 1000 medições</li> </ul>

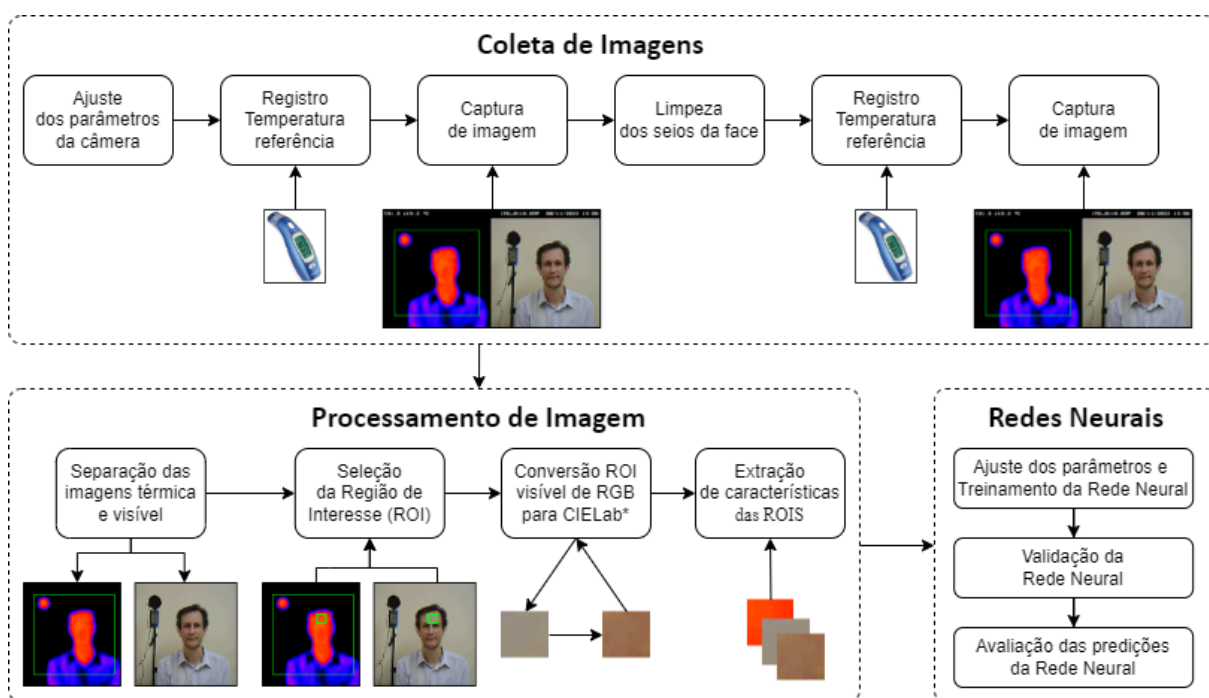
Este modelo de termômetro foi escolhido porque possibilita a coleta de temperatura na região da testa, mesma região de interesse da imagem térmica.

### 3.2 METODOLOGIA PROPOSTA

A abordagem computacional foi desenvolvida em ambiente Anaconda Spyder utilizando a linguagem Python 3.8, uma vez que parte da abordagem (Processamento de imagens em três bandas) já estava implementada nessa linguagem. Outro fator que favoreceu o uso do Python é a facilidade implementação utilizando as bibliotecas OpenCV e Scikit-learn, para Visão Computacional e Redes Neurais Artificiais, respectivamente.

A Figura 26 apresenta o diagrama da metodologia proposta para o estudo, bem como as etapas de processamento das imagens e Redes Neurais Artificiais.

Figura 26 - Diagrama da metodologia proposta



Fonte: Autor

A metodologia contempla 3 etapas básicas:

1. Aquisição de Imagens: Este bloco contém todas as etapas do processo de aquisição de imagens para criar o banco de dados de imagens. O mesmo processo deve ser utilizado para novas capturas e previsões futuras.
  - a. Ajuste dos parâmetros da câmera térmica: neste ponto, todos os ajustes são feitos na câmera térmica para atender às necessidades apresentadas pelo problema.

- b. Leitura de temperatura: Neste ponto, a temperatura na região da testa da pessoa é medida usando um termômetro de contato.
  - c. Aquisição de imagem: Neste ponto, a primeira imagem da pessoa é capturada pela câmera.
  - d. Limpeza do rosto com papel: este passo é necessário porque a oleosidade da pele pode causar erros de leitura. Assim, com duas imagens, o algoritmo pode aprender a compensar esse problema.
  - e. Leitura de temperatura: Neste ponto, a temperatura na região da testa da pessoa é medida novamente usando um termômetro de contato.
  - f. Aquisição de imagem: Neste ponto, a segunda imagem da pessoa é capturada pela câmera.
2. Processamento de Imagem: No processamento de imagem, são executadas etapas de pré-processamento e extração de características.
- a. Separação das imagens visível e térmica: Este passo consiste em abrir o arquivo .BMP da câmera e dividi-lo em duas novas imagens, sendo a primeira a imagem com a representação térmica da temperatura e a segunda a imagem RGB visível da pessoa.
  - b. Seleção da ROI (Região de Interesse): o processo de seleção da ROI envolve o recorte de uma janela de 20x20 pixels da região da testa, tanto da imagem visível quanto da imagem térmica, gerando assim duas novas imagens. Essas dimensões foram definidas para garantir um padrão da captura da região da testa em amostras de imagens de diferentes pessoas levando em consideração da possibilidade da presença de cabelo próximo da ROI.
  - c. Conversão da ROI da imagem visível de RGB para CIELab\*: Para ser capaz de perceber a oleosidade da pele, a ROI da imagem visível em RGB foi convertida para o espaço de cores CIELab\*. Esse espaço de cores é composto por informações de brilho, sendo muito útil nessa análise.
  - d. Extração de características da ROI (RGB térmico, RGB visível e CIELab\*): A extração de características da ROI envolve a extração dos valores das bandas RGB das ROIs térmicas e visíveis, e as bandas Lab da ROI CIELab\*. Além dos valores das bandas, a temperatura da ROI térmica também é calculada com base na distribuição de cores e nas especificações da câmera, realizando assim uma conversão direta, da mesma forma que é feita pelo software fornecido pela Minipa.

3. Redes Neurais: Este é o momento de organizar os dados para treinamento e validação da rede neural bem como avaliar os resultados preditos
  - a. Ajuste dos Parâmetros e Treinamento da Rede Neural: Primeiro passo a realizar é o ajuste dos hiperparâmetros da rede neural por meio de um modelo de regressão (mlpRegressor) disponível na biblioteca ScikitLearn para Python. Importante ressaltar que 80% das amostras disponíveis são usadas para o treino da Rede
  - b. Validação da Rede Neural: Logo após o treino, a rede é validada utilizando os outros 20% restantes do banco de imagens.
  - c. Avaliação do desempenho de predição da Rede Neural: Com os dados de temperatura real do termômetro de referência e os valores preditos pela rede, fazer análises de desempenho de predição avaliando se o houve redução do erro de medida em relação aos valores indicados pela câmera inicialmente

### 3.3 PROPRIEDADES DA IMAGEM

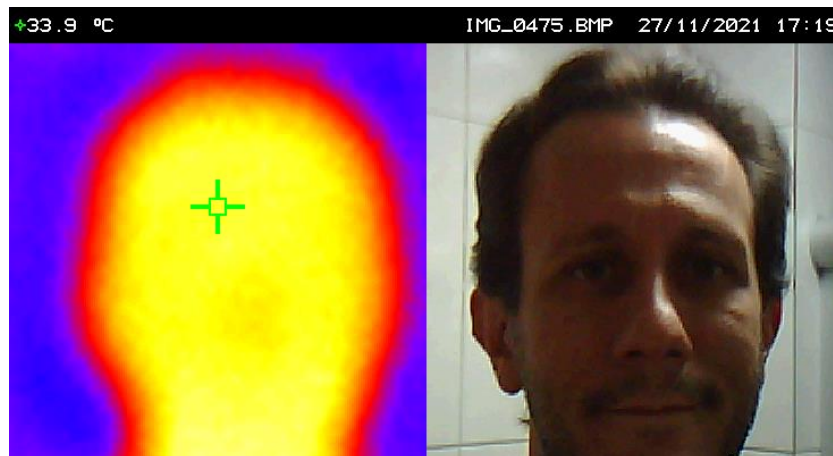
Para compreender as propriedades da imagem registrada pela câmera térmica, foram utilizados os conhecimentos de processamento de imagens apresentado por PEDRINI & SCHWARTZ (2008) combinados com as informações disponíveis no manual da câmera térmica.

#### 3.3.1 ARQUIVOS REGISTRADOS PELA CÂMERA

A câmera disponível para o estudo armazena os dados da imagem térmica e imagem visível em dois formatos de arquivos:

- Extensão .IR2 – Arquivo específico do software da câmera que possibilita acesso aos dados de Infravermelho capturados. Não foi possível acessar estes dados. Por este motivo, foi desenvolvido um código específico para determinar a temperatura a partir dos valores RGB dos pixels presentes na imagem térmica;
- Extensão .BMP – Arquivo com a imagem Infravermelha (IR) e imagem visível capturadas e dispostas lado-a-lado com detalhes da imagem na parte superior. A Figura 27 apresenta um exemplo da imagem contida neste arquivo.

Figura 27 - Exemplo da imagem .BMP capturada



Fonte: Autor

A tabela 4 apresenta as propriedades da imagem .BMP registrada pela câmera

Tabela 4 - Propriedades da imagem BMP da câmera Térmica

Propriedade	Valor
Dimensões	736 x 400
Largura	736 pixels
Altura	400 pixels
Intensidade de bits	24

Fonte: Manual de Instruções do produto (2011)

A imagem de formato BMP (*Bitmap* ou Mapa de bits) registrada pela câmera térmica consiste em uma matriz de 400 linhas de pixels distribuídos em 736 colunas por linha sendo que, cada pixel possui 3 bandas de 8 bits, o que resulta na intensidade de 24bits. Um bit tem a característica de reter apenas um dentre 2 possíveis valores (nível lógico 0 ou nível lógico 1), ou seja, é uma unidade binária e pode ser interpretada como um sistema numérico de base 2.


Então, uma banda de 8 bits pode reproduzir valores possíveis desde oito bits iguais a 00000000 até oito bits iguais a 11111111 em um sistema de base 2. Convertendo para o sistema de base 10 (mais facilmente assimilado pela cognição humana), temos valores possíveis desde 0 até 255. Para fazer esta conversão, basta calcular  $(2^n - 1)$ , onde  $n$  é o número de bits do sistema binário.

O hardware da câmera é composto por uma matriz de sensores capazes de fazer a conversão da radiação infravermelha proporcional à temperatura do corpo emissor em níveis de tensão analógicos. Estes níveis de tensão são interpretados por uma unidade de processamento que apresenta os valores de níveis de cinza das bandas RGB que melhor representam o nível de radiação incidente em cada sensor da matriz de sensores da câmera. Com esta premissa, é possível interpretar que os valores de entrada sejam valores numéricos inteiros de base decimal entre 0 e 255 atribuídos às bandas RGB.

Agora, também é possível incluir uma etapa de normalização, dividindo cada possível valor de nível de cinza (dentro do intervalo de 0 a 255) e obter uma escala de níveis de cinza com valores decimais entre 0 e 1 para cada uma das três bandas RGB

A figura 28 apresenta os gráficos das bandas R, G e B com seus respectivos níveis de cinza apresentados em uma faixa entre 0 e 255 no eixo das abcissas e os valores correspondentes na faixa entre 0 e 1 no eixo das ordenadas.

Figura 28 - Normalização dos níveis de cinza para as bandas RGB da imagem .BMP



Fonte: Autor


### 3.3.2 PALETA DE CORES DA IMAGEM TÉRMICA

A interface da câmera permite a escolha da paleta de cores da imagem infravermelha. A escala padrão da câmera denominada “cores metálicas” se mostrou adequada para o estudo porque apresenta a maior variedade de cores ao longo da escala bem como apresenta facilidade na percepção visual das regiões mais frias e mais quentes presentes na imagem térmica.

Temperaturas mais próximas do valor mínimo da escala são representados por níveis de cinza de RGB mais baixos (com valor mínimo na cor preta e valores iniciais mais baixos na banda B – azul).

Da mesma forma níveis de cinza de RGB mais altos correspondem aos maiores valores de temperatura da escala. A figura 29 apresenta a imagem da tela da câmera com a paleta de cores em ao lado da escala térmica da câmera.


Figura 29 - Interface da câmera – paleta “cores metálicas”



Fonte: Manual de Instruções do produto (2011)

Com o objetivo de estabelecer a relação numérica entre a escala térmica e a representação da temperatura por pseudo-cores, foi desenvolvido um código para estudar os detalhes das distribuições dos níveis de cinza das bandas RGB da paleta de cores. Com esse detalhamento é possível analisar o valor dos níveis de cinza das bandas RGB em função da temperatura dentro de uma faixa determinada, viabilizando estruturação da base de conhecimento necessária para realizar a medida da temperatura de maneira ponderando estas três bandas. A Figura 30 apresenta a paleta de cores separada em níveis de cinza para cada uma das bandas

Figura 30 - Escala em cores e separada por níveis de cinza das bandas RGB



Fonte: Autor


Os valores de nível de cinza das bandas RGB são compostos por números inteiros. O valor mais alto para o nível de cinza destas bandas é vinculado ao número 255 que corresponde à cor branca. Pela mesma lógica, o valor mais baixo para o nível de cinza destas mesmas bandas é vinculado ao número 0 que corresponde à cor preta. Os valores intermediários assumem níveis de cinza diferentes, avançando do 0 (mais escuro) para o 255 (mais claro).

Por meio deste raciocínio, a Banda R, na parte inferior da figura anterior, possui valores que iniciam em 0 (cor preta), atingindo seu valor máximo na metade da altura da imagem. Este é o momento em que é percebido aumento nos níveis de cinza da banda G, que atinge seu valor máximo um pouco antes do topo da imagem.

Observando a banda B, é possível notar um comportamento de oscilação, ou seja, os níveis de cinza aumentam, mantêm-se em um nível máximo, diminuem e tornam a subir novamente.

A Figura 31 apresenta o comportamento descrito dos níveis de cinza para cada uma das bandas na forma gráfica. O eixo das abcissas apresenta os valores de temperatura dentro do intervalo da escala de temperatura determinada. O eixo das ordenadas apresenta os valores de níveis de cinza normalizados, ou seja, a faixa de níveis de 0 a 255 passa a ser interpretada como uma faixa de números decimais de 0 a 1.

Figura 31 - Níveis de cinza para as bandas RGB da escala em cores




Fonte: Autor

Uma vez que já se tem a relação dos valores de RGB com a temperatura, também é importante identificar visualmente a região em que se está coletando os valores RGB para determinar o valor da temperatura. Para isto, foram criados dois cursores que identificam visualmente o pixel selecionado na imagem térmica bem como o pixel correspondente na imagem visível. Os cursores foram desenvolvidos para terem o posicionamento sincronizado entre as duas imagens (térmica e visível) além de serem movimentados de acordo com comandos do teclado, para viabilizar a navegação sobre os pixels das imagens.

A figura 32 apresenta o arquivo bitmap de teste que foi criado com as mesmas características da imagem produzida pela câmera térmica. Este arquivo foi criado para testar o posicionamento do cursor e coleta dos valores RGB em cada pixel da imagem.

Figura 32 - Imagem de teste para posicionamento de cursor e coleta de valores RGB



Fonte: Autor

A imagem de teste tem as mesmas características da imagem gerada pela câmera térmica, ou seja, é composta de dois quadros lado a lado de mesmas dimensões e uma faixa superior com dados gerais. A área retangular central dos dois quadros contempla a escala térmica da câmera. Dentro desta área central é que estará a região de interesse para se medir a temperatura. No entorno dos dois quadros, foi criado um *grid* que é utilizado para testar o sincronismo do posicionamento do cursor da imagem térmica (à esquerda) em relação à imagem visível (à direita).

A imagem de teste contempla dois quadros repetidos lado a lado porque, em uma imagem originalmente criada pela câmera, o quadro da esquerda contempla a imagem térmica e o quadro da direita contempla a imagem visível do arquivo. A abordagem desenvolvida separa os dois quadros em duas imagens (visível e térmica) e posiciona um cursor em cada uma delas para que seja possível a navegação e coleta dos valores RGB dos pixels da imagem térmica e indicação da localização do pixel selecionado na imagem visível.

### 3.4 EXTRAÇÃO DE TEMPERATURA DA IMAGEM

Para fazer a extração da temperatura a partir do valor RGB dos pixels presentes na imagem térmica, foram utilizados os conhecimentos de processamento de imagens apresentado por PEDRINI & SCHWARTZ (2008) combinados com as informações disponíveis no manual da câmera térmica e desenvolvendo abordagem computacional em linguagem Python com auxílio da biblioteca OpenCV.

#### 3.4.1 FUNÇÕES DE TEMPERATURA POR PSEUDO-CORES

As bandas RGB de um pixel podem assumir níveis de cinza com valores numéricos inteiros entre 0 e 255. Normalizando este intervalo de valores, é possível criar uma escala de 0 a 1 facilitando a interpretação percentual do nível de cinza de cada uma das bandas.

Observando o gráfico da figura 34, é possível interpretar a escala de temperatura da imagem térmica partindo da premissa de que a combinação dos níveis de cinza das bandas RGB de cada pixel da imagem representa um valor específico de temperatura que pode ser facilmente calculado por meio de funções de primeiro grau.

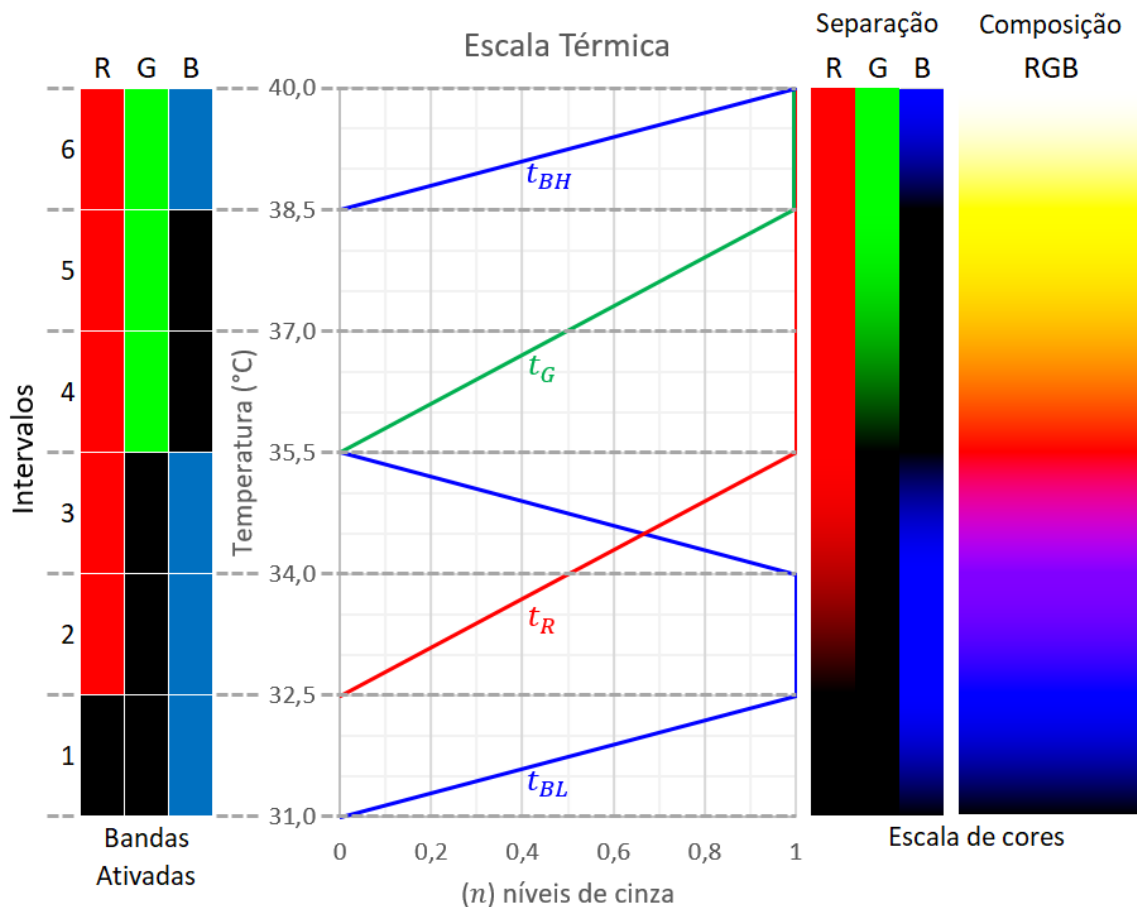
O menor valor da escala da imagem térmica corresponde a valores nulos de níveis de cinza das bandas RGB, ou seja, um pixel que tenha valores RGB iguais a 0 corresponde a um ponto preto na imagem térmica que representa o menor valor da escala térmica determinada.

Assim, valores de RGB próximos de zero estão próximos da cor preta e representam valores de temperatura próximos do valor mínimo da escala térmica. Pela mesma lógica valores de RGB maiores (próximos de 1) estão próximos da cor branca e representam valores de temperatura próximos do valor máximo da escala térmica.

Todo o intervalo da escala térmica abrange diversas combinações percentuais dos níveis de cinza das bandas RGB, compondo cores diferentes na imagem e, conseqüentemente, diferentes valores de temperatura.

A Figura 33 apresenta o gráfico da escala térmica entre 31°C e 40°C. À esquerda, 6 intervalos são caracterizados de acordo com as bandas ativadas (que possuem valores diferentes de zero). A cor preta indica que a banda em questão está desativada (possui valores iguais a zero). À direita está a decomposição das três bandas RGB com suas variações de níveis de cinza para cada temperatura correspondente bem como a composição das três bandas formando a escala térmica.

Figura 33 - Distribuição de níveis de cinza para cada banda RGB (escala de 31°C a 40°C)



Fonte: Autor

A análise do gráfico deve ser feita da seguinte maneira: Os valores de níveis de cinza RGB são interpretados como a variável de entrada no eixo horizontal. A composição dos valores de RGB resultam em uma cor correspondente à temperatura como variável de saída presente no eixo vertical. O Gráfico está dividido em seis intervalos. Os intervalos 1 e 6 serão usados para extrair as funções de primeiro grau associados aos níveis de cinza da banda B ( $t_{BL}$  e  $t_{BH}$ ). Pela mesma lógica, as funções associadas aos níveis de cinza das bandas R ( $t_R$ ) e G ( $t_G$ ) serão determinada a partir dos intervalos 3-4 e 5-6, respectivamente.

**Primeiro intervalo (31,0°C a 32,5°C)** – Somente a banda B está ativada (R=0 e G=0). Os Níveis de cinza das bandas vão de R=0, G=0 e B=0 até R=0, G=0 e B=1, sendo  $t_{BL}$  uma função crescente entre 0 e 1, iniciando em 31,0°C e atingindo seu valor máximo em 32,5°C. A extração da temperatura a partir do nível de cinza da banda B se dá pela função de primeiro grau a seguir:

$$t_{BL} = 31,0 + 1,5n_B \quad (11)$$

**Segundo intervalo (32,5°C a 34,0°C)** – Bandas R e B ativadas (G=0). Os níveis de cinza das bandas vão de R=0, G=0 e B=1 até R=0,5, G=0 e B=1, sendo a banda B apresentando nível de cinza constante em 1 e  $t_R$  uma função crescente entre 0 e 0,5, iniciando em 32,5°C e atingindo nível de cinza igual a 0,5 em 32,5°C. Como a o nível de cinza da banda B manteve valor constante em 1, não será possível utilizar essa banda para extração da temperatura em °C. Podemos observar que a função  $t_R$  é uma rampa crescente que percorre tanto o segundo quanto o terceiro intervalo. Portanto, a função de primeiro grau  $t_R$  será determinada depois da análise do terceiro intervalo.

**Terceiro intervalo (34°C a 35,5°C)** – Pode ser identificado como a continuação do segundo intervalo. Bandas R e B ativadas (G=0). Os níveis de cinza das bandas vão de R=0,5, G=0 e B=1 até R=1, G=0 e B=0, sendo que os níveis de cinza da Banda diminuem de 1 a 0 e a função  $t_R$  permanece crescente entre 0,5 e 1, iniciando em 34,0°C e atingindo seu valor máximo em 35,5°C. Apesar da banda B apresentar uma função decrescente neste intervalo, o que possibilitaria estabelecer uma função de primeiro grau para determinar a temperatura, é importante considerar que no intervalo anterior (segundo intervalo) a banda B permaneceu constante. Por outro lado, no

segundo e terceiro intervalo, a banda R apresentou comportamento de rampa crescente, viabilizando a determinação da temperatura a partir de uma única função de primeiro grau para ambos intervalos. A extração da temperatura a partir do nível de cinza da banda R, para o segundo e terceiro intervalos se dá pela função de primeiro grau a seguir:

$$t_R = 32,5 + 3n_R \quad (12)$$

**Quarto e Quinto intervalos (35,5°C a 38,5°C)** – Bandas R, G e B ativadas. Os níveis de cinza das bandas vão de R=1, G=0 e B=0 até R=1, G= 1 e B=0, sendo a banda R apresentando nível de cinza constante em 1 e  $t_G$  uma função crescente de 0 a 1 iniciando em 35,5°C e atingindo seu valor máximo em 38,5°C. A extração da temperatura a partir do nível de cinza da banda G, para o quarto e quinto intervalos se dá pela função de primeiro grau a seguir:

$$t_G = 35,5 + 3n_G \quad (13)$$

**Sexto intervalo (38,5°C a 40°C)** – Bandas R, G e B ativadas. Os níveis de cinza das bandas vão de R=1, G=1 e B=0 até R=1, G=1 e B=1, sendo as bandas R e G apresentando níveis de cinza constantes em 1 e  $t_{BH}$  uma função crescente de 0 a 1 iniciando em 38,5°C e atingindo seu valor máximo em 40°C. A extração da temperatura a partir do nível de cinza da banda B se dá pela função de primeiro grau a seguir:

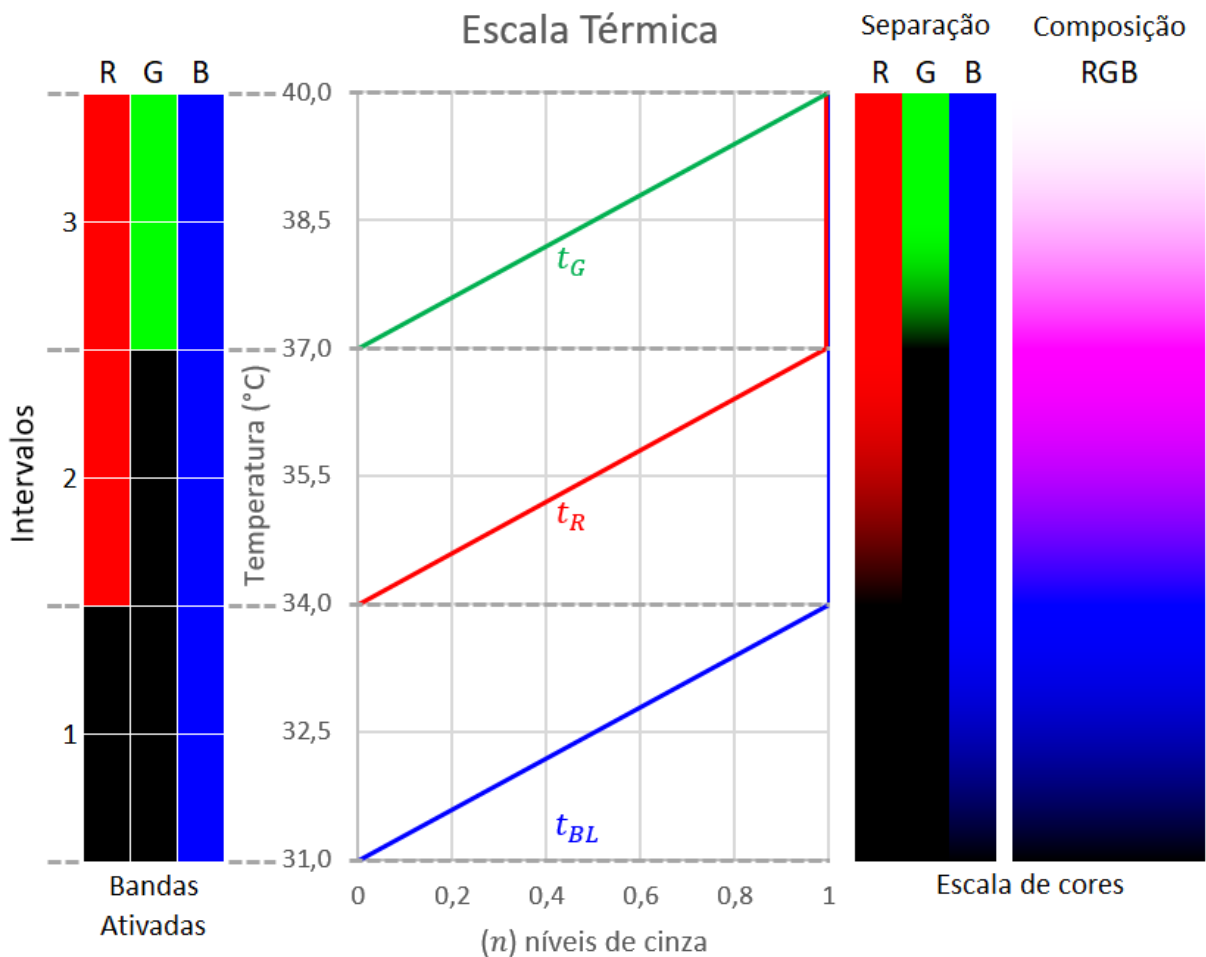
$$t_{BH} = 38,5 + 1,5n_B \quad (14)$$

Pela análise dos intervalos, é possível constatar que:

- O coeficiente angular das funções  $t_R$  e  $t_G$  ( $3n_R$  e  $3n_G$ ) correspondem ao dobro do coeficiente angular das funções  $t_{BL}$  e  $t_{BH}$  ( $1,5n_B$ );
- A banda B possui duas funções de primeiro grau. Uma no primeiro intervalo e outra no sexto intervalo. Por este motivo, é importante que a Banda B retorne a zero antes do sexto intervalo;
- A Banda B fica constante durante o segundo intervalo e se comporta como uma rampa decrescente no terceiro intervalo para produzir um efeito gradiente na composição RGB em relação à temperatura

As três características observadas são importantes para proporcionar o efeito gradiente com mais variações de composições RGB. A figura 34 apresenta um gráfico das funções das bandas RGB modificadas para se obter funções com o mesmo coeficiente angular espaçados uniformemente na escala de temperatura.

Figura 34 - Escala considerando mesmos coeficientes angulares para RGB



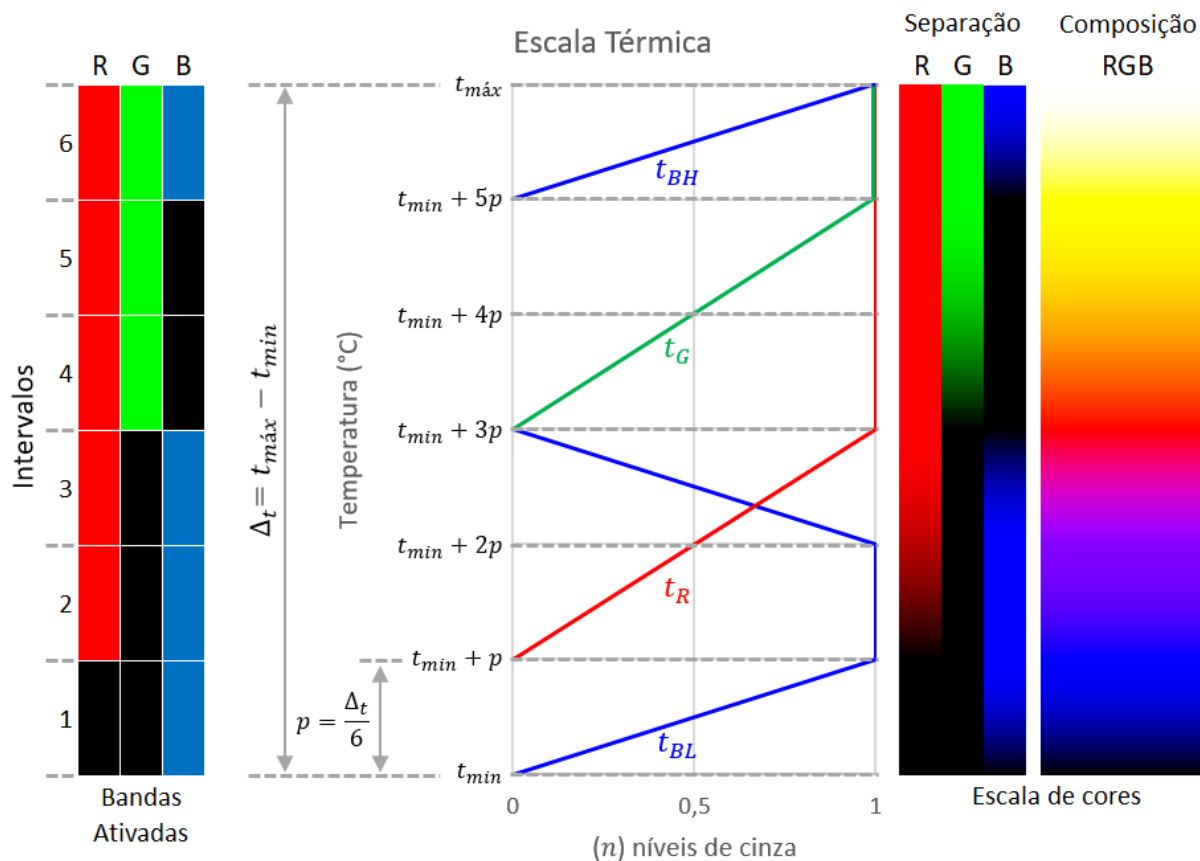
Fonte: Autor

É possível notar que, apesar de se obter um efeito gradiente, as combinações de cores ficaram restritas ao preto, azul, violeta e branco, diferentemente da escala da figura 33 que apresenta combinações que resultam em preto, azul, violeta, vermelho, laranja, amarelo e branco.

### 3.4.2 FUNÇÕES DE TEMPERATURA COM ESCALA VARIÁVEL

Uma vez caracterizadas as funções considerando escala fixa entre 31°C e 40°C, é possível apresentar na figura 35 o gráfico nos níveis de cinza das bandas RGB com escala variável de temperatura, viabilizando o ajuste das funções de a partir com os limites mínimo e máximo da escala térmica.

Figura 35 - Gráfico dos níveis de RGB com escala térmica variável



Fonte: Autor

Onde:

- $t_{min}$  → Limite inferior da escala térmica
- $t_{max}$  → Limite superior da escala térmica
- $\Delta_t$  → Intervalo da escala térmica
- $p$  → Passo da escala térmica

Observando no gráfico, temos funções da banda B com passo  $p$  e funções da banda R e G com passo  $2p$ . Uma vez que todas as funções são de primeiro grau com níveis de cinza variando entre 0 e 1, podemos generalizar funções para cada uma das bandas

Para todas as funções, podemos considerar o passo  $p$  como sendo a sexta fração da diferença entre os limites superior e inferior da escala térmica ( $\Delta_t$ ), ou seja:

$$p = \frac{\Delta_t}{6} = \frac{(t_{m\acute{a}x} - t_{m\acute{i}n})}{6} \quad (15)$$

Portanto, uma vez sabendo os limites mínimo e máximo da escala térmica, é possível determinar o passo que define os intervalos de temperatura das bandas RGB e, conseqüentemente, as temperaturas a partir das pseudo-cores.

#### 3.4.2.1 FUNÇÃO DE TEMPERATURA A PARTIR DA BANDA R

Considerando que a banda R apresenta função crescente com passo  $2p$  vinculados aos segundo e terceiro intervalos da escala (entre  $t_{min} + p$  e  $t_{min} + 3p$ ), temos:

$$t_R(n_R) = 2p * n_R + t_{min} + p \quad (16)$$

Onde:

- $t_R(n_R)$  → Função de temperatura a partir da banda R
- $n_R$  → Nível de cinza da banda R
- $p$  → Passo da escala térmica dado por (15)
- $t_{min}$  → Limite inferior da escala térmica
- $t_{m\acute{a}x}$  → Limite superior da escala térmica
- $\Delta_t$  → Intervalo da escala térmica

### 3.4.2.2 FUNÇÃO DE TEMPERATURA A PARTIR DA BANDA G

Considerando que a banda G apresenta função crescente com passo  $2p$  vinculados aos quarto e quinto intervalos da escala (entre  $t_{min} + 3p$  e  $t_{min} + 5p$ ), temos:

$$t_G(n_G) = 2p * n_G + t_{min} + 3p \quad (17)$$

Onde:

- $t_G(n_G)$  → Função de temperatura a partir da banda G
- $n_G$  → Nível de cinza da banda G
- $p$  → Passo da escala térmica dado por (15)
- $t_{min}$  → Limite inferior da escala térmica
- $t_{máx}$  → Limite superior da escala térmica
- $\Delta_t$  → Intervalo da escala térmica

### 3.4.2.3 FUNÇÕES DE TEMPERATURA A PARTIR DA BANDA B

Considerando que a banda B apresenta funções crescentes com passo  $p$  no primeiro e último intervalos da escala, temos:

Para o primeiro intervalo da escala (entre  $t_{min}$  e  $t_{min} + p$ ):

$$t_{BL}(n_B) = p * n_B + t_{min} \text{ e,} \quad (18)$$

Para o último intervalo da escala (entre  $t_{min} + 5p$  e  $t_{máx}$ ):

$$t_{BH}(n_B) = p * n_B + t_{min} + 5p \quad (19)$$

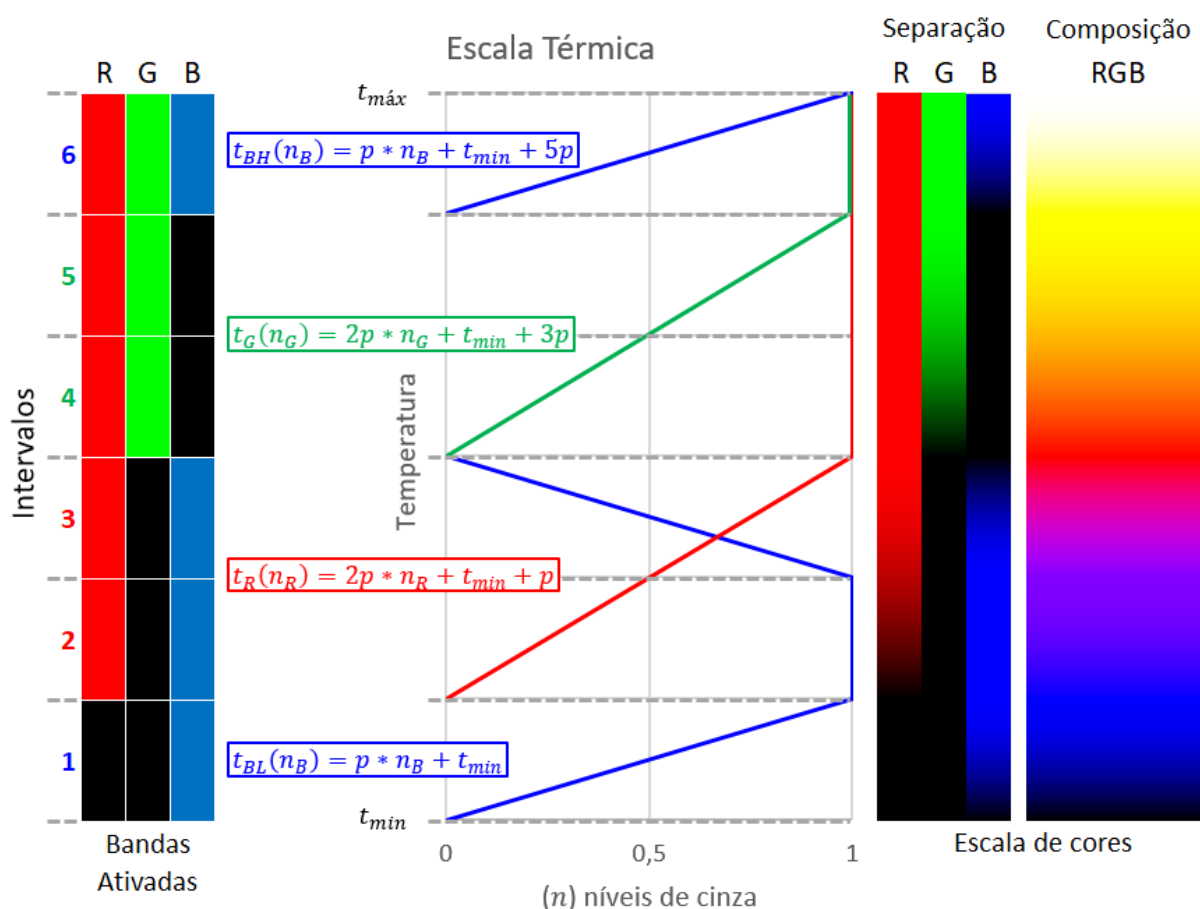
Onde:

- $t_{BL}(n_B)$  → Função de temperatura a partir da banda B do primeiro intervalo
- $t_{BH}(n_B)$  → Função de temperatura a partir da banda B do último intervalo
- $n_B$  → Nível de cinza da banda B
- $p$  → Passo da escala térmica dado por (15)
- $t_{min}$  → Limite inferior da escala térmica
- $t_{máx}$  → Limite superior da escala térmica
- $\Delta_t$  → Intervalo da escala térmica

### 3.4.3 TEMPERATURA EM FUNÇÃO DA COMPOSIÇÃO RGB DO PIXEL

A partir da composição RGB de um pixel, é possível determinar a temperatura correspondente a partir das funções apresentadas anteriormente dentro dos limites  $t_{min}$  e  $t_{máx}$  da escala térmica. A figura 36 apresenta o gráfico dos níveis de RGB em relação à escala térmica. Cada intervalo do gráfico possui uma função para determinar a temperatura a partir dos níveis de cinza das bandas RGB de qualquer pixel da imagem.

Figura 36 - Temperatura em função dos níveis de cinza RGB



Fonte: Autor

Onde:

- $t_R, t_G, t_{BL}, t_{BH}$  → Funções de temperatura a partir das bandas RGB
- $n_R, n_G, n_B$  → Níveis de cinza das bandas RGB do pixel
- $t_{min}$  → Limite inferior da escala térmica
- $t_{máx}$  → Limite superior da escala térmica
- $p$  → Passo da escala térmica dado por (15)

Com base nas funções do gráfico apresentado, é possível criar uma tabela denominada tabela de regras a partir da identificação booleana da ativação da banda relacionada, ou seja, no caso da Banda estar ativada, sua identificação assume o valor booleano Verdadeiro. Pela mesma lógica, uma banda está desativada quando sua identificação assume o valor booleano Falso.

A tabela 5 organiza os dados e informações a respeito das bandas que estão ativadas (V) ou desativadas (F), composição de cores, identificação do intervalo da escala térmica e cálculo correspondente. A tabela de regras é a referência para desenvolver o processo para calcular a temperatura a partir dos valores RGB da imagem térmica.

Tabela 5 - Tabela de Regras para cálculo da temperatura

R	G	B	Composição de cores	Número do intervalo na escala	Cálculo de temperatura
F	F	F	$n_{RGB} = (0,0,0)$	$t_{min}$	$t \leq t_{min}$
F	F	V	$0 \leq n_B \leq 1$	1	$t_{BL}(n_B) = p * n_B + t_{min}$ (18)
F	V	F	Não Aplicável	Não Aplicável	Não Aplicável
F	V	V	Não Aplicável	Não Aplicável	Não Aplicável
V	F	F	$n_R = 0$	$t_{min} + 3p$	$temp = t_{min} + 3p$
V	F	V	$0 \leq n_R \leq 1$	2 e 3	$t_R(n_R) = 2p * n_R + t_{min} + p$ (16)
V	V	F	$0 \leq n_G \leq 1$	4 e 5	$t_G(n_G) = 2p * n_G + t_{min} + 3p$ (17)
V	V	V	$0 \leq n_B \leq 1$	6	$t_{BH}(n_B) = p * n_B + t_{min} + 5p$ (19)

\*Observação: Ativação das cores R, G, B, sendo F = Falso e V = Verdadeiro

Onde:

- $t_R, t_G, t_{BL}, t_{BH}$  → Funções de temperatura a partir das bandas RGB
- $n_R, n_G, n_B$  → Níveis de cinza das bandas RGB do pixel
- $t_{min}$  → Limite inferior da escala térmica
- $t_{máx}$  → Limite superior da escala térmica
- $p$  → Passo da escala térmica dado por (15)

### 3.5 CORPO AQUECIDO COM TEMPERATURA CONTROLADA

Para estudar as configurações da câmera, é essencial ter um objeto com temperatura semelhante à do corpo humano devido à necessidade de múltiplas capturas de imagens e limitação de disponibilidade de pessoas para esta rotina.

Além disso, é importante considerar que a temperatura corporal das pessoas varia de acordo com o controle térmico de cada indivíduo. Essa variação individual adiciona complexidade ao estudo e exploração das configurações da câmera.

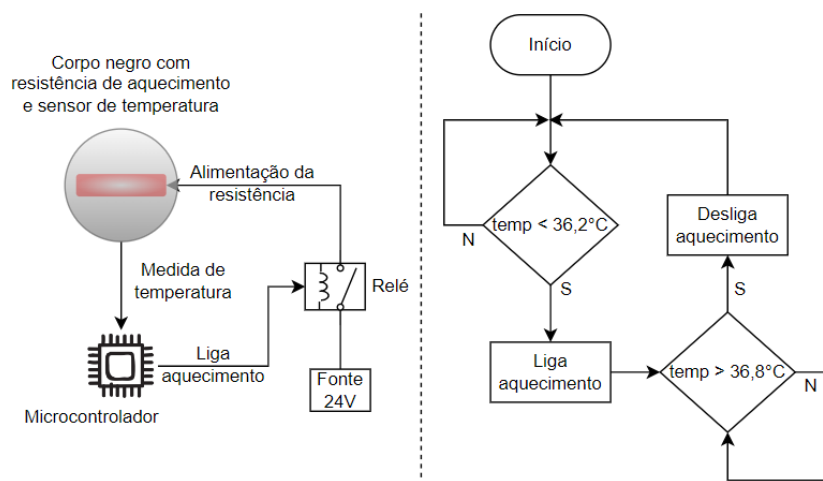
Rassels & French (2021) e HAMADA et. al. (2022) utilizaram corpos negros em estudos com termografia. Neste trabalho, foi desenvolvido um simulador de corpo aquecido, utilizando um corpo negro, com o objetivo de capturar imagens térmicas de um objeto com temperatura conhecida. Essa abordagem permitiu a criação de um cenário de teste controlado, possibilitando um melhor entendimento das configurações e características da câmera.

Para criar o simulador, foi construído um sistema de controle de aquecimento de um corpo negro para apresentar uma temperatura de referência pré-determinada, servindo de base para ajustar avaliar o comportamento da câmera.

O sistema de controle da temperatura aquece o corpo negro por meio de uma resistência de 20W cuja alimentação de 24V é controlada por um relé. A temperatura a ser controlada é medida por meio de um sensor NTC conectado à entrada analógica de um microcontrolador cuja saída digital controla o acionamento do relé de alimentação da resistência de aquecimento citada inicialmente.

A figura 37 apresenta o diagrama em blocos e o fluxograma do sistema de controle de temperatura concebido com valor de temperatura de controle entre 36,2°C e 36,8°C

Figura 37 - Diagrama em blocos e fluxograma – Controle de temperatura do corpo negro



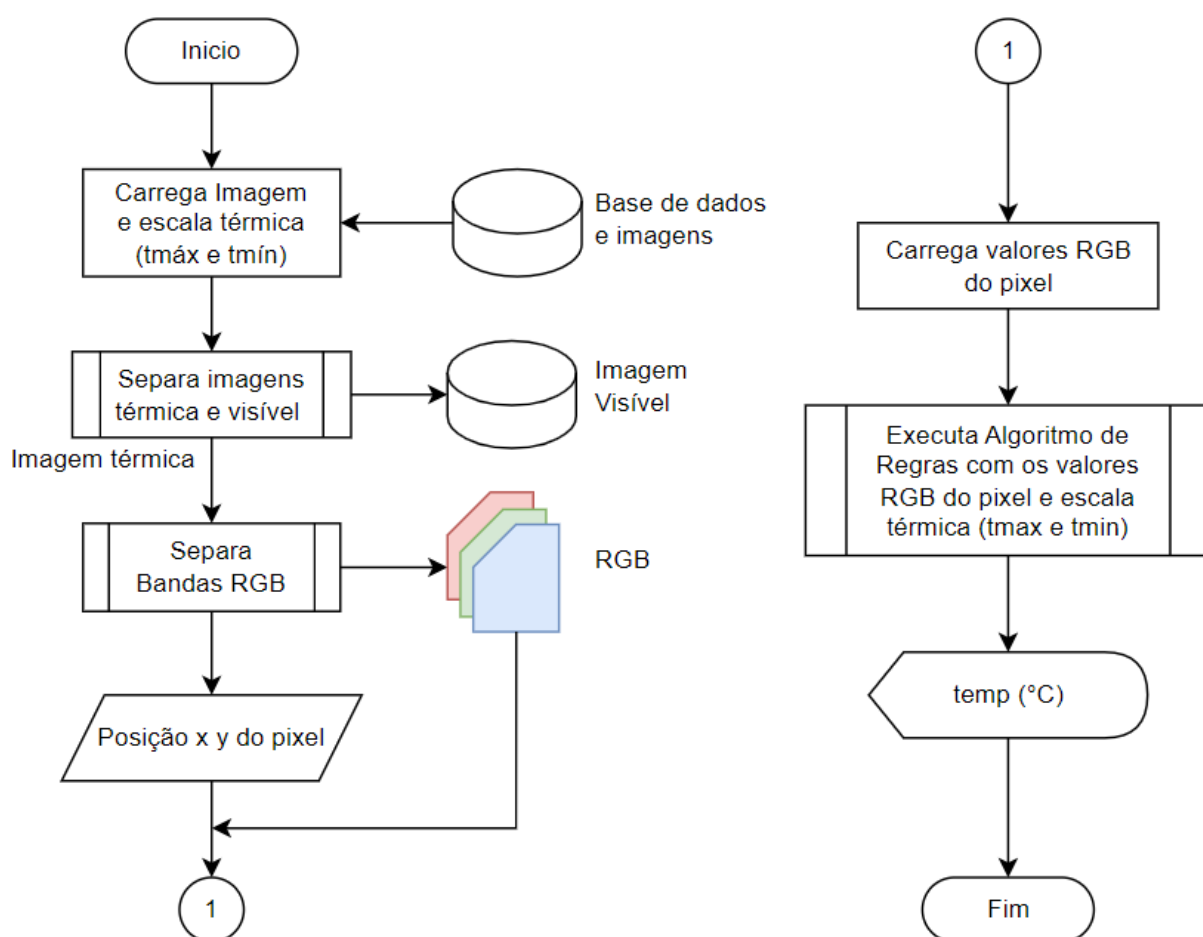
Fonte: Autor

### 3.6 DETERMINAÇÃO DE TEMPERATURA POR PSEUDO-CORES

Nesta etapa foi necessário desenvolver, também, um algoritmo que determina a temperatura usando uma função de primeiro grau escolhida de acordo com as bandas ativadas do pixel em questão.

A figura 38 apresenta o fluxograma da abordagem desenvolvida para coletar o valor RGB do pixel, identificar quais bandas estão ativadas para selecionar a função adequada que converta o valor RGB do pixel em valor numérico de temperatura em °C

Figura 38 - Fluxograma para a conversão do valor RGB do pixel em °C



Fonte: Autor

Com base na tabela de regras, é possível identificar quais bandas estão ativadas e selecionar a função mais adequada para calcular a temperatura em °C. O algoritmo de regras é apresentado a seguir:

## Algoritmo de regras

```
P ← (tmax – tmin) / 6
Se R > 2 então: Bin_R ← 1, senão: Bin_R ← 0
Se G > 2 então: Bin_G ← 1, senão: Bin_G ← 0
Se B > 2 então: Bin_B ← 1, senão: Bin_B ← 0
nR ← R / 255
nG ← G / 255
nB ← B / 255
Se (Bin_R = 0, Bin_G = 0 e Bin_B = 0) então: temp ← tmin
Se (Bin_R = 0, Bin_G = 0 e Bin_B = 1,) então: temp ← p * nB + tmin
Se (Bin_R = 1, Bin_G = 0 e Bin_B = 0) então: temp ← tmin + 3p
Se (Bin_R = 1, Bin_G = 0 e Bin_B = 1) então: temp ← 2p * nR + tmin + p
Se (Bin_R = 1, Bin_G = 1 e Bin_B = 0) então: temp ← 2p * nG + tmin + 3p
Se (Bin_B = 1, Bin_R = 1 e Bin_G = 1) então: temp ← p * nB + tmin + 5p
```

Fonte: Autor

### Observações:

- Bin\_R, Bin\_G e Bin\_B → bandas ativadas (1) ou desativadas (0)
- tmin e tmax → limites da escala térmica
- p → 1/6 da escala térmica, ou seja: (tmax – tmin) / 6
- nR, nG, nB → níveis de cinza do pixel normalizados para valores decimais entre 0,0 e 1,0

## 3.7 BANCO DE IMAGENS


Para buscar formas de corrigir o erro de medida de temperatura da câmera, foi necessário aumentar a quantidade de amostras de imagens. Nesse contexto, uma empresa especializada em neonatologia gentilmente colaborou com o estudo, cedendo equipamentos, dados de temperatura e imagens térmicas.

Foram cedidas 448 imagens com o registro da temperatura de referência, tanto antes quanto depois da captura da imagem. Além disso, a base de dados também contempla registros da temperatura após a limpeza dos seios da face com papel toalha, seguido de uma nova captura de imagem (também com o registro da temperatura de referência antes e depois da captura).

A temperatura de referência foi coletada usando um termômetro de contato independente

A figura 39 apresenta o gráfico com os dados de temperatura de referência disponibilizados, bem como os valores de temperatura medidos pela câmera


Figura 39 - Temperatura das amostras de imagens



Fonte: Autor

A figura 40 apresenta o gráfico com os erros de medida de temperatura da câmera em relação à medida de referência (coletada por meio de um termômetro de contato)

Figura 40 - Erro de medida de temperatura das amostras de imagens



Fonte: Autor

Com base nos gráficos, é possível observar a necessidade de reduzir o erro de medição da câmera térmica, uma vez que todos os valores estão apresentando erros acima de  $2,0^{\circ}\text{C}$ , excedendo o limite de precisão estabelecido pela norma de berços aquecidos ( $\pm 0,3^{\circ}\text{C}$ ).

### 3.8 CORREÇÃO DE MEDIDA DE TEMPERATURA POR REDE NEURAL

Como já indicado anteriormente, a norma ABNT NBR IEC 60601-2-21 de berços aquecidos preconiza um erro de medida de temperatura menor ou igual a  $0,3^{\circ}\text{C}$ , o que nos direciona a buscar uma forma de melhorar a precisão da medida de temperatura, visto que o método por pseudo-cores é limitado pelas características de hardware da câmera térmica.

A medição de temperatura por meio do algoritmo de pseudo-cores considera apenas as bandas RGB da imagem térmica, o que pode resultar em limitações na exatidão da medida.

Para buscar melhorias nesse aspecto, foi levantada a oportunidade de se usar Redes Neurais Artificiais para aproveitar todas as informações disponíveis de cada imagem, como a imagem térmica em suas bandas RGB, a imagem visível em espaço de cores RGB e CIELab\*, o valor medido por meio do algoritmo de pseudo-cores e a medida de temperatura de referência (realizada por meio do termômetro de contato).

Analisando os artigos apresentados na Tabela 1, que lista as publicações mais pertinentes ao tema na seção 1.2 - Revisão de Literatura, percebe-se a ausência de estudos que explorem uso da abordagem com RNAs na redução do erro de medida de temperatura por termografia infravermelha em recém-nascidos, incorporando informações da imagem visível como entrada da rede neural.

Utilizar Redes Neurais Artificiais se apresenta como uma solução promissora, uma vez que apresenta a capacidade de prever valores de temperatura considerando variáveis que vão além das bandas RGB da imagem térmica (único parâmetro usado pela câmera disponível para o estudo).

Uma Rede Neural pode ser treinada com um conjunto relevante de amostras de dados de treinamento, em que os pesos sinápticos são ajustados durante este treinamento para melhorar a exatidão das medidas com base em entradas como os níveis RGB da imagem térmica, níveis RGB e CIELab\* da imagem visível, valor de temperatura encontrado pelo algoritmo de pseudo-cores e valor de saída de temperatura de referência.

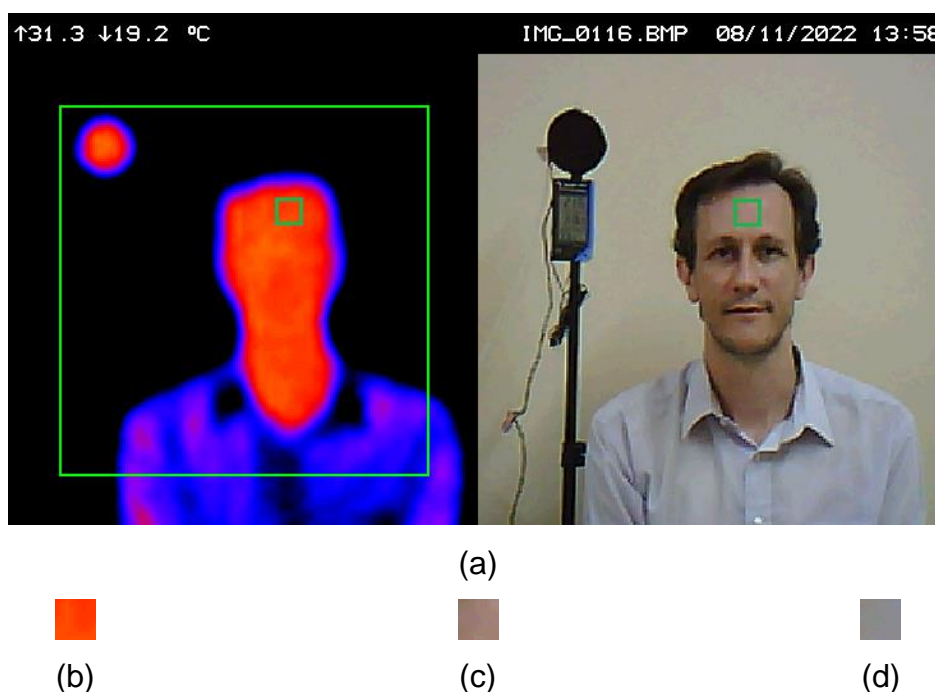
Para validar se uma rede neural seria capaz de prever os valores de temperatura com base nas imagens térmicas, foram extraídas características destas imagens. Foram realizados recortes com dimensões de  $20 \times 20$  pixels da região da testa nas imagens coletadas, tal região foi definida como Região de Interesse (ROI),

pois nesta região foram aferidas as temperaturas com o termômetro digital. Contudo, vale ressaltar que o ponto central da ROI deveria ter sido analisado um ponto de máximo, maximizando assim a resposta área, uma vez que em todos os casos o valor da imagem térmica a temperatura é em torno de 5°C abaixo da temperatura real.

A Figura 41 apresenta um exemplo de uma imagem com a delimitação da ROI e suas 3 sub-imagens, sendo a primeira a térmica em RGB, a segunda a imagem visível em RGB e a última, a imagem visível no espaço de cores CIELab\*.

Figura 41 - Exemplo de uma imagem com as ROIs selecionadas

Imagem original, (b) ROI térmica, (c) ROI Visível RGB e (d) ROI Visível CIELab



Fonte: Autor

É importante lembrar que as dimensões de 20x20 pixels da ROI foram definidas para garantir um padrão da captura da região da testa em amostras de imagens de diferentes pessoas levando em consideração da possibilidade da presença de cabelo próximo da ROI.

Uma vez delimitadas as ROIs, foram extraídas informações dos valores de cores médios dos pixels para a imagem térmica bem como para a imagem visível em RGB. Para aumentar as características a serem utilizadas como entrada para a RNA, a imagem visível em RGB foi convertida para o espaço de cores CIELab, onde é possível extrair informações de luminosidade, por exemplo.

Como entrada para o treinamento e validação da RNA proposta foram apresentados vetores contendo os valores médios para as três ROIs identificadas acima e, também, a informação da temperatura calculada pelo algoritmo de pseudo-cores, totalizando dez elementos no vetor de entrada. Por fim, como rótulo de saída para o treinamento da RNA, foram atribuídos os valores de temperatura medidos com o termômetro de referência.

A estrutura inicial da RNA utilizada para este experimento é uma rede percéptron de múltiplas camadas, com 10 entradas, uma camada oculta com 30 neurônios e 1 neurônio na camada de saída. O algoritmo de treinamento é o back-propagation implementado na biblioteca em Python scikit-learn. Essa estrutura foi definida para trazer flexibilidade de aprendizado no contexto de um problema de regressão. A abordagem com Redes Neurais consegue relacionar a complexidade entre as variáveis de entrada para prever o valor de temperatura corrigido na saída da rede. Essa parametrização com uma única camada também apresenta melhor eficiência computacional por ser uma arquitetura mais simplificada.

Posteriormente uma nova RNA foi estruturada usando a função GridSearch da biblioteca Scikit-learn. Por meio dessa função, é possível automatizar o processo de busca de hiperparâmetros, economizando esforço manual na busca de melhores hiperparâmetros.

A base de dados para o treinamento da RNA foi estruturada de acordo com o modelo apresentado pela tabela 6.

Tabela 6 - Modelo da estrutura da base de dados

Imagem Térmica (RGB)			Imagem Visível (RGB)			Imagem Visível (CIELab*)			Temperatura (°C)	
B	G	R	B	G	R	L	a	b	Câmera	Referência

As nove primeiras colunas da base de dados são valores inteiros, enquanto que as duas últimas colunas são valores reais com uma casa decimal de precisão. Essas colunas representam as informações necessárias para a RNA. Os dados RGB da imagem térmica, os dados RGB e Lab\* da imagem visível e o valor numérico da temperatura obtido por meio do algoritmo de pseudo-cores são usados como entradas da RNA

A temperatura de referência, presente na última coluna da base de dados, é usada para o cálculo do erro entre a temperatura predita pela RNA e a temperatura de referência, possibilitando o ajuste dos pesos sinápticos durante o treinamento, cujo objetivo é de melhorar a precisão das predições da rede. Além disso, a temperatura de referência também é usada para a validação da RNA, possibilitando a avaliação do desempenho de predição da rede.

Com a avaliação do desempenho da rede, é possível ajustar novos hiperparâmetros, repetindo o processo de treinamento e validação com o objetivo de se obter predições cada vez melhores.

Com o intuito de explorar abordagens com RNAs para avaliar o desempenho na redução do erro de medida de temperatura, foram estruturadas duas RNAs com 4 e 7 entradas.

A RNA com 4 entradas considera apenas os valores RGB da imagem térmica e a temperatura calculada pelo algoritmo de pseudo-cores. A outra RNA com 7 entradas considera, além dos valores RGB da imagem térmica e a temperatura calculada pelo algoritmo de pseudo-cores, também contempla os valores RGB da imagem visível. Essas duas configurações de RNAs foram escolhidas para analisar o impacto da inclusão de informações presentes na imagem visível na redução do erro de medida de temperatura.

Dessa forma, podemos avaliar a contribuição do uso de RNAs na redução do erro de temperatura considerando as seguintes abordagens:

1. RNA com 4 entradas: RGB da imagem térmica e temperatura da câmera
2. RNA com 7 entradas: Inclusão dos valores RGB da imagem visível
3. RNA com 10 entradas: Inclusão dos valores Lab da imagem visível
4. RNA com 10 entradas: Uso da função GridSearch para automatizar a busca de hiperparâmetros

Com o intuito de estabelecer comparativo entre as abordagens com 4 entradas, 7 entradas e 10 entradas, a arquitetura da rede permanecerá com 30 neurônios em uma única camada oculta, alterando-se somente as entradas.

## 4. RESULTADOS E DISCUSSÃO

### 4.1 ALGORITMO DE PSEUDO-CORES

Como não foi possível acessar diretamente os dados de temperatura câmera, um código em Python foi desenvolvido utilizando a biblioteca OpenCV para extrair a temperatura da imagem térmica no formato BMP. O código separa a imagem térmica da imagem visível, permite posicionar um cursor em qualquer região da imagem térmica, exibindo um cursor correspondente na imagem visível e apresenta as coordenadas dos cursores nas imagens, bem como os níveis de cinza das bandas RGB onde o cursor está posicionado e a temperatura calculada pelo algoritmo de pseudo-cores.

#### 4.1.1 TESTES INICIAIS EXPLORATÓRIOS


O primeiro teste foi realizado com duas imagens capturadas de uma criança de 3 anos e 10 meses em que foram registradas as temperaturas dos pés, mãos, testa e tórax. O menor erro de medição encontrado foi de  $-1,1^{\circ}\text{C}$  na região da testa, enquanto o menor erro nas demais regiões foi de  $-1,9^{\circ}\text{C}$ . Esse resultado sugere que a região da testa é a mais adequada para obter leituras com menor erro.

No segundo teste realizado com um bebê de 1 mês e 23 dias, foram coletadas seis amostras de imagem e realizadas duas medidas de temperatura (antes e depois das capturas de imagem). Com o foco ajustado para uma distância de 1m, observou-se um erro mínimo de  $-0,8^{\circ}\text{C}$  e um erro máximo de  $-1,1^{\circ}\text{C}$  na região da testa.

Apesar da identificação da região da testa como sendo a região de menor erro para a medida de temperatura, este erro ainda se apresenta maior que  $\pm 0,3^{\circ}\text{C}$ .

Observando as imagens térmicas capturadas nos testes iniciais, identificamos que as bandas R e B estão ativadas enquanto a banda G apresenta pouca ou nenhuma presença. Isso pode causar problemas de resolução da imagem térmica, uma vez que a metade da escala de cores não está sendo utilizada. Na Figura 42, que apresenta as imagens obtidas nessa etapa do estudo, nota-se a presença somente das cores azul, vermelha e suas combinações. Não é possível identificar pixels com cores laranja, amarela ou branca, indicando a falta de ativação da banda G.

Figura 42 - Imagens térmicas de Crianças (3a10m e 1m23d)




#### 4.1.2 MEDIDAS EM BERÇO AQUECIDO

Continuando com os testes, foi realizado um experimento com corpos negros em um berço aquecido com o intuito de simular a situação de captura de imagem em uma UTI neonatal. Cinco corpos negros foram distribuídos sobre o leito do berço aquecido com sua fonte de calor energizada para elevar a temperatura destes corpos. Os sensores de temperatura T1 e T2 do equipamento foram posicionados em dois dos cinco corpos negros para realizar as medições.

A Figura 43 apresenta algumas fotos do teste, cujos resultados estão apresentados na Tabela 7. Diferentes configurações foram consideradas, incluindo ajuste de foco, emissividade, e faixa de escala, além do tempo de espera para estabilização da temperatura dos corpos negros

Figura 43 - Imagem térmica de corpos negros sobre o leito de berço aquecido



Fonte: Autor

Tabela 7 - Teste com corpos negros em berço aquecido


Sensor T1 (corpo negro central) (°C)			Sensor T2 (corpo negro acima e à direita) (°C)		
Berço	Algoritmo	Erro	Berço	Algoritmo	Erro
35,9	35,9	0,0	36,6	36,7	0,1
35,7	36	0,3	36,6	36,8	0,2
36,5	36,8	0,3	36,4	36,9	0,5
36,5	36,6	0,1	36,4	36,9	0,5
36,2	36,1	-0,1	36,0	36,2	0,2
36,1	36,5	0,4	36,0	36,5	0,5
36,1	36,3	0,2	36,0	36,5	0,5
35,2	35,6	0,4	35,2	35,5	0,3
35,1	35,4	0,3	35,0	35,1	0,1
35,0	35,4	0,4	35,2	35,1	-0,1

Os resultados do experimento com o berço aquecido sugerem que a radiação infravermelha proveniente do equipamento não interfere na medição da temperatura pela câmera térmica.

#### 4.1.3 ERRO DE MEDIDA DE TEMPERATURA


Continuando com o estudo, para entender melhor o desempenho da câmera térmica, foram realizados testes adicionais em que foi observado um erro de *offset* entre o valor do termômetro de referência e a medida pela imagem térmica. Esta situação é percebida visualmente observando a imagem 44, que apresenta uma sequência de imagens térmicas capturadas ao longo de uma hora. O gráfico da figura 45 revelou uma tendência de aumento desse erro a cada amostra de imagem capturada.

Figura 44 - Faces de pessoas - erro de medida de temperatura aumenta com o tempo



Fonte: Autor

Figura 45 - Tendência de aumento de erro da câmera térmica



Fonte: Autor

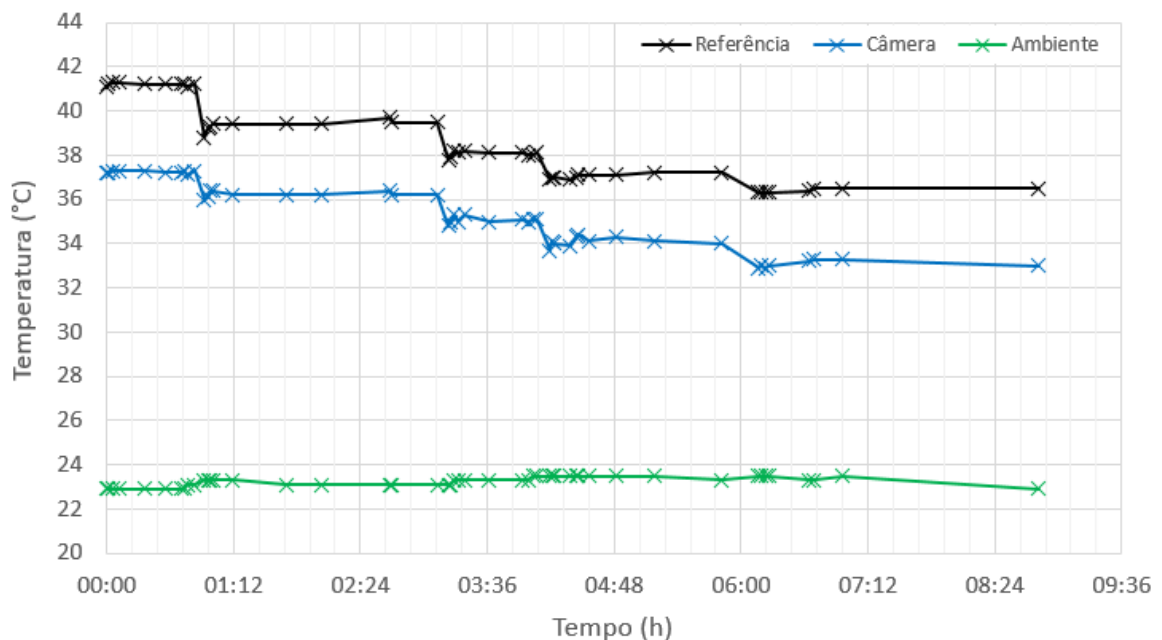
Na Tabela 8, podemos observar grande discrepância entre o valor da câmera e o valor de referência, que variam de -4,4 a 6,0°C. Então, para aprimorar a compreensão do erro e do desempenho da câmera, um estudo foi iniciado utilizando um corpo negro aquecido de temperatura controlada. Nesse breve estudo, foram ajustados valores de temperatura no corpo negro e coletadas medidas de temperatura tanto pelo termômetro de referência quanto pela câmera. O gráfico da figura 46 apresenta a diferença entre as duas medidas em diferentes temperaturas ajustadas no corpo negro

Tabela 8 - Erro entre temperatura de referência e temperatura medida pela câmera térmica

Temperatura de referência (°C)	Temperatura da Câmera (°C)	Erro entre as medidas (°C)
36,2	31,8	-4,4
36,3	31,1	-5,2
36,4	31,2	-5,2
36,5	30,9	-5,6
36,6	30,6	-6,0
36,7	30,7	-6,0
36,8	31,3	-5,5

Fonte: Autor

Figura 46 - Diferença de temperatura indicada (câmera térmica e termômetro de referência)




Fonte: Autor

O gráfico acima sugere que o erro de medida pela câmera térmica pode ser corrigido. Diante dessa possibilidade, novas imagens foram capturadas e a temperatura foi corrigida com base na temperatura controlada do corpo negro.

#### 4.1.4 CORREÇÃO DE ERRO DE *OFFSET*

A Figura 47 apresenta essas imagens térmicas capturadas já com a presença do corpo negro na imagem. Na parte inferior de cada imagem são apresentadas as temperaturas do termômetro de referência da imagem térmica corrigida.

Figura 47 - Imagens térmicas – temperaturas corrigidas com base no corpo negro



Fonte: Autor

A Tabela 9 apresenta as temperaturas de referência, sem correção e com correção

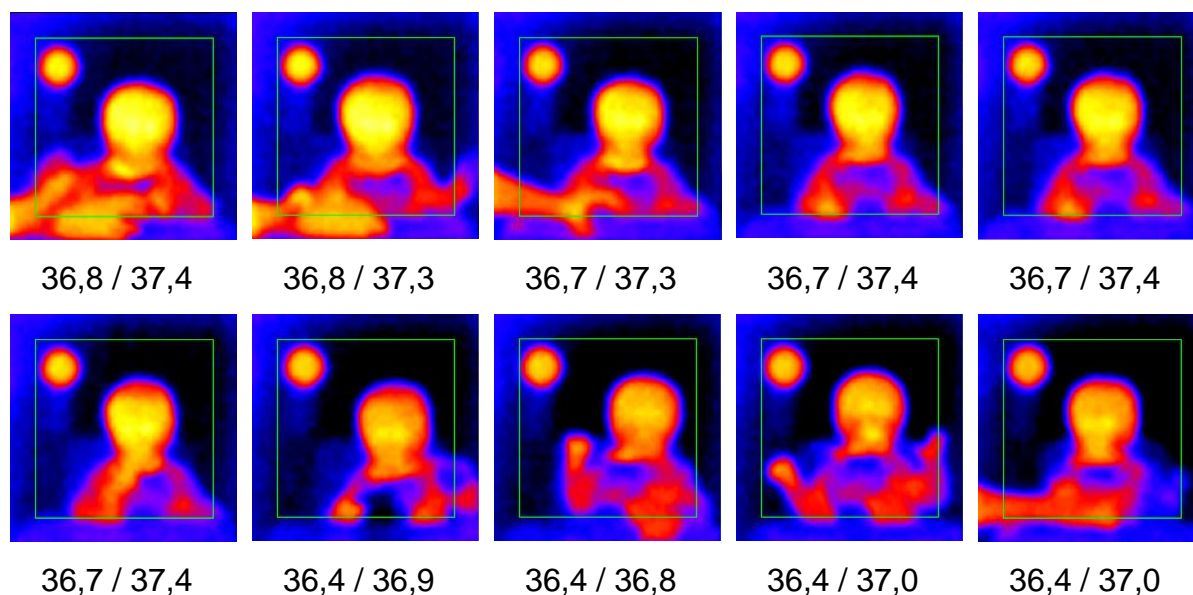
Tabela 9 - Resultado da correção a partir da temperatura do corpo negro

Referência	Temperatura (°C)			
	Sem correção		Com correção	
	Imagem	Erro	Imagem	Erro
36,8	31,1	-5,7	36,5	-0,3
36,3	29,9	-6,4	35,5	-0,8
36,1	29,8	-6,3	35,5	-0,6
35,8	29,2	-6,6	35,3	-0,5
36,2	30,1	-6,1	36,1	-0,1
35,9	29,3	-6,6	35,3	-0,6
36,2	29,4	-6,8	35,4	-0,8
36,0	30,2	-5,8	35,7	-0,3
36,3	30,3	-6,0	35,8	-0,5
36,6	30,6	-6,0	36,1	-0,5

Fonte: Autor

Da mesma forma, a figura 48 apresenta imagens térmicas de bebê, também com o corpo negro na imagem.

Figura 48 - Imagens térmicas de bebê – temperaturas corrigidas com base no corpo negro



Fonte: Autor


A Tabela 10 apresenta as temperaturas de referência, sem correção e corrigida e a figura 49 apresenta estes dados na forma gráfica.

Tabela 10 - Resultado da correção a partir da temperatura do corpo negro

Referência	Temperatura (°C)			
	Sem correção		Com correção	
	Imagem	Erro	Imagem	Erro
36,8	34,7	-2,1	37,4	0,6
36,8	34,7	-2,1	37,3	0,5
36,7	34,2	-2,5	37,3	0,6
36,7	34,2	-2,5	37,4	0,7
36,7	34,2	-2,5	37,4	0,7
36,7	34,2	-2,5	37,4	0,7
36,4	33,5	-2,9	36,9	0,5
36,4	33,2	-3,2	36,8	0,4
36,4	33,4	-3,0	37,0	0,6
36,4	33,2	-3,2	37,0	0,6

Fonte: Autor

Figura 49 - Medidas de temperatura (com correção, referência e sem correção)



Fonte: Autor

Apesar de observarmos um crescente e elevado erro de medida da câmera térmica em relação ao termômetro de referência em função do tempo, este erro tende a se estabilizar e, assim pode ser corrigido.

Os testes realizados até o momento foram conduzidos para conhecer o desempenho da câmera térmica, suas limitações e validar a possibilidade de melhorar esse desempenho, abrindo caminho para o uso de técnicas mais avançadas de correção, como redes neurais artificiais.

A adoção de redes neurais pode permitir uma correção ainda mais precisa, considerando outros fatores presentes na imagem térmica e sem a necessidade de se introduzir um corpo negro aquecido na imagem. Desta maneira é justificável utilizar técnicas de redes neurais artificiais para a correção da medida de temperatura, uma vez que a validação da correção aplicada com o corpo negro aquecido apresentou resultados promissores.

## 4.1 CORREÇÃO DA MEDIDA DE TEMPERATURA POR REDES NEURAIS


O uso de redes neurais artificiais, permite incorporar aspectos da imagem visível que não foram considerados até então, como os níveis de cinza das bandas RGB e os valores CIE Lab\* da imagem visível, trazendo oportunidade de ir além dos dados da imagem térmica.

A base de dados do banco de imagens possui 460 amostras que contemplam os valores RGB das imagens térmicas, valores RGB das imagens visíveis, valores CIE Lab\* das imagens visíveis, temperaturas medidas pelo algoritmo de pseudo-cores e temperaturas medidas com o termômetro de referência. Todos estes valores são referentes à área de 20x20 pixels na região da testa.

Os treinamentos de todas as RNAs foram realizados com 80% das amostras da base de dados resultando em 367 amostras para treino. Os 20% restantes equivalem a 92 amostras e foram utilizados para a validação das respectivas RNAs.

### 4.1.1 REDE NEURAL COM 4 ENTRADAS


A Figura 50 apresenta o desempenho de predição de uma RNA com 4 entradas, camada oculta com 30 neurônios e um neurônio na camada de saída. As entradas da rede são compostas por valores RGB da imagem térmica e a temperatura medida da câmera pelo algoritmo de pseudo-cores.



Fonte: Autor

A figura 51 apresenta o gráfico com os erros de medida de temperatura corrigidas com base nos valores preditos da RNA

Figura 51 - Erro de predição da temperatura pela RNA



Fonte: Autor

Dentre as amostras de validação, a configuração com 4 entradas apresentou erro médio de  $-0,13^{\circ}\text{C}$ . O gráfico demonstra uma tendência de acompanhar as temperaturas reais com valores de erro na faixa entre  $-0,9^{\circ}\text{C}$  e  $+0,9^{\circ}\text{C}$ .


Os gráficos indicam que, apesar da proximidade entre o valor real e predito pela RNA trazendo a melhora significativa na exatidão da medida. Das 92 amostras, 37 pontos apresentaram erros além do limite de  $\pm 0,3^{\circ}\text{C}$ , que é o limite de tolerância estabelecido pela norma de berços aquecidos.

Como resultado de desempenho, a RNA apresentou um coeficiente de regressão com valor negativo de  $-0,43$ , indicando baixa capacidade de predição da rede e um erro médio quadrático de  $9,68\text{e-}5$ . Tais valores são usados como valores de referência para comparação com as RNAs apresentadas a seguir

#### 4.1.2 REDE NEURAL COM 7 ENTRADAS

A Figura 52 apresenta o desempenho de predição de uma RNA com 7 entradas, camada oculta com 30 neurônios e um neurônio na camada de saída. As entradas da rede são compostas por valores RGB da imagem térmica, valores RGB da imagem visível e a temperatura medida da câmera pelo algoritmo de pseudo-cores.


Figura 52 - Valor real x Predição da RNA de 7 entradas



Fonte: Autor

A figura 53 apresenta o gráfico com os erros de medida de temperatura corrigidas com base nos valores preditos da RNA

Figura 53 - Erro de predição da temperatura pela RNA



Fonte: Autor

Dentre as amostras de validação, a configuração com 7 entradas apresentou erro médio de  $-0,08^{\circ}\text{C}$ . O gráfico demonstra uma tendência de acompanhar as temperaturas reais com valores de erro na faixa entre  $-1,3^{\circ}\text{C}$  e  $+0,9^{\circ}\text{C}$ .


Os gráficos indicam que, apesar de um ponto ter apresentado erro maior em comparação com a rede de 4 entradas, os demais valores apresentam maior proximidade entre o valor real e predito pela RNA indicando sutil melhora na exatidão da medida. Das 92 amostras, 25 pontos apresentaram erros além do limite de  $\pm 0,3^{\circ}\text{C}$ , que é o limite de tolerância estabelecido pela norma de berços aquecidos.

Como resultado de desempenho, a RNA continua apresentando um coeficiente de regressão com valor negativo de  $-0,38$ , indicando melhora em relação à rede com 4 entradas, mas ainda com baixa capacidade de predição. O erro médio quadrático de  $8,25\text{e-}5$  também indica sutil melhora na capacidade de predição da rede.

#### 4.1.3 REDE NEURAL COM 10 ENTRADAS

A Figura 54 apresenta o desempenho de predição de uma RNA com 10 entradas, camada oculta com 30 neurônios e um neurônio na camada de saída. As entradas da rede são compostas por valores RGB da imagem térmica, valores RGB da imagem visível, valores CIE Lab\* da imagem visível e a temperatura medida da câmera pelo algoritmo de pseudo-cores.


Figura 54 - Valor real x Predição da RNA com 10 entradas



Fonte: Autor

A figura 55 apresenta o gráfico com os erros de medida de temperatura corrigidas com base nos valores preditos da RNA

Figura 55 - Erro de predição da temperatura pela RNA



Fonte: Autor

Dentre as amostras de validação, a configuração com 10 entradas apresentou erro médio de  $-0,1^{\circ}\text{C}$ . O gráfico demonstra uma tendência de acompanhar as temperaturas reais com valores de erro na faixa entre  $-1,3^{\circ}\text{C}$  e  $+0,8^{\circ}\text{C}$ .


Os gráficos indicam que, apesar de um ponto ter apresentado erro maior em comparação com a rede de 4 entradas, os demais valores apresentam maior proximidade entre o valor real e predito pela RNA indicando sutil melhora na exatidão da medida. Das 92 amostras, 28 pontos apresentaram erros além do limite de  $\pm 0,3^{\circ}\text{C}$ , que é o limite de tolerância estabelecido pela norma de berços aquecidos.

Como resultado de desempenho, a RNA continua apresentando um coeficiente de regressão com valor negativo de  $-0,08$ , indicando melhora significativa em relação à rede com 4 e 7 entradas. O erro médio quadrático de  $8,71\text{e-}5$  também indica sutil melhora na capacidade de predição da rede em relação ao modelo com 4 entradas.

#### 4.1.4 REDE NEURAL COM FUNÇÃO GRIDSEARCH

A Figura 56 apresenta o desempenho de predição de uma RNA estruturada com o auxílio da função GridSearch configurada com 10 entradas, camada oculta com 30 neurônios e um neurônio na camada de saída. As entradas da rede são compostas por valores RGB da imagem térmica, valores RGB da imagem visível, valores CIE Lab\* da imagem visível e a temperatura medida da câmera pelo algoritmo de pseudo-cores.


Figura 56 - Valor real x Predição da RNA com 10 entradas com função GridSearch



Fonte: Autor

A figura 57 apresenta o gráfico com os erros de medida de temperatura corrigidas com base nos valores preditos da RNA

Figura 57 - Erro de predição da temperatura pela RNA



Fonte: Autor

Dentre as amostras de validação, a configuração com 10 entradas usando a função GridSearch apresentou erro médio de  $-0,1^{\circ}\text{C}$ . O gráfico demonstra uma tendência de acompanhar as temperaturas reais com valores de erro na faixa entre  $-0,7^{\circ}\text{C}$  e  $+0,5^{\circ}\text{C}$ .

Os gráficos indicam que a rede com 10 entradas com hiperparâmetros configurados com o auxílio da função GridSearch apresentou amplitude de erro menor em comparação com todas as RNAs anteriores. Das 92 amostras, 28 pontos apresentaram erros além do limite de  $\pm 0,3^{\circ}\text{C}$ , que é o limite de tolerância estabelecido pela norma de berços aquecidos.

Como resultado de desempenho, a RNA apresentou um coeficiente de regressão com valor positivo de  $+0,12$ , indicando melhora significativa e boa capacidade de predição em comparação com as RNAs anteriores. O erro médio quadrático de  $6,10\text{e-}5$  também indica melhora no desempenho da rede em relação aos modelos anteriores.

Com o auxílio da função GridSearch para ajuste dos hiperparâmetros da RNA, o coeficiente de regressão aumentou de  $-0,0795$  para  $0,1212$ . Além disso, o erro médio logarítmico de regressão diminuiu de  $8,7139\text{e-}5$  para  $6,1060\text{e-}5$ , indicando redução no erro médio em relação aos resultados de desempenho das RNAs anteriores.

## 5. CONCLUSÕES

O estudo apresenta uma abordagem para se medir a temperatura de bebês recém-nascidos a partir da termografia. Os principais benefícios desta técnica estão associados à ausência de contato com a pele do paciente e a possibilidade de se identificar a temperatura em vários pontos no corpo do paciente. Atualmente, os profissionais de neonatologia contam somente com dois sensores de contato direto com a pele do paciente presos por meio de um adesivo.

Apesar de a técnica da termografia apresentar grandes benefícios em sua aplicação, alguns cuidados são necessários para assegurar a precisão na medição da temperatura, tais como:

- Ajuste do foco em relação à distância da câmera para a captura da imagem
- Ajuste no alinhamento da imagem RGB com a imagem Infravermelha
- Identificar condições que potencialmente podem afetar a qualidade da medida de temperatura, como reflexão de luz solar sobre a pele, distância e ângulo de captura da imagem em relação à posição do paciente.
- Assegurar ambiente com baixo fluxo de ar para trazer maior estabilidade da temperatura medida e mitigar riscos de perda de calor do paciente.
- Presença de substância sobre a pele causando alteração no perfil de emissão e propagação da radiação infravermelha do corpo que se deseja medir a temperatura

A estruturação gráfica da escala de térmica de cores distribuída em funções de primeiro grau, formou uma boa base de conhecimento para estruturar uma abordagem capaz de calcular a temperatura partir dos níveis de cinza das bandas RGB da imagem térmica. Com esta abordagem é possível medir a temperatura em qualquer pixel da imagem térmica.

Incluir elemento de temperatura conhecida na imagem torna possível a correção de erros de temperatura em toda a imagem a partir de uma única região da imagem com um valor preciso e conhecido de temperatura.

A precisão da temperatura medida pela termografia está diretamente atrelada ao custo. Uma forma de viabilizar a construção de equipamentos com este tipo de tecnologia seria a inclusão de sensores indiretos, posicionados na imagem para se obter dois pontos de medição precisos e, com o uso de visão computacional localizar estes pontos na imagem para compensação de erro nos demais valores da imagem.

A captura da imagem térmica é possível porque o hardware e software embarcado da câmera tem a capacidade de montar uma matriz numérica com base na onda eletromagnética de comprimento de onda na faixa de infravermelho que é emitida pelo corpo do paciente. Incluir a este sistema recursos de algoritmos de inteligência artificial que considerem variáveis da imagem visível, como os espaços de cores RGB e CIELab\* se apresenta como uma boa opção para melhorar o desempenho das câmeras termográficas disponíveis no mercado.

Durante os testes com o banco de imagens, verificou-se que a medida da temperatura por meio do algoritmo de pseudo-cores apresentou erros de medida superiores a 5°C. Ao incluir um corpo negro com temperatura controlada na imagem para servir como fator de correção de erro, observou-se uma redução significativa do erro máximo, resultando em valores iguais ou inferiores a 3,5°C. Em grande parte dos casos, dentre as 459 amostras utilizadas no experimento, o erro máximo ficou abaixo de 1,5°C. Vale destacar, também, que o erro médio caiu de 4,7°C para 0,3°C.

Os experimentos conduzidos com o uso da RNA proporcionaram redução significativa do erro médio de 0,3°C para 0,1°C, tendo um erro máximo de 0,7°C, mostrando a viabilidade da técnica bem como a importância de aperfeiçoar o uso desta técnica.

O aprimoramento da estrutura da RNA apresentada bem como a avaliação de mudança no tamanho da ROI, exploração de outros espaços de cores e outras características que podem ser extraídas da imagem podem ainda ajudar no processo para uma melhor predição da RNA para o problema apresentado.

## Referências

ABBAS, A. K., HEINMANN, K., JERGUS, K. *et al.* **Neonatal non-contact respiratory monitoring based on real-time infrared thermography.** BioMed Eng OnLine, 2011, Vol.10, 93

ABBAS, A. K. *et al.* **Neonatal Monitoring Technologies: Design for Integrated Solutions**, Capítulo 5: Neonatal Infrared Thermography Imaging. USA: Medical Information Science Reference, 2012, p. 84-124.

ALTIMIER, L. **Thermoregulation: What's New? What's Not?** Newborn and infant nursing reviews, 2012, Vol.12(1), p.51-63.

AMMER, K. & RING, F. **The Thermal Human Body: A Practical Guide to Thermal Imaging.** Jenny Stanford Publishing, 2019, p.1-8

ANTINK, C. H. FERREIRA, J. C. M. PAUL, M. *et al.* **Fast body part segmentation and tracking of neonatal video data using deep learning.** Medical & Biological Engineering & Computing, 2020, Vol.58(12), p.3049(13).

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR IEC 60601-2-21: Equipamento eletromédico Parte 2-21: **Requisitos particulares para a segurança básica e o desempenho essencial de aquecedores radiantes para recém-nascidos.** ABNT, 2019

BERKSOY, E. A., BAG, Ö., YAZICI, S., ÇELIK, T. **Use of noncontact infrared thermography to measure temperature in children in a triage room.** Medicine (Baltimore), 2018, Vol. 97(5), e9737

BERNARD, V., STAFFA, E., MORNSTEIN, V., BOUREK, A. **Infrared camera assessment of skin surface temperature - Effect of emissivity.** Physica medica V.29, issue 6, p583-591, 2013

CHARLTON, M., STANLEY, S.A., WHITMAN, Z., WENN, V., COATS, T.J., SIMS, M., *et al.* **The effect of constitutive pigmentation on the measured emissivity of human skin.** PLoS ONE, 2020, Vol.15(11).

HAYKIN, S., **Redes neurais princípios e prática**. Bookman, 2007. 9788577800865. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788577800865/>. Acesso em: 26 mar. 2023.

JADDOA, M. A., GONZALEZ, L., CUTHBERTSON, H., JUMAILY, A. A. **Multiview Eye Localisation to Measure Cattle Body Temperature Based on Automated Thermal Image Processing and Computer Vision**. *Infrared Physics & Technology*, 2021, Vol.119, p.1350-4495

JOSEPH, R. A., DERSTINE, S., KILLIAN, M., **Ideal Site for Skin Temperature Probe Placement on Infants in the NICU: A Review of Literature**. *Advances in Neonatal Care*, 2017, Vol 17, p. 114-122.

JUNG, T., MATTSSON, M. O., BRIDGES, J. *et. al.* **SCENIHR (Scientific Committee on Emerging and Newly-Identified Health Risks), Scientific opinion on light sensitivity**, Brussels: European Commission, Health & Consumers DG, 23 September 2008.

KOH, K. H. & YU, C. W. **Comparing the accuracy of skin sensor temperature at two placement sites to axillary temperature in term infants under radiant warmers**. Elsevier. *Journal of Neonatal Nursing* 2016, 22, p. 196-203.

KUMAR, R. **Research Methodology: a step-by-step guide for beginners**. 3<sup>rd</sup>. Edition. Sage, 2011.

KNOBEL, R. B., GUENTHER, B. D., RICE, H. E. **Thermoregulation and Thermography in Neonatal Physiology and Disease**. *Biological Research for Nursing* 13(3), 274–282, 2011.

KNOBEL, R. B., HOLDITCH, D., SLOANE, R., GUENTHER, B. D., KATZ, L. M., **Body temperature in premature infants during the first week of life: Exploration using infrared thermal imaging**. *Journal of Thermal Biology*. 69:118-123. 2017

LOZANO, R. F. J., García, F. L., ADANA, M. R., PALOMARES, J. M., Olivares, J., **Non-Invasive Forehead Segmentation in Thermographic Imaging**. *Sensors*, 19, no. 19: 4096, 2019.

LY, B. C. K. *et al.* **Research Techniques Made Simple: Cutaneous Colorimetry: A Reliable Technique for Objective Skin Color Measurement.** The Journal of investigative dermatology vol. 140,1 (2020): 3-12.e1

MINIPA DO BRASIL LTDA. **Manual de Instruções Câmera térmica MTV-2010**, 2011, Revisão 00, Emissão: 04/04/2011.

MICROLIFE CORPORATION. **Microlife Termômetro IFR1DU1 – Dual Mode - Instruções de Uso.** 2021, Versão manual: I B IFR1DU1 Medlevensohn 1020

NEGISHI, T., ABE, S., MATSUI, T., LIU, H., KUROSAWA, M., KIRIMOTO, T., SUN, G. **Contactless Vital Signs Measurement System Using RGB-Thermal Image Sensors and Its Clinical Screening Test on Patients with Seasonal Influenza.** Sensors, 20, 2171 2020.

ORNEK, A. H., CEYLAN, M., ERVURAL, S. **Health status detection of neonates using infrared thermography and deep convolutional neural networks.** Infrared Physics & Technology, Volume 103, 2019.

PEDRINI, H., & SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações.** Cengage Learning Brasil, 2007. 9788522128365. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788522128365/>. Acesso em: 28 mai. 2022.

RASSELS, K., & French, P. **Accurate Body Temperature Measurement of a Neonate Using Thermography Technology.** In Proceedings of the Smart Systems Integration, SSI 2021 [9467024] IEEE.

SYAMIMI, N., & YAHUD, S. **General design criteria for neonatal temperature monitoring sensor using " smart material" conducting polymer development: A review.** Applied Research and Smart Technology (ARSTech), v. 2, n. 1, p. 18-26, 2021.

SEGRE, C. A. M. *et al.* **Perinatologia: fundamentos e prática.** São Paulo: Sarvier, 2015, 1575 p.

SOLLAI, S. DANI, C. BERTI, E. et al. **Performance of a non-contact infrared thermometer in healthy newborns.** BMJ Open, 2016, v.6: e008695.

**Standards for improving quality of care for small and sick newborns in health facilities.** Geneva: World Health Organization; 2020. Licence: CC BY-NC-SA 3.0 IGO. Disponível em: <https://www.who.int/publications/i/item/9789240010765>. Acesso em: 17 jun. 2021.

STEKETEE, J. **Spectral emissivity of skin and pericardium.** Physics in Medicine & Biology, V18, N. 5, 1973, p. 686-94.

TOPALIDOU, A. ALI, N., SEKULIC, S. et al. **Thermal imaging applications in neonatal care: a scoping review.** BMC Pregnancy Childbirth, 2019, vol.19.

VILLASENOR-MORA, C. & SANCHEZ-MARIN, F. J. & CALIXTO-CARRERA, S. **An indirect skin emissivity measurement in the infrared thermal range through reflection of a CO2 laser beam.** Revista Mexicana de Física, México, v. 55, n. 5, 2009, p. 387-392

WANG, F. K., SHIH, J. Y., JUAN, P. H., SU, Y. C., WANG, Y. C. **Non-Invasive Cattle Body Temperature Measurement Using Infrared Thermography and Auxiliary Sensors.** Sensors. 2021, Vol.21(7):2425

YANG, F., HE, S., SADANAND, S. YUSUF, A., BOLIC, M., **Contactless Measurement of Vital Signs Using Thermal and RGB Cameras: A Study of COVID 19-Related Health Monitoring.** Sensors. 2022; 22(2):627.