



Pós-Graduação em Ciência da Computação

Thyago Maia Tavares de Farias

Caracterização da Persistência do Canal Arterial em Imagens Térmicas de Neonatos a partir do Uso de Redes Neurais Artificiais



Universidade Federal de Pernambuco
posgraduacao@cin.ufpe.br
<http://cin.ufpe.br/~posgraduacao>

Recife
2019

Thyago Maia Tavares de Farias

Caracterização da Persistência do Canal Arterial em Imagens Térmicas de Neonatos a partir do Uso de Redes Neurais Artificiais

Trabalho apresentado ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Doutor em Ciência da Computação.

Área de Concentração: Aprendizagem de Máquina

Orientador: Manoel Eusebio de Lima

Recife
2019

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

F224c Farias, Thyago Maia Tavares de
Caracterização da persistência do canal arterial em imagens térmicas de neonatos a partir do uso de redes neurais artificiais / Thyago Maia Tavares de Farias. – 2019.

124 f.: il., fig., tab.

Orientador: Manoel Eusebio de Lima.

Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2019.

Inclui referências, apêndices e anexos.

1. Inteligência artificial. 2. Aprendizagem de máquina. 3. Redes neurais artificiais. I. Lima, Manoel Eusebio de (orientador). II. Título.

006.3

CDD (23. ed.)

UFPE- MEI 2019-115

Thyago Maia Tavares de Farias

“Caracterização da Persistência do Canal Arterial em Imagens Térmicas de Neonatos a partir do Uso de Redes Neurais Artificiais”

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Ciência da Computação.

Aprovado em: 09/05/2019.

Orientador: Prof. Manoel Eusebio de Lima

BANCA EXAMINADORA

Profª. Dra. Edna Natividade da Silva Barros
Centro de Informática/UFPE

Profª. Dra. Veronica Teichrieb
Centro de Informática/UFPE

Prof. Dr. Abel Guilhermino da Silva Filho
Centro de Informática/UFPE

Prof. Dr. Wellington Pinheiro dos Santos
Departamento de Engenharia Biomédica / UFPE

Profª. Dra. Sandra da Silva Mattos
Real Hospital Português de Beneficência em Pernambuco

Prof. Dr. Hilário Tomaz Alves de Oliveira
Departamento de Computação / UNIPÊ

Decido este trabalho a minha família, em especial a meu pai Antonio Fernando Tavares de Farias, que sempre foi e sempre será um exemplo de honestidade, caráter, integridade, coragem e força. A minha mãe Iraneide Maia Tavares, minha melhor amiga, que sempre me apoiou em todas as minhas decisões e esteve ao meu lado em todos os momentos. A minha esposa Suzienne de Araujo Martins Maia que, com seu carinho, afeto e companheirismo esteve sempre ao meu lado, ajudando-me nos momentos de dificuldade, aconselhando-me nos momentos de dúvida, reerguendo-me nas derrotas, glorificando-me nas vitórias e me amando, mesmo com todos os meus defeitos. Aos meu filhos Theo Martins Maia e Sophia Martins Maia, razão da minha vida, que me alegram e inspiram todos os dias, demonstrando que tudo o que eu fiz para chegar até aqui valeu a pena.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me conceder uma vida saudável e cheia de oportunidades.

Agradeço ao Professor Luis Carlos Carvalho, que desde a graduação apoia meu desenvolvimento acadêmico. O mesmo também abriu portas para que eu ingressasse no Centro de Informática da Universidade Federal de Pernambuco.

Ao Professor Gustavo Henrique Matos Bezerra Mota, do Centro de Informática da Universidade Federal da Paraíba, também por abrir portas para o ingresso no CIn-UFPE.

Ao Professor Manoel Eusebio de Lima, pela orientação, confiança e parceria no desenvolvimento deste trabalho. Sua contribuição foi determinante para viabilizar a pesquisa em questão.

A Médica Cardiologista Pediátrica, Dr^a Sandra da Silva Mattos, pela oportunidade em trabalhar com o projeto em questão, pela aquisição da câmara térmica utilizada na pesquisa, pela orientação no âmbito clínico, pelo auxílio na aprovação do projeto em Comitês de Ética em Pesquisa e pelo acesso a rede conveniada da Fundação Círculo do Coração de Pernambuco.

A Dr^a Lucia Roberta Didier Nunes Moser, pela ajuda na execução da pesquisa no CISAM/UPE, pela interlocução com o Comitê de Ética da instituição e apoio para que eu pudesse apresentar os resultados do trabalho em uma conferência internacional.

A Dr^a Juliana Sousa Soares de Araújo, Coordenadora de Neonatologia e do Centro de Estudos do Instituto Cândida Vargas, pelo apoio na execução do projeto e pelo acesso à instituição para aplicação do protocolo de captura de imagens.

Aos professores Abel Guilhermino da Silva Fiho, Edna Natividade da Silva Barros, Wellington Pinheiro dos Santos, Veronica Teichrieb e Hilário Tomaz pela contribuição para a conclusão do referido trabalho, seja nas suas ótimas aulas, orientações e conselhos.

RESUMO

Este trabalho propõe um sistema computacional preditivo para a caracterização da Persistência do Canal Arterial (PCA) em imagens térmicas de recém-nascidos a partir do uso de uma Rede Neural Artificial (RNA). Recentemente, o rápido crescimento das tecnologias de termografia médica em vários campos clínicos tem promovido o uso de imagens térmicas como sensores fisiológicos sem contato. Em particular, a medicina intensiva neonatal é um campo clínico em que a termografia infravermelha pode desempenhar um papel importante em monitores não invasivos. Uma das complicações associadas à prematuridade, com potencial de monitoramento a partir de imagens térmicas, é a PCA. O canal arterial é um vaso largo que comunica a artéria pulmonar com a aorta no feto. O fechamento funcional do canal arterial no recém-nascido a termo ocorre com 12 a 15 horas de vida. No prematuro, o canal arterial permanece aberto por um período prolongado, e a frequência da persistência do canal arterial é proporcionalmente maior quanto mais imaturo for o recém-nascido. Se não tratado adequadamente, pode resultar em mortalidade, sobretudo entre os recém-nascidos de muito baixo peso. A PCA aumenta em até 30% o fluxo sanguíneo nos pulmões, elevando a velocidade de fluxo da artéria pulmonar. Esse “roubo de fluxo” deixa áreas da circulação sistêmica com déficit. Evidências descritas na literatura sugerem que alterações no fluxo sanguíneo geram aumento de temperatura corporal localizada, provocando o surgimento de regiões assimétricas de calor em imagens térmicas. Tais regiões podem evidenciar a ocorrência de alguma alteração no organismo ou doenças. A dificuldade do uso da assimetria de temperatura como um fator de avaliação médica está na correlação de um determinado mapa de temperatura apresentado em uma imagem térmica com uma doença específica, devido a possíveis inconsistências na captura e na análise de tais imagens. RNAs têm a habilidade em descobrir padrões que parecem despercebidos aos especialistas humanos ou para os métodos estatísticos tradicionais, sendo amplamente reconhecidas como valiosas ferramentas de apoio à decisão clínica e, portanto, úteis na caracterização de mapas de temperatura que possam evidenciar a presença do canal arterial em um neonato. Frente à magnitude do problema e a potencialidade do uso das redes neurais na classificação de imagens térmicas, a referida pesquisa objetiva capturar imagens térmicas de neonatos saudáveis e com PCA, afim de definir mapas de temperatura característicos para as duas classes, determinar e extrair vetores de características a serem correlacionadas com a PCA e com controles normais, aplicar uma arquitetura de rede neural artificial, definida especificamente para classificação das imagens térmicas capturadas e comparar as classificações realizadas pela RNA com avaliações clínicas, afim de validar o sistema computacional proposto.

Palavras-chaves: Termografia. Persistência do Canal Arterial. Aprendizagem de Máquina. Redes Neurais Artificiais. Reconhecimento de Padrões.

ABSTRACT

This work proposes a predictive computational system for a characterization of the persistence ductus arteriosus in neonatal thermal images from the use of an artificial neural network (ANN). Recently, the rapid growth of medical thermography technologies in various clinical fields has promoted the use of thermal imaging as non-contact physiological sensors. In particular, neonatal intensive care medicine is a clinical field in which infrared thermography can play an important role in noninvasive monitors. One of the complications associated with prematurity, with potential for monitoring from thermal imaging, is the persistence of the ductus arteriosus (PCA). The ductus arteriosus is a large vessel that communicates the pulmonary artery to the aorta in the fetus. Functional closure of the ductus arteriosus in the term newborn occurs at 12 to 15 hours of life. In preterm infants, the ductus arteriosus remains open for a prolonged period, and the frequency of ductus arteriosus persistence is proportionally higher in preterm infants. If not treated properly, it can result in mortality, especially among very low birth weight infants. PCA increases blood flow in the lungs by up to 30%, increasing the flow velocity of the pulmonary artery. This "flow theft" leaves areas of the systemic circulation with deficit. Evidence described in the literature suggests that changes in blood flow generate a localized increase in body temperature, provoking the emergence of asymmetric regions of heat in thermal images. Such regions may evidence the occurrence of any changes in the body or diseases. The difficulty of using temperature asymmetry as a medical evaluation factor is in the correlation of a given temperature map presented in a thermal image with a specific disease due to possible inconsistencies in the capture and analysis of such images. Artificial neural networks (ANNs) can discover patterns that seem unnoticed to human experts or traditional statistical methods and are widely recognized as valuable tools to support clinical decision making and thus useful in characterizing temperature maps that can evidence the presence of the ductus arteriosus in a neonate. In view of the magnitude of the problem and the potentiality of the use of neural networks in the classification of thermal images, the aforementioned proposal aims to capture thermal images of healthy neonates and the presence of arterial duct, in order to define characteristic temperature maps for the two classes, to determine and extract characteristic vectors to be correlated with the presence of ductus arteriosus and with normal controls, to apply an artificial neural network architecture, specifically defined for the classification of the captured thermal images and to compare the ANN classifications with clinical evaluations, in order to validate the proposed computational system.

Keywords: Thermography. Persistence of the Ductus Arteriosus. Machine Learning. Artificial Neural Networks. Pattern Recognition.

LISTA DE FIGURAS

Figura 1 – Frequência e necessidade de tratamento da PCA em neonatos com peso inferior a 1000 gramas.	19
Figura 2 – Frequência e necessidade de tratamento da PCA em neonatos com peso superior a 1000 gramas.	20
Figura 3 – Termograma de visão anterior de um recém-nascido prematuro com persistência do canal arterial.	24
Figura 4 – Termograma de visão anterior de um bebê prematuro, três dias após ligação ductal.	24
Figura 5 – Imagens térmicas com paleta máxima capturadas durante teste de hipótese.	25
Figura 6 – O canal arterial.	27
Figura 7 – Relação entre a aorta, ramos, artéria pulmonar e canal arterial durante o desenvolvimento de um feto.	28
Figura 8 – Relação entre a aorta, ramos, artéria pulmonar e canal arterial após o nascimento de um bebê.	29
Figura 9 – Relação entre a aorta, ramos, artéria pulmonar e canal arterial após o nascimento de um bebê, com a persistência do canal arterial.	29
Figura 10 – O espectro eletromagnético.	31
Figura 11 – Diagrama de blocos para o processamento de sinais de uma câmera térmica.	31
Figura 12 – O mecanismo de fluxo de calor radiativo.	32
Figura 13 – Estrutura de uma célula neural no cérebro humano.	39
Figura 14 – Estrutura de um neurônio em uma rede neural artificial.	40
Figura 15 – Arquitetura de uma RNA genérica.	41
Figura 16 – Exemplo de uma RNA Perceptron.	42
Figura 17 – Exemplo de uma RNA Perceptron multicamada.	43
Figura 18 – A câmera térmica FLIR ONE iOS.	53
Figura 19 – Informações sobre a captura de imagens térmicas realizadas durante a pesquisa.	54
Figura 20 – Algumas imagens térmicas obtidas a partir da aplicação do protocolo proposto.	56
Figura 21 – Exemplo de registro de temperaturas obtidas a partir de um termômetro infravermelho.	58
Figura 22 – Abordagem proposta para a segmentação de tronco neonatal.	61
Figura 23 – Saída do algoritmo dos contornos ativos para determinadas iterações.	63
Figura 24 – Gráfico de uma distribuição simétrica.	66

Figura 25 – Gráfico de uma distribuição assimétrica à direita ou positiva.	66
Figura 26 – Gráfico de uma distribuição assimétrica à esquerda ou negativa.	66
Figura 27 – Curvas de Curtose.	67
Figura 28 – O algoritmo SMOTE.	68
Figura 29 – Exemplo ilustrativo de como o SMOTE gera amostras simuladas, considerando um banco de instâncias reduzido.	69
Figura 30 – Exemplo ilustrativo de como o SMOTE gera amostras simuladas, considerando um banco de instâncias ampliado.	69
Figura 31 – Configurações de RNA testadas em experimentos.	71
Figura 32 – Algoritmo do Gradiente Conjugado Escalonado.	73
Figura 33 – Fluxo do extrator de características das imagens de tronco de neonatos.	75
Figura 34 – Exemplo de saída da aplicação desenvolvida.	76
Figura 35 – Diferença visual entre as segmentações manual e automática do tronco do neonato da Figura 34, onde as regiões coloridas representam as regiões divergentes para cada técnica.	77
Figura 36 – Fluxo adotado para a extração e simulação de características.	77
Figura 37 – Curva de Aprendizagem - Teste de Precisão Vs. Tamanho do Conjunto de Dados.	79
Figura 38 – Matrizes de confusão para cada configuração de RNA testada.	80
Figura 39 – Tela inicial do sistema PCA Diagnostic.	84
Figura 40 – Diagrama de Transição de Estados do PCA Diagnostic.	86
Figura 41 – Fluxograma do PCA Diagnostic.	87
Figura 42 – PCA Diagnostic realizando uma classificação de imagem térmica.	88
Figura 43 – Janela de diálogo do PCA Diagnostic para teste de classificação.	88

LISTA DE TABELAS

Tabela 1 – Métodos e resultados dos trabalhos levantados na revisão bibliográfica realizada	49
Tabela 2 – Especificações da câmera FLIR ONE iOS.	53
Tabela 3 – Média da diferença de temperatura entre o termômetro infravermelho e a câmera térmica FLIR One iOS.	59
Tabela 4 – Estudo do Teste de Precisão Vs. Tamanho do Conjunto de Dados. . . .	78
Tabela 5 – Resumo das saídas para cada configuração de RNA testada.	80
Tabela 6 – Resumo dos resultados obtidos nos testes de desempenho por cada técnica de Aprendizagem de Máquina (AM) disponíveis no Weka. . . .	81
Tabela 7 – Resumo dos resultados obtidos nos testes de desempenho por cada técnica de AM disponíveis no Weka, considerando 2688 amostras. . . .	82
Tabela 8 – Testes de Desempenho entre Técnicas de Aprendizagem de Máquina Disponíveis no Weka considerando 112 amostras	103
Tabela 9 – Testes de Desempenho entre Técnicas de Aprendizagem de Máquina Disponíveis no Weka considerando 2688 amostras	107

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizagem de Máquina
ARFF	<i>Attribute-Relation File Format</i>
CEP	Comitê de Ética em Pesquisa
CirCor	Círculo do Coração de Pernambuco
CISAM/UPE	Centro Integrado de Saúde Amaury de Medeiros da Universidade de Pernambuco
CONEP	Comissão Nacional de Ética em Pesquisa
ECG	Eletrocardiograma
ECN	Enterocolite Necrosante Neonatal
GUI	<i>Graphical User Interface</i>
GUIDE	<i>Graphical User Interface Development Environment</i>
ICV	Instituto Cândida Vargas
PCA	Persistência do Canal Arterial
RMSE	<i>Root Mean Squared Error</i>
RNA	Rede Neural Artificial
RNTP	Recém-Nascido Prematuro
SGC	Gradiente Conjugado Escalonado
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>
STC	Síndrome do Túnel do Carpo
UTI	Unidade de Terapia Intensiva
UTIN	Unidade de Terapia Intensiva Neonatal
UTIP	Unidade de Terapia Intensiva Pediátrica

LISTA DE SÍMBOLOS

Σ	Somatório
\bar{x}	Média
s	Desvio Padrão

SUMÁRIO

1	INTRODUÇÃO	16
1.1	PROBLEMA	17
1.2	OBJETIVOS	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivos Específicos	18
1.2.3	Justificativa	19
1.2.4	Hipóteses e Premissas	22
1.2.4.1	Hipóteses	22
1.2.4.2	Premissas	22
1.3	ESTRUTURA DA TESE	25
1.3.1	Publicações	25
2	CONCEITOS GERAIS E REVISÃO DA LITERATURA	27
2.1	PERSISTÊNCIA DO CANAL ARTERIAL	27
2.2	TERMOGRAFIA	30
2.2.1	Uso da Termografia na Medicina Neonatal	32
2.3	VISÃO COMPUTACIONAL	34
2.4	APRENDIZAGEM DE MÁQUINA	35
2.4.1	Viés Indutivo	37
2.4.2	Redes Neurais Artificiais	38
2.4.3	Uso de RNAs na Análise e Classificação de Imagens Térmicas	44
2.5	DISCUSSÃO DO CAPÍTULO	50
3	METODOLOGIA	52
3.1	PROCEDIMENTOS PARA A AQUISIÇÃO DE IMAGENS TÉRMICAS	52
3.1.1	Diretrizes para a escolha e configuração de equipamentos	52
3.1.2	Ambientes de captura de imagens térmicas	54
3.1.3	Características das imagens capturadas e gerenciamento dos pacientes envolvidos	55
3.1.4	Documentação	55
3.1.5	Aspectos Éticos da Pesquisa	55
3.1.6	Análise de Precisão da Câmera Térmica Adotada	57
3.2	SEGMENTAÇÃO DA REGIÃO DE INTERESSE	59
3.3	VIESES INDUTIVOS DA PESQUISA	63
3.4	SIMULAÇÃO DE CONJUNTOS DE DADOS DESBALANCEADOS	67
3.5	QUANTIDADE DE AMOSTRAS E ESTIMATIVA DE DESEMPENHO	69

3.6	REDE NEURAL ARTIFICIAL PROPOSTA	71
3.7	DISCUSSÃO DO CAPÍTULO	74
4	AVALIAÇÃO E RESULTADOS	75
4.1	MÓDULO PARA SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS	75
4.1.1	Módulo de Extração e Simulação de Características	76
4.1.2	Definição da Quantidade de Instâncias	78
4.2	TESTES DE CLASSIFICAÇÃO	79
4.3	O PCA DIAGNOSTIC	83
5	CONCLUSÕES E TRABALHOS FUTUROS	89
5.1	RESUMO DOS RESULTADOS	89
5.2	TRABALHOS FUTUROS	91
	REFERÊNCIAS	93
	APÊNDICE A – MODELO DA FICHA DE REGISTRO CLÍNICO	98
	APÊNDICE B – TERMO DE CONSENTIMENTO LIVRE E ES- CLARECIDO	99
	APÊNDICE C – TABELA - TESTES DE DESEMPENHO ENTRE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA DISPONÍVEIS NO WEKA CONSIDERANDO 112 AMOSTRAS	102
	APÊNDICE D – GRÁFICO - TESTES DE DESEMPENHO EN- TRE TÉCNICAS DE APRENDIZAGEM DE MÁ- QUINA DISPONÍVEIS NO WEKA, CONSIDE- RANDO 112 AMOSTRAS	104
	APÊNDICE E – TABELA - TESTES DE DESEMPENHO ENTRE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA DISPONÍVEIS NO WEKA CONSIDERANDO 2688 AMOSTRAS	106
	APÊNDICE F – GRÁFICO - TESTES DE DESEMPENHO EN- TRE TÉCNICAS DE APRENDIZAGEM DE MÁ- QUINA DISPONÍVEIS NO WEKA, CONSIDE- RANDO 2688 AMOSTRAS	108

ANEXO A – PLATAFORMA BRASIL - INFORMAÇÕES BÁSICAS DO PROJETO	110
ANEXO B – PARECER CONSUBSTANCIADO DO CEP	112
ANEXO C – CARTA DE ANUÊNCIA - CIRCOR	122
ANEXO D – CARTA DE ANUÊNCIA - ICV	123
ANEXO E – CARTA DE ANUÊNCIA - CISAM	124

1 INTRODUÇÃO

Os sinais vitais de recém-nascidos são monitorados a partir do uso de sensores e eletrodos aderidos a pele em uma Unidade de Terapia Intensiva Neonatal Unidade de Terapia Intensiva Neonatal (UTIN). Dentre os sinais vitais captados, temos o Eletrocardiograma (ECG), a oximetria de pulso, além de temperatura e pressão sanguínea. Tais sensores e eletrodos que ficam em contato direto com a derme dos neonatos, através de material adesivo, podem irritar ou ferir esta derme sensível. Especialmente em recém-nascidos prematuros (24 a 27 semanas de gestação), a pele é muito vulnerável para a remoção de fitas adesivas e eletrodos devido à falta de tecido subcutâneo (KLAESSENS et al., 2014). O contato direto com tais sensores e eletrodos adesivos ainda podem causar estresse e dor aos recém-nascidos (VILLARROEL et al., 2014). A presença de cabos (um para cada eletrodo fixado) pode também limitar consideravelmente a mobilidade e o conforto do paciente, forçando-o a manter uma posição inicial (supino) por todo o período de monitoramento ou limitando seus movimentos devido ao tamanho dos cabos (SCALISE, 2012).

Além dos problemas associados às ferramentas de captura de sinais, tem havido uma crescente preocupação de que procedimentos invasivos intrínsecos ao manejo na Unidade de Terapia Intensiva Neonatal e na Unidade de Terapia Intensiva Pediátrica (UTIP), como a intubação endotraqueal, exames repetidos de sangue, inserção de linhas periféricas e cirurgia, podem induzir alterações no sistema nervoso central dos recém-nascidos. Os sistemas fisiológicos destes pacientes são instáveis e imaturos, tornando-os vulneráveis aos efeitos dos procedimentos invasivos repetitivos (GRUNAU; HOLSTI; PETERS, 2006).

Nos últimos anos, várias técnicas de monitoramento sem contato, métodos não invasivos e técnicas de imagem estão sendo estudadas em laboratório e em (pré) ambientes clínicos: bioimpedância, sensores de movimento, radar, imagem multiespectral e termografia, indução magnética, além de fotopletiografia a partir de smartphones e câmeras RGB (KLAESSENS et al., 2014).

Recentemente, o rápido crescimento das tecnologias de termografia médica em vários campos clínicos tem promovido o uso de imagens termográficas como um sensor fisiológico sem contato. Em particular, a medicina intensiva neonatal é um campo clínico em que a termografia infravermelha pode desempenhar um papel importante em monitores não-invasivos (ABBAS; LEONHARDT, 2014). Thiruvengadam, Anburajan e Venkatraman (2014) reforçam o potencial do uso de imagens térmicas como ferramenta para a predição de doenças cardiovasculares, já que refletem mudanças na temperatura da pele de pacientes. Hoekstra (2016) também justifica o uso de imagens térmicas na predição de doenças do coração, afirmando que imagens termográficas mostram claramente as áreas de energia diminuída e aumentada do fluxo sanguíneo, sendo o método não invasivo mais sensível e preciso na indicação de doenças do coração.

1.1 PROBLEMA

Os recentes avanços tecnológicos na assistência perinatal têm possibilitado maior sobrevivência de recém-nascidos prematuros. No entanto, ainda se observam frequências elevadas de complicações, internações prolongadas e sequelas nesses pacientes. Entre as complicações associadas à prematuridade, destaca-se a persistência do canal arterial que, se não tratado adequadamente, pode resultar em aumento de mortalidade, sobretudo entre os recém-nascidos de muito baixo peso ao nascer. Além disso, o manejo ou diagnóstico clínico e radiológico do canal arterial em recém-nascidos prematuros ainda é controverso, já que a caracterização clínica é difícil, sobretudo nos primeiros três primeiros dias de vida, quando a resistência pulmonar encontra-se ainda elevada, particularmente em recém-nascidos prematuros com angústia respiratória e necessidade de ventilação mecânica. Nos recém-nascidos prematuros, sobretudo naqueles com idade gestacional menor que 30 semanas e com peso de nascimento inferior a 1000g, a caracterização clínica da persistência do canal arterial também é complicada, mesmo na presença de um desvio ductal significativo (BRAGANÇA, 2011).

Segundo Diakides e Bronzinho (2008):

“A termografia vem se tornando uma importante técnica no auxílio ao diagnóstico clínico, permitindo avaliar diversas doenças. Trata-se de uma modalidade de imagem que está sendo usada em muitas áreas médicas, tais como: oncologia, anestesiologia, cirurgia, reumatologia, neurologia, urologia, ginecologia, oftalmologia, dermatologia, pneumologia, odontologia, pediatria, medicina esportiva, medicina neonatal, medicina ocupacional e medicina veterinária” (DIKIDES; BRONZINHO, 2008).

Um fator que favorece o uso de imagens térmicas de recém-nascidos na identificação de doenças está na variação de temperatura apresentada em imagens de neonatos com e sem patologias. Em aplicações médicas, uma das principais características observadas em uma imagem térmica é a simetria de temperatura. A superfície da pele de uma pessoa saudável possui uma simetria térmica, indicando normalidade. Imagens térmicas são geralmente assimétricas nas enfermidades, indicando a ocorrência de alguma alteração no organismo. Assimétricas significativas podem indicar doenças como câncer, infecção, doença vascular e variações anatômicas (SANCHES, 2009). A dificuldade do uso da simetria de temperatura como um fator de avaliação médica está na correlação de um determinado mapa de temperatura apresentado em uma imagem térmica com uma doença específica. Segundo Sanches (2009), é difícil associar variações de temperatura da pele com estruturas ou órgãos internos.

A partir de tais considerações, propõem-se nesse trabalho utilizar uma rede neural artificial e técnicas de aprendizagem de máquina com o objetivo de detectar regiões as-

simétricas de temperatura em imagens térmicas de recém-nascidos que caracterizem a presença do canal arterial persistente em neonatos.

1.2 OBJETIVOS

Este estudo propõe atender ao objetivo geral e aos objetivos específicos a seguir.

1.2.1 Objetivo Geral

Desenvolver um sistema computacional preditivo para a caracterização da persistência do canal arterial em imagens térmicas de recém-nascidos a partir do uso de redes neurais artificiais.

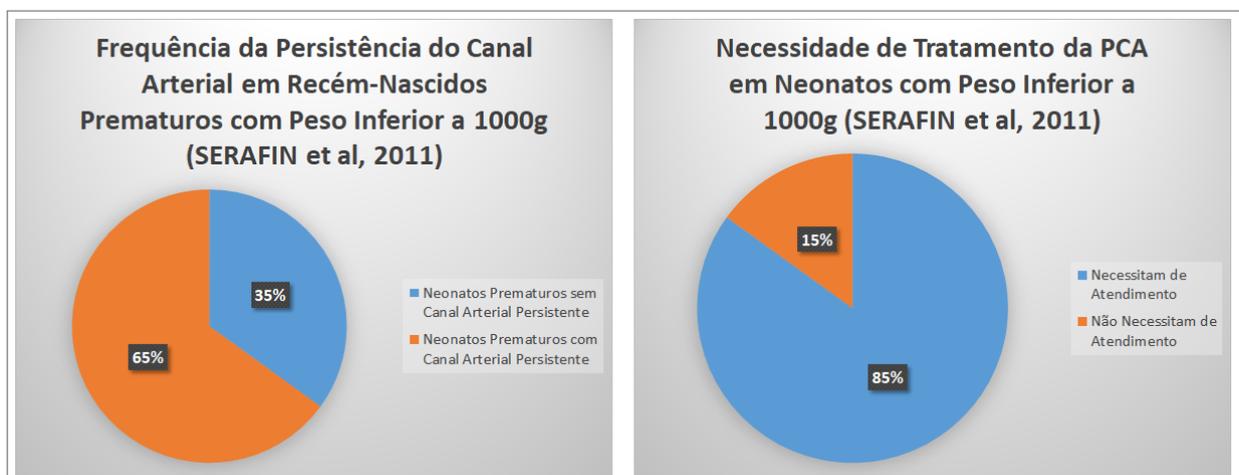
1.2.2 Objetivos Específicos

- Definir infraestrutura e protocolo para a captura de imagens térmicas de recém-nascidos;
- Capturar imagens térmicas de neonatos saudáveis e com a persistência do canal arterial, afim de definir mapas de temperatura característicos para as duas classes;
- Definir uma região de interesse nas imagens térmicas capturadas que auxilie na classificação de neonatos quanto a persistência do canal arterial;
- Desenvolver uma aplicação para a segmentação automática da região de interesse definida para a pesquisa;
- Determinar e extrair vetores de características a serem correlacionadas com a persistência do canal arterial e com controles normais;
- Aplicar uma arquitetura de rede neural artificial, definida especificamente para classificação de imagens térmicas de recém-nascidos com e sem a persistência do canal arterial;
- Comparar a acurácia preditiva obtida pela arquitetura de RNA adotada com outras técnicas de aprendizagem de máquina;
- Comparar as classificações realizadas pela rede neural artificial com avaliações clínicas, afim de validar a metodologia adotada.

1.2.3 Justificativa

A referida proposta de pesquisa foi baseada em uma demanda encaminhada pelo projeto Círculo do Coração de Pernambuco (CirCor)¹. A referida fundação destacou a necessidade de novas ferramentas de auxílio ao diagnóstico do canal arterial patente frente às ocorrências dessa complicação: Segundo Yang, Song e Choi (2013), a presença do ducto arterioso é de fundamental importância para a circulação fetal. A falha em seu fechamento está associada com significativa morbidade. A incidência da PCA em recém-nascido a termo foi estimada em 57 a cada 100.000 nascidos vivos, ao passo que a incidência de PCA em recém-nascidos pré-termo, pesando entre 501 e 1500g, foi de 31%. Em crianças que pesam 1000g ou menos (extremo baixo peso ao nascer) 55% foram descritas como portadoras de PCA sintomática² que, em última instância, precisa de tratamento médico. Segundo Serafin, Moreira e Margotto (2011), vinte e cinco por cento dos neonatos com peso entre 1000 e 1500 gramas apresentam PCA com 72 horas de vida e 70% destes requerem tratamento. Sessenta e cinco por cento dos neonatos com peso menor que 1000 gramas apresentam PCA com 72 horas de vida e destes 85% precisam de tratamento (SERAFIN; MOREIRA; MARGOTTO, 2011). Tais dados são apresentados de forma gráfica nas Figuras 1 e 2.

Figura 1 – Frequência e necessidade de tratamento da PCA em neonatos com peso inferior a 1000 gramas.



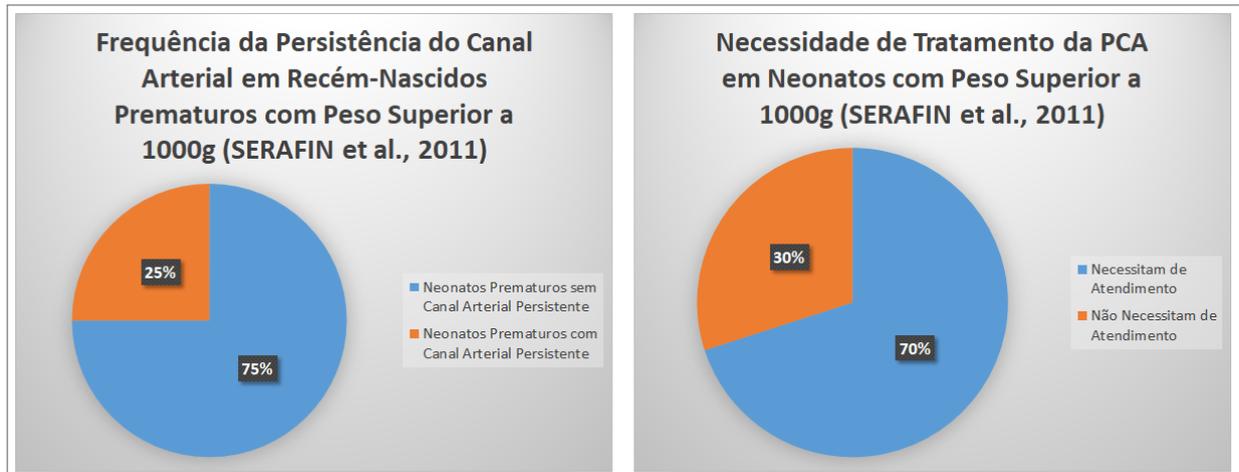
Fonte: (SERAFIN; MOREIRA; MARGOTTO, 2011)

Segundo Serafin, Moreira e Margotto (2011), a PCA aumenta em até 30% o fluxo sanguíneo pulmonar, elevando a velocidade de fluxo da artéria pulmonar. Esse “roubo de fluxo” deixa áreas da circulação sistêmica com déficit. Evidências descritas na literatura sugerem que alterações no fluxo sanguíneo provocam o aumento de temperatura corpo-

¹ O CirCor apoia o projeto com orientações em neonatologia, na disponibilização de imagens térmicas de neonatos, na classificação assistida dos mapas de temperatura e na avaliação dos resultados da referida proposta.

² Que constitui sintoma.

Figura 2 – Frequência e necessidade de tratamento da PCA em neonatos com peso superior a 1000 gramas.



Fonte: (SERAFIN; MOREIRA; MARGOTTO, 2011)

ral localizada. A pesquisa de Christidis et al. (2003) evidenciou a existência de simetria térmica em termogramas capturados após a primeira hora de vida de 41 recém-nascidos saudáveis. Já Pomerance, Lieberman e Ukrainski (1977) observaram a ocorrência de assimetria térmica em termogramas de um recém-nascido com canal arterial persistente e insuficiência cardíaca congestiva³ (temperatura do tórax mais fria graças a diminuição do fluxo sanguíneo da artéria pulmonar devido a ligadura ductal), e em imagens térmicas de outro bebê com o rim direito moderadamente hipoplástico (temperatura do flanco esquerdo mais quente). A partir da termografia médica, é possível quantificar a temperatura da superfície do corpo, medindo a radiação infravermelha emitida pela pele humana. Logo, o uso de imagens térmicas viabilizaria a análise de alterações de fluxo sanguíneo a partir da classificação de regiões de calor.

Porém, apesar de apresentar um grande potencial, o uso de termogramas na medicina ainda está envolto de ceticismo, devido a possíveis inconsistências na captura e na análise de tais imagens. Segundo Koay, Herry e Frize (2004), as inconsistências são em parte devido ao equipamento de aquisição de imagem utilizado, aos procedimentos de uso adotados, a dificuldade em processar e interpretar dados provenientes de imagens térmicas e, mais importante, devido à falta de protocolos padrão para orientar a revisão final. A avaliação dos termogramas é frequentemente feita de forma manual e, portanto, afetada pela subjetividade humana. Com a definição de protocolos padrão para a captura de imagens térmicas, a computação e ferramentas de processamento de imagem disponíveis hoje, a análise das imagens poderia ser feita mais rápida e de forma mais precisa a partir de programas de computador especializados e do uso de RNAs. Segundo Pettres (2011),

³ Situação em que o coração se torna incapaz de manter a circulação necessária ao organismo ou só pode fazê-lo mediante uma pressão mais elevada que a normal, em vista de que o fluxo sanguíneo encontra algum impedimento para seguir o seu curso (ABCMED, 2017)

RNAs têm a habilidade em descobrir padrões que parecem despercebidos aos especialistas humanos ou para os métodos estatísticos tradicionais. Dados com grau significativo de não-linearidade, o que é previsto em informações de temperatura a serem obtidas a partir de imagens térmicas, têm efeito negativo para grande parte das técnicas de análise matemática, sendo que em casos como estes, os fatores importantes para a tomada de decisões parecem muitas vezes imperceptíveis. Redes neurais artificiais são amplamente reconhecidas como valiosas ferramentas de apoio à decisão clínica e, portanto, foram muito úteis no escopo da pesquisa em questão.

No que se refere às pesquisas relacionadas ao uso da termografia na caracterização de mapas de temperatura correlacionados com a presença e repercussão termodinâmica do canal arterial em recém-nascidos, a literatura apresenta um único trabalho (POMERANCE; LIEBERMAN; UKRAINSKI, 1977). Além disso, os trabalhos que tiveram como foco o desenvolvimento de soluções computadorizadas que auxiliassem o diagnóstico da PCA a partir de AM adotaram o sopro cardíaco⁴ e a análise de fonocardiografia como fonte de dados para extração de instâncias de treinamento (KOTB et al., 2019). Apesar de tais trabalhos terem obtido resultados relevantes no auxílio automatizado ao diagnóstico da PCA, o clássico sopro contínuo é raro e, por vezes, o Recém-Nascido Prematuro (RNTP) com PCA pode apresentar um sopro sistólico semelhante ao da estenose funcional de ramos pulmonares (BRAGANÇA, 2011). Além disso, a fonte de dados adotada não permite a captura de informações relacionadas com a alteração da repercussão hemodinâmica provocadas pelo defeito cardíaco em questão, diferentemente dos dados obtidos a partir de imagens térmicas. Tal informação pode tornar a correlação de um dado conjunto de atributos com a PCA ainda mais factível.

Não há benefícios médicos imediatos para os neonatos envolvidos nesta pesquisa, pois este é um estudo investigativo para determinar o possível valor da termografia no auxílio ao diagnóstico da Persistência do Canal Arterial. No entanto, ser capaz de compreender melhor o mecanismo fisiológico associado à PCA pode levar a um melhor gerenciamento da doença e reduzir as taxas de mortalidade no futuro. Se não tratada adequadamente, a PCA pode resultar em mortalidade, sobretudo entre os recém-nascidos de muito baixo peso. Ao demonstrar que a termografia pode “ver” as alterações no fluxo sanguíneo dos neonatos provocados pela PCA, proporciona-se um meio objetivo de avaliar a PCA de forma não invasiva, algo atualmente não disponível e de grande impacto, potencial, nesta população.

Frente à magnitude do problema, a falta de investigações envolvendo a análise preditiva da persistência do canal arterial em imagens térmicas de recém-nascidos a partir de técnicas de reconhecimento de padrões e aprendizagem de máquina, além do impacto gerado no auxílio ao diagnóstico da PCA, justifica-se um aprofundamento no conhecimento

⁴ Um dos sintomas da PCA. É apresentado um som característico durante a respiração do neonato que possui o defeito cardíaco.

científico associado ao uso de imagens térmicas e redes neurais artificiais, proporcionando uma nova ferramenta que viabilizará uma análise não invasiva da persistência do canal arterial em neonatos.

1.2.4 Hipóteses e Premissas

Nesse tópico serão apresentadas as suposições a serem investigadas, além das informações essenciais que servem de base para a definição das especulações que norteiam as questões de pesquisa.

1.2.4.1 Hipóteses

A superfície da pele de uma pessoa saudável possui uma simetria térmica, indicando normalidade. Imagens térmicas são geralmente assimétricas nas enfermidades, indicando a ocorrência de alguma alteração no organismo. Tal fato ocorre em adultos e crianças.

É possível correlacionar um determinado mapa de temperatura apresentado em uma imagem térmica com a persistência do canal arterial no coração de um recém-nascido, já que alterações no fluxo sanguíneo provocadas pelo canal arterial influenciam a alteração de temperatura em determinadas regiões do corpo de um neonato. É previsto o surgimento de áreas de assimetria nas seguintes regiões de interesse:

- Braços – Devido a alterações na circulação sanguínea provocados pela PCA, é prevista uma queda de temperatura no braço direito e um aumento de temperatura no braço esquerdo;
- Tórax – Devido à possíveis registros de aumento de temperatura, provocados pela aumento de fluxo sanguíneo nessa região;
- Abdômen – Devido à possíveis registros de diminuição de temperatura, provocada pelo redução de fluxo sanguíneo nessa região.

A partir de tal mapa, é possível extrair vetores de características e dados estatísticos a partir das imagens térmicas de recém-nascidos. Tais vetores podem ser utilizados como dados de entrada para funções de aprendizagem de cada neurônio que irá compor uma rede neural artificial específica. Após as etapas de treinamento, validação e testes da RNA, será possível classificar as imagens térmicas em duas classes distintas: com e sem a persistência do canal arterial.

1.2.4.2 Premissas

Segundo Diakides e Bronzinho (2008), a imagem infravermelha é usada em muitas aplicações médicas. Algumas das principais áreas em que a termografia infravermelha está sendo usada com sucesso são: oncologia (câncer de mama, de pele, etc.), doenças vasculares

(diabetes, trombose venosa profunda, etc.), reumáticas, dermatológicas, disfunções do sistema musculoesquelético, medicina neonatal, neurologia, oftalmologia, gerenciamento de dor, inflamações, cirurgia, viabilidade dos tecidos, monitoramento da eficácia de drogas e terapias e doenças respiratórias. Segundo Sanches (2009), a termografia é um excelente auxiliar ao exame clínico e complementar para outras técnicas de diagnóstico por imagem, como radiografia, ultrassonografia e cintilografia, sendo classificada como um método de imagem funcional.

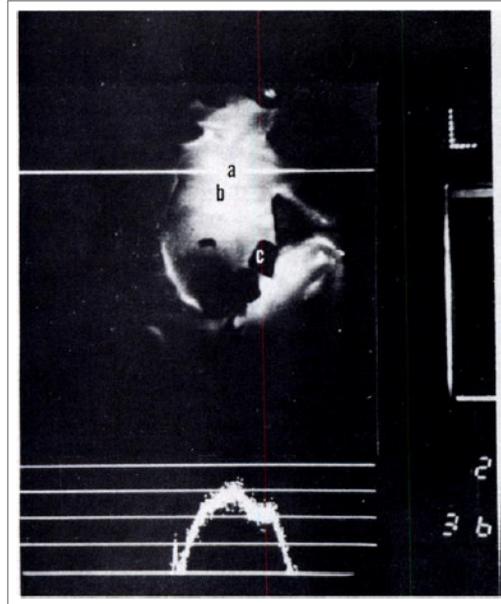
Sanches (2009) afirma que a diferença de temperatura da pele em indivíduos normais, em ambos os lados, é pequena, em torno de $0,2^{\circ}\text{C}$. Em condições ambientais neutras com temperatura ambiente de 28°C a 30°C e umidade relativa de 40% a 60%, a temperatura de um indivíduo saudável, em repouso e sem roupas, é de aproximadamente 37°C . As temperaturas da superfície cutânea na frente, tronco, dedos das mãos e pés são progressivamente mais baixas. Quando se mede a temperatura cutânea em ambientes mais frios, a distribuição é heterogênea. Por outro lado, a temperatura da pele é mais homogênea em ambientes quentes. A distribuição de temperatura da pele do corpo humano depende de vários fatores complexos, como os processos de troca de calor entre o tecido da pele, o tecido interno, a vascularização local, a atividade metabólica e anormalidades patológicas. Logo, o registro da distribuição da temperatura do corpo humano pode fornecer informações importantes a respeito do processo fisiológico que causam tais anormalidades. Assimetrias significativas podem indicar doenças como câncer, infecção, doença vascular e variações anatômicas.

Segundo Koay, Herry e Frize (2004), a termografia médica é um método utilizado na quantificação da temperatura da superfície do corpo, medindo a radiação infravermelha emitida pela pele humana. Como o calor metabólico é realizado em todo o corpo, principalmente por convecção através do fluxo sanguíneo, o aumento de temperatura da pele localizada geralmente indica um aumento de fluxo sanguíneo em torno do ponto quente.

Pomerance, Lieberman e Ukrainski (1977) verificaram, em estudos de viabilidade do uso de imagens térmicas em recém-nascidos que, em imagens térmicas de um neonato que possuía PCA, era possível detectar uma assimetria térmica no tórax do bebê, provocada pelo calor gerado pelo recebimento excessivo de sangue nos pulmões via aorta através do canal arterial. Uma das imagens capturadas que refletiram tais características é apresentada na Figura 3. Uma grande área quente foi detectada sobre o peito, refletindo o aumento do suprimento de sangue dos pulmões (Figura 3, área a). Outra região de assimetria foi visualizada no abdômen, sobrepondo o fígado do neonato (Figura 3, área b). Dobras cutâneas no pescoço, axilas, linhas inguinais e fossa poplítea esquerda também apareceram mais aquecidas.

Três dias após a realização da ligação cirúrgica do canal arterial, novas imagens térmicas foram capturadas do mesmo neonato. Tais imagens, uma delas apresentada na Figura 4, apresentaram redução de temperatura nas regiões que outrora geraram regiões de as-

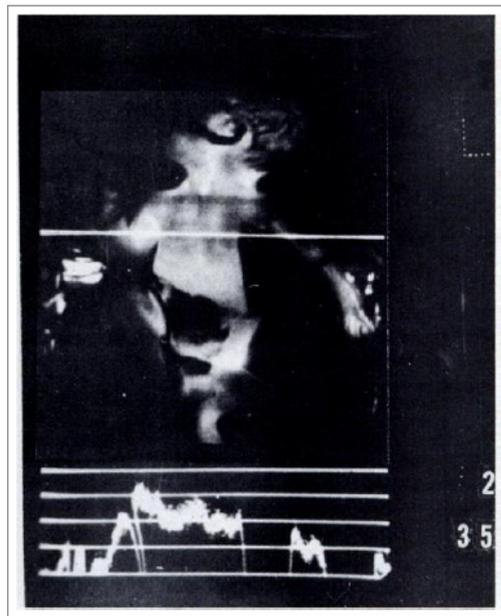
Figura 3 – Termograma de visão anterior de um recém-nascido prematuro com persistência do canal arterial.



Fonte: (POMERANCE; LIEBERMAN; UKRAINSKI, 1977)

simetria no mapa de temperatura do neonato, apresentando uma maior uniformidade. O fluxo sanguíneo nos pulmões foi reduzido, resultando em uma região mais fria no peito do bebê.

Figura 4 – Termograma de visão anterior de um bebê prematuro, três dias após ligação ductal.

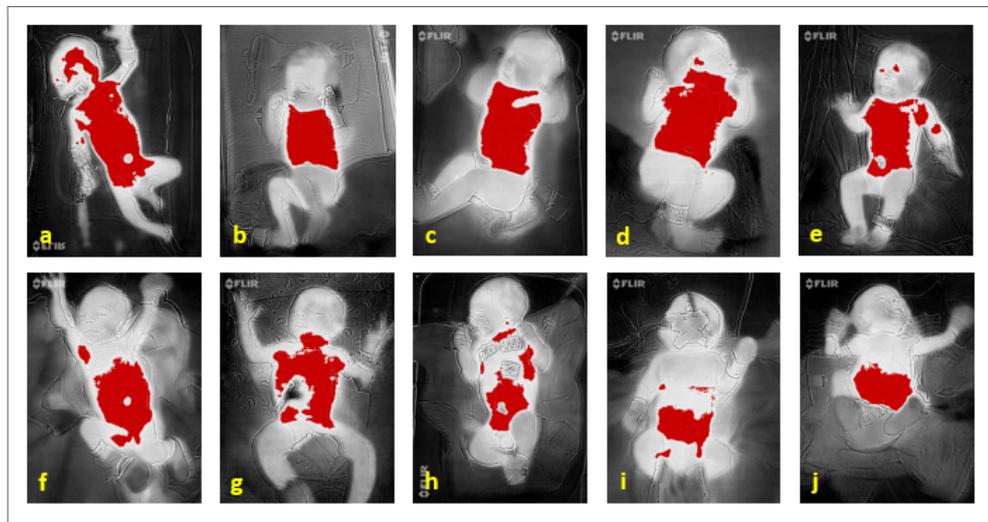


Fonte: (POMERANCE; LIEBERMAN; UKRAINSKI, 1977)

A pesquisa em questão também realizou testes de captura de imagens térmicas em

neonatos⁵ com o objetivo de confrontar as hipóteses levantadas pela tese e fundamentar ainda mais seu conjunto de premissas. Foram capturadas imagens térmicas com filtros que destacavam em vermelho as regiões do corpo mais quentes de vários neonatos. Algumas imagens capturadas são apresentadas na Figura 5. Nela, é possível verificar regiões homogêneas de calor no tronco dos neonatos sem PCA (Figura 5a, 5b, 5c, 5d, 5e, 5f e 5g), e um mapa de temperatura assimétrico em imagens térmicas de bebês com PCA (Figura 5h, 5i e 5j), indicando que o tronco de neonatos é um forte candidato para região de interesse a ser adotado em processos de extração de características que evidenciem ou não a PCA.

Figura 5 – Imagens térmicas com paleta máxima capturadas durante teste de hipótese.



Fonte: Próprio Autor

1.3 ESTRUTURA DA TESE

A tese está estruturada em 4 capítulos. No Capítulo 2, faz-se uma revisão da literatura sobre imagens térmicas, o uso de imagens térmicas na medicina neonatal, redes neurais artificiais e sua aplicação na classificação de imagens térmicas. No Capítulo 3, são apresentados os materiais e métodos para o desenvolvimento do trabalho. O Capítulo 4 apresenta os resultados obtidos para cada conjunto de imagens e descritores estatísticos utilizado no processo de aprendizagem da rede. Por fim, no Capítulo 5, é apresentada uma discussão sobre o projeto como um todo, as dificuldades encontradas, o status atual do projeto, além das considerações finais e o planejamento para trabalhos futuros.

1.3.1 Publicações

A tese em questão gerou resultados que permitiram a publicação do artigo *Automatic Segmentation of Neonates Thermal Imaging for Evaluation of Trunk Thermal Asymmetry*

⁵ O projeto foi aprovado pelo comitê de ética do Centro Integrado de Saúde Amaury de Medeiros (CISAM) da Universidade de Pernambuco (UPE), com o código CAAE 69729617.3.0000.5191

nos anais da *International Conference on Bioinformatics and Biomedicine* (BIBM 2018), realizada entre os dias 3 e 6 de dezembro de 2018, em Madrid, Espanha. O referido artigo descreve o módulo de segmentação automática de tronco de neonatos em imagens térmicas, necessário para a obtenção do vetor de temperaturas a partir da região de interesse definida na pesquisa, a ser apresentado em maiores detalhes no Capítulo 3, Tópico 3.2.

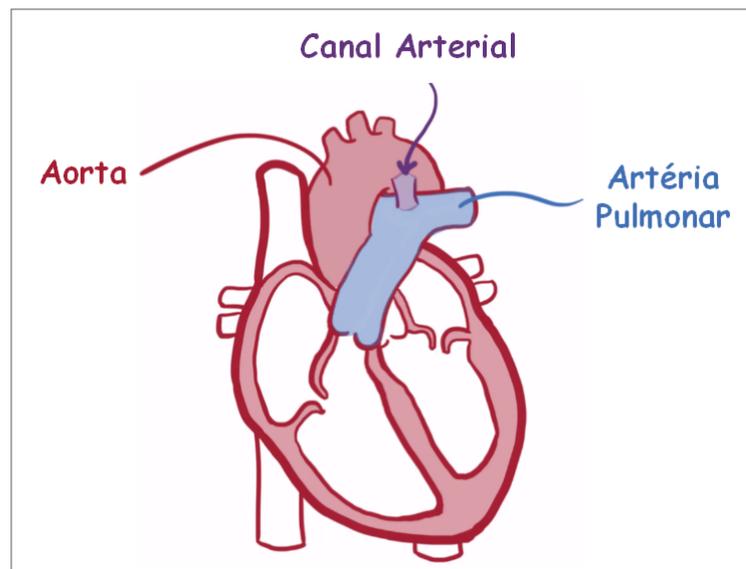
2 CONCEITOS GERAIS E REVISÃO DA LITERATURA

Neste capítulo, será proporcionado o “estado da arte” sobre o tema a que se refere o estudo. Neste capítulo também serão determinadas as variáveis que serão estudadas, esclarecendo exatamente o significado de cada uma delas dentro da pesquisa e como acontecem as relações dentro do tema.

2.1 PERSISTÊNCIA DO CANAL ARTERIAL

Um canal arterial persistente, apresentado na Figura 6, refere-se a um vaso sanguíneo que liga a artéria pulmonar à aorta durante o desenvolvimento fetal. O canal fica no arco aórtico, onde os vasos se ramificam até o cérebro e extremidades superiores (Open Osmosis, 2016).

Figura 6 – O canal arterial.

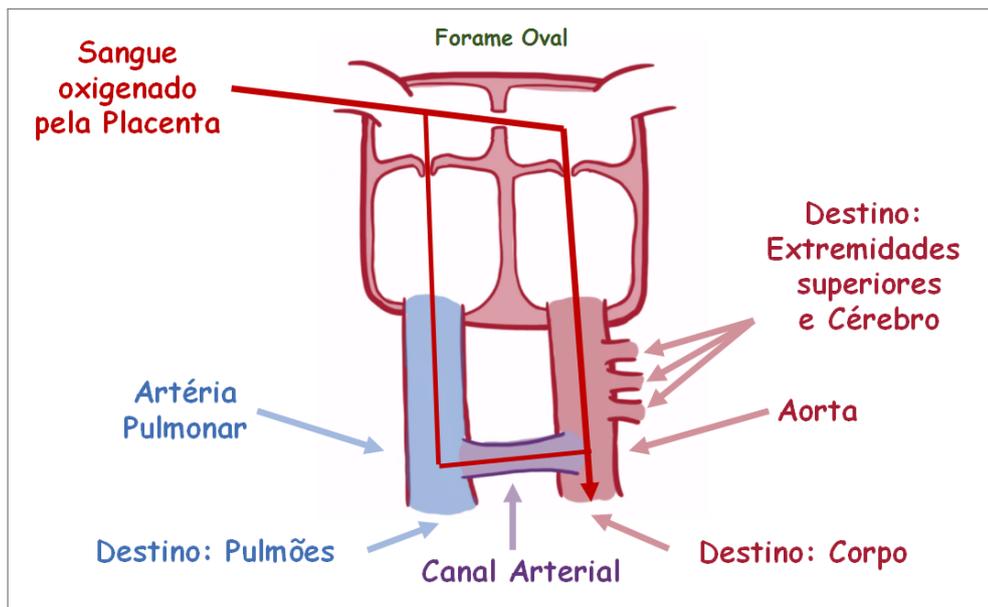


Fonte: (Open Osmosis, 2016)

Para uma melhor demonstração da relação entre a aorta, arco aórtico, artéria pulmonar e canal arterial, será utilizado o modelo simplificado do coração, apresentado na Figura 7. O canal arterial geralmente fecha após o nascimento porque suas paredes se contraem, tornando-se um ligamento – o ligamento arterial. Porém, quando ele permanece aberto após o nascimento, é dito que há Persistência do Canal Arterial (PCA), porque ainda há sangue passando por ele. Durante o desenvolvimento, o feto ainda não usa os pulmões e depende do sangue oxigenado da placenta, que entra no átrio direito. A maior parte desse sangue na verdade circula pelo forame oval, uma abertura entre os átrios. O sangue que não chega ao forame oval é bombeado do ventrículo direito à artéria pulmonar, onde

a maior parte dele segue para a aorta pelo canal arterial, em vez de ir para os pulmões (afinal, o feto ainda não está utilizando os pulmões). No desenvolvimento fetal, o canal arterial é mantido aberto pelos altos níveis de um vasodilatador produzido pela placenta e pelo próprio canal arterial (Open Osmosis, 2016).

Figura 7 – Relação entre a aorta, ramos, artéria pulmonar e canal arterial durante o desenvolvimento de um feto.

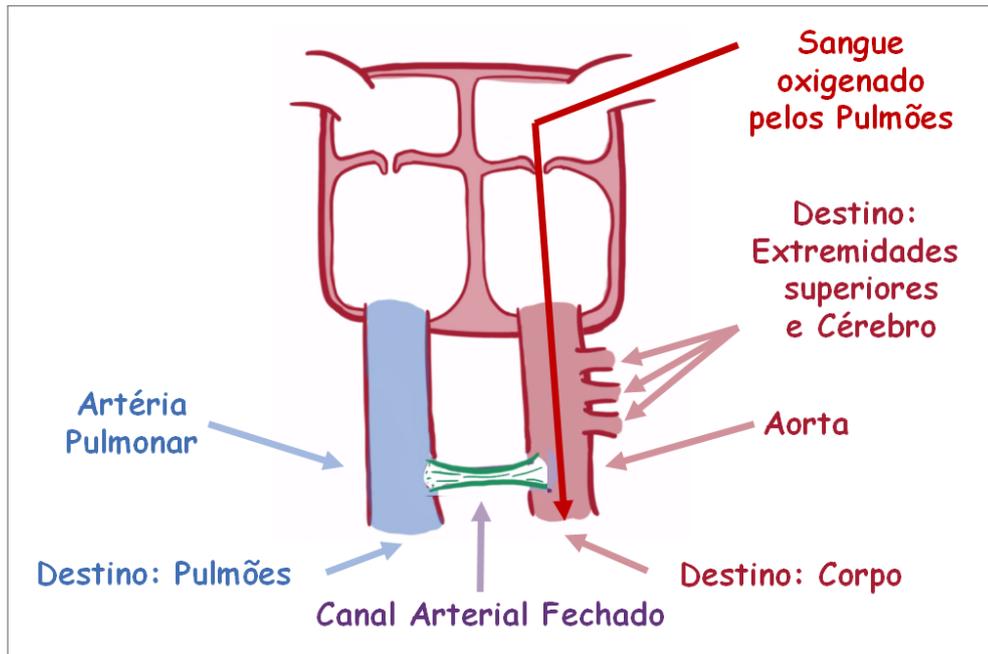


Fonte: (Open Osmosis, 2016)

No nascimento, os níveis de oxigênio no sangue sobem drasticamente e os pulmões se tornam a principal fonte de sangue oxigenado. Tais alterações são apresentadas na Figura 8. Logo após o nascimento, o forame oval se fecha e os níveis do vasodilatador caem, fazendo com que o canal arterial se feche. Os pulmões começam então a liberar um pequeno polímero de aminoácido que contrai a musculatura lisa da parede do canal arterial e auxilia no processo. Normalmente, já no primeiro dia o canal arterial começa a se estreitar, e em 3 semanas já está completamente fechado, transformando-se no ligamento arterial. Se esse canal não se fechar, será responsável por cerca de 10% de todos os defeitos cardíacos congênitos, dos quais cerca de 90% são defeitos cardíacos isolados, ou seja, não há mais nenhum defeito congênito (Open Osmosis, 2016).

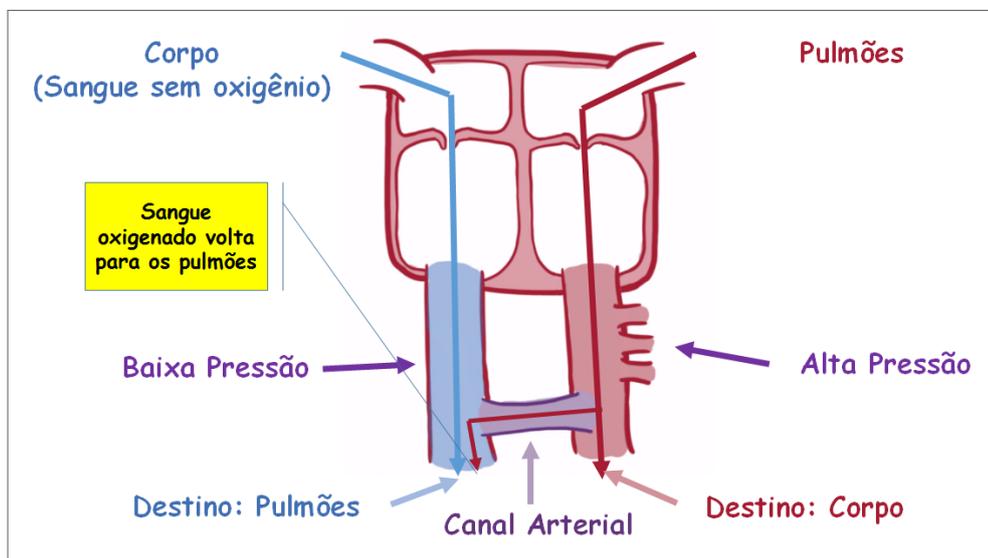
Com o canal arterial aberto e os pulmões sendo usados, o sangue entrará no átrio direito e seguirá para o ventrículo direito, se aproximando do canal arterial. O sangue terá duas opções de fluxo: continuar descendo pela artéria pulmonar ou mudar de direção e ir para o sistema de maior pressão na aorta (Open Osmosis, 2016). Como é tendência do sangue seguir um fluxo a partir de uma região com pressão mais alta para outra com pressão mais baixa, e a pressão na aorta é mais alta, ele seguirá em direção aos pulmões, como é apresentado na Figura 9.

Figura 8 – Relação entre a aorta, ramos, artéria pulmonar e canal arterial após o nascimento de um bebê.



Fonte: (Open Osmosis, 2016)

Figura 9 – Relação entre a aorta, ramos, artéria pulmonar e canal arterial após o nascimento de um bebê, com a persistência do canal arterial.



Fonte: (Open Osmosis, 2016)

Em seguida, o sangue oxigenado entrará no átrio esquerdo e ventrículo esquerdo, e mais uma vez terá duas opções. Porém, desta vez, já se encontra no sistema de pressão mais alta, sendo desviado para a artéria pulmonar (tal desvio é chamado de *shunt*). Logo, o sangue oxigenado passará pela segunda vez pelos pulmões desnecessariamente, podendo provocar o aumento no volume do pulmão ou o aumento de pressão interna. Se isso

acontecer, a pressão pode enfim aumentar até um ponto em que a pressão do lado direito é maior que a pressão do lado esquerdo, invertendo o fluxo de sangue pelo canal arterial (Open Osmosis, 2016).

Dado o aumento de pressão no fluxo sanguíneo e na pressão interna dos pulmões provocados pela PCA, além da inversão de fluxo de sangue devido ao canal arterial, é previsto o surgimento de pontos de calor e de queda abrupta de temperatura em determinadas regiões da pele dos recém-nascidos. Tais regiões podem ser evidenciadas em imagens térmicas, também chamados de termogramas. A seguir, serão discutidos os conceitos gerais associados a esse tipo de imagem.

2.2 TERMOGRAFIA

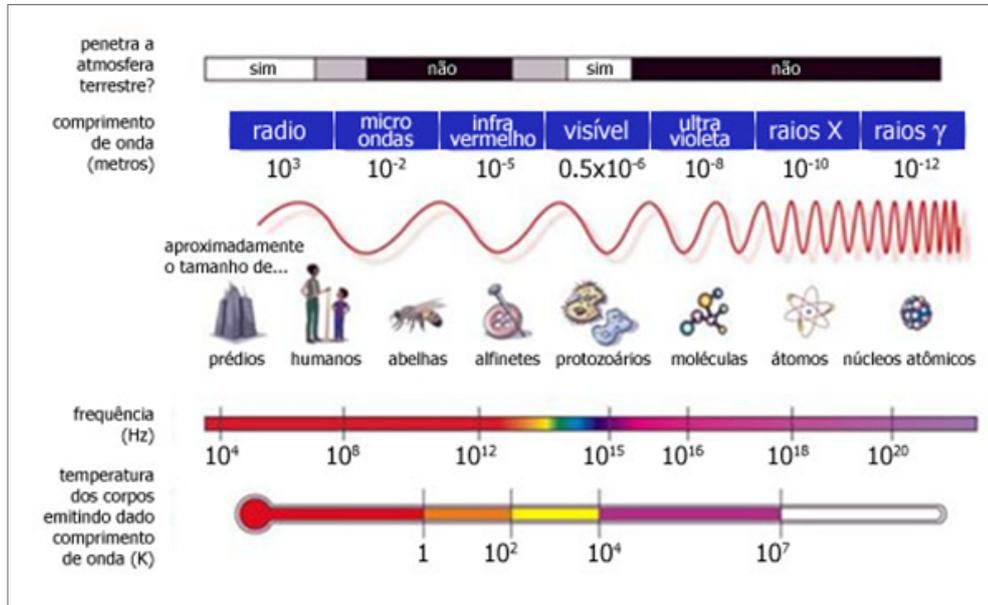
Segundo Sanches (2009), a termografia infravermelha, ou imagem térmica infravermelha, é o registro da distribuição da temperatura no corpo humano usando radiação infravermelha emitida pela pele:

É uma modalidade de imagem que permite a investigação e o diagnóstico médico a partir da análise das alterações de temperatura na superfície do corpo. A termografia é uma técnica não-invasiva, usada para converter a energia térmica do espectro eletromagnético, emitida pela superfície do corpo, em impulsos elétricos que podem ser visualizados na forma de imagem colorida usando pseudo-cores ou em tons de cinza (SANCHES, 2009).

Qualquer objeto cuja temperatura esteja acima do zero absoluto Kelvin ($-273,15^{\circ}\text{C}$) emite radiação a uma taxa particular em uma distribuição de comprimentos de onda. Tal distribuição de comprimento de onda depende da temperatura do objeto e da sua emissividade espectral. A emissividade espectral, que também pode ser considerada como a eficiência de radiação em um dado comprimento de onda, é por sua vez caracterizada pela eficiência de emissão de radiação baseada nas características do corpo (se é negro, cinzento ou um radiador seletivo). Na temperatura ambiente, as emissões típicas para uma matéria sólida são máximas na região de longa onda infravermelha do espectro eletromagnético (ABBAS et al., 2011). O espectro eletromagnético, que apresenta a classificação de radiação infravermelha e os comprimentos de onda correspondentes, é ilustrado na Figura 10.

Em princípio, quanto mais quente o objeto, mais alta é a máxima frequência da radiação, que se move em direção à região visível do espectro eletromagnético. Mesmo que a radiação infravermelha seja invisível ao olho humano, ela pode ser detectada e visualizada por câmeras térmicas especiais que, segundo Williams (2009) são compostas pelos seguintes elementos básicos, apresentados na forma de diagramas de bloco na Figura 11: (1) Um sistema ótico que pode formar uma imagem usando radiação em uma faixa no comprimento de onda termal; (2) Um ou mais elementos detectores que podem converter

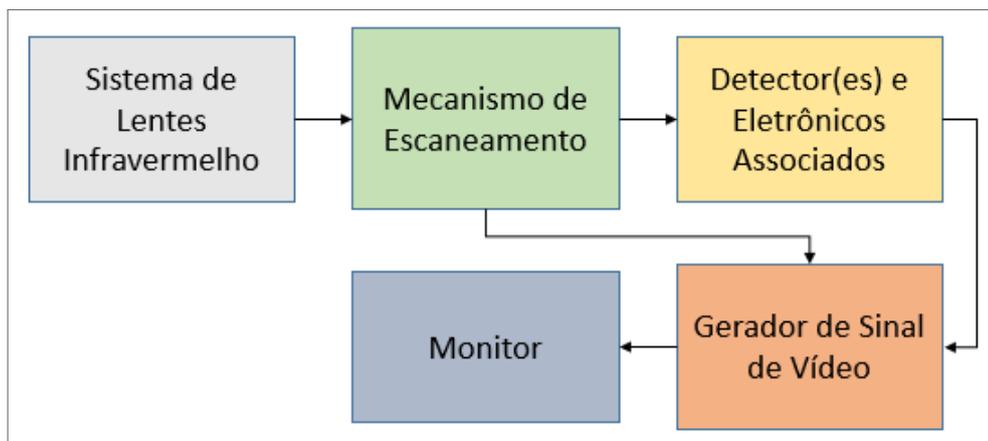
Figura 10 – O espectro eletromagnético.



Fonte: (ROABERT, 2017)

radiação termal em sinais elétricos proporcionais à radiação que incide sobre eles; (3) Um mecanismo de verificação que registra o campo de visão do sensor; (4) Um processador eletrônico que converte sinais elétricos em sinais de vídeo; (5) Um monitor que gera uma imagem a partir de um sinal de vídeo. Segundo Abbas et al. (2011) “Tais câmeras infravermelhas detectam a radiação infravermelha emitida por um objeto e convertidas em uma imagem monocromática ou multicolorida, onde vários tons ou cores representam os padrões térmicos através da superfície do objeto”.

Figura 11 – Diagrama de blocos para o processamento de sinais de uma câmera térmica.

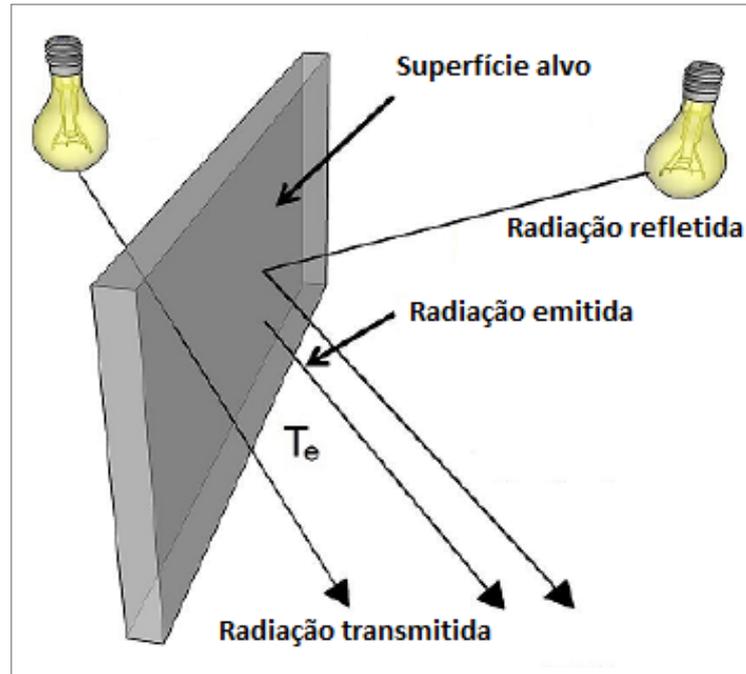


Fonte: (CATALAN, 2009)

De acordo com Abbas et al. (2011), a radiação térmica infravermelha que parte de uma superfície é chamada de emissividade. Essa energia pode ser emitida a partir de uma superfície, refletida para fora da superfície ou transmitida através da superfície. A

emissão de energia descrita é apresentada na Figura 12. A emissividade total é igual à soma da radiação emitida, da radiação refletida e da radiação transmitida. A temperatura de superfície é relacionada à radiação emitida. Quando uma câmera térmica é posicionada na frente de uma superfície alvo, a rede de radiação que será detectada é igual a radiação emitida. Isso significa que os outros componentes de emissividade não serão considerados na captura e geração de imagens térmicas.

Figura 12 – O mecanismo de fluxo de calor radiativo.



Fonte: (ABBAS et al., 2011)

Vale frisar que cada superfície emite uma emissividade específica, sendo necessária uma configuração prévia de tal valor físico em câmeras térmicas para que a captura das imagens seja feita de forma satisfatória. Sanches (2009) afirma que o conhecimento da emissividade é importante ao medir a temperatura da pele através do sistema infravermelho. É importante conhecer o valor exato da emissividade, porque uma diferença de 0,945 a 0,98 pode conduzir a um erro de 0,6°C na temperatura da pele. Ainda segundo Sanches (2009), a pele humana possui uma emissividade entre 0,97 e 0,98. Uma vez que a emissividade da pele humana é extremamente alta, medidas de radiação infravermelha emitida pela pele podem ser convertidas diretamente em valores de temperatura. A cor da pele não afeta significativamente a temperatura do corpo ou a emissão da radiação térmica.

2.2.1 Uso da Termografia na Medicina Neonatal

Em vários trabalhos, a análise de imagens térmicas em recém-nascidos permitiu a captura não-invasiva de sinais vitais, a obtenção de informações sobre distribuição de

temperatura, a detecção de alterações no fluxo sanguíneo e o diagnóstico de doenças. Pomerance, Lieberman e Ukrainski (1977) avaliaram a possibilidade de estruturas profundas altamente vasculares ou metabolicamente ativas poderem ser detectadas na superfície de recém-nascidos a partir de imagens térmicas. O objetivo foi definir termogramas normais de visão anterior e posterior do tronco neonatal. Além disso, foram observados desvios do normal e correlacionadas com informações clínicas e laboratoriais. Para o estudo, foram capturados termogramas de 37 neonatos no período de 3 meses. Em 30 desses neonatos, foram capturadas imagens de visão anterior. Para os demais neonatos, foram capturadas imagens de visão posterior. As imagens térmicas foram capturadas a partir de uma câmera Spectrotherm 2000. Para obter um ambiente padrão de captura, todos os estudos foram realizados sob um aquecedor radiante a uma temperatura abdominal da pele de 36°C. A pesquisa demonstrou que imagens térmicas destacam alterações de fluxo sanguíneo na superfície da pele ou próxima a ela, já que o sangue é “o principal veículo através do qual o calor é distribuído por todo o corpo”. Maiores detalhes da pesquisa, em especial a análise de imagens de neonatos com a presença do canal arterial, foram observados no tópico sobre as premissas da referida tese (Capítulo 1, Tópico 1.2.4.2).

Christidis et al. (2003) investigaram a temperatura de superfície de recém-nascidos na primeira hora após o nascimento. Além disso, a influência de diferentes condições ambientais em relação à temperatura da superfície foi documentada. A temperatura da superfície do corpo foi registrada em várias condições ambientais pelo uso de termografia infravermelha. Quarenta e dois recém-nascidos, todos entregues a termo e com peso adequado para a data, foram investigados em condições controladas. A temperatura de superfície, imediatamente após o nascimento, mostra uma imagem uniforme de todo o corpo. Logo após o nascimento, os locais periféricos tornam-se mais frios, enquanto que uma temperatura constante é mantida no tronco. Banhar em água morna novamente leva a um perfil de temperatura mais uniforme. A pesquisa provou que a termografia é uma ferramenta simples e confiável para a medição de perfis de temperatura da pele em recém-nascidos.

Abbas et al. (2011) desenvolveram e investigaram uma nova modalidade de monitoramento de respiração não invasiva para uma unidade intensiva neonatal a partir de imagens térmicas. Foi demonstrado que a taxa de respiração dos neonatos pode ser monitorada com base na análise do perfil de temperatura do nariz anterior (narinas) associado às fases de inspiração e expiração. Uma transformada contínua wavelet baseada na função de Dabeuchies foi aplicada para detectar o sinal respiratório em vídeos gravados a partir de câmeras térmicas. A respiração foi monitorada com sucesso com base em uma diferença de temperatura de 0,3°C a 0,5°C entre as fases de inspiração e expiração.

Nur (2013) propôs um novo método de diagnóstico para a Enterocolite Necrosante Neonatal (ECN) em recém-nascidos, uma doença inflamatória para as quais não há cura e as causas exatas permanecem desconhecidas, a partir da análise de imagens térmicas abdominais. Tais imagens revelaram anomalias térmicas que indicavam inflamação intes-

tinal característica da ECN. Uma análise da simetria termal abdominal, realizada em 20 neonatos normais e 9 recém-nascidos com a enterocolite necrosante, foi estatisticamente comparada. O mais alto grau de assimetria termal foi observado no grupo com ECN em comparação com o grupo normal.

Rice et al. (2015) realizaram um estudo com o objetivo de examinar a viabilidade do uso da termografia na medição da temperatura abdominal em recém-nascidos com baixo peso, comparar a temperatura da pele abdominal e torácica, além de explorar possíveis relações entre a temperatura abdominal e a ECN. Foram examinados dados clínicos, radiográficos e de imagens térmicas em 13 bebês com pesos abaixo de 1000g e abaixo de 29 semanas de gestação, no primeiro mês de vida. A temperatura do abdômen e do tórax eram medidas durante a captura das imagens. A temperatura abdominal foi comparada à temperatura do tórax, e estes achados foram ainda examinados em crianças com e sem evidência radiográfica de ECN. Foi descoberto que a termografia em bebês com baixo peso é viável e pode resultar em medições precisas da temperatura da pele em regiões anatômicas. No geral, temperatura abdominal média é mais baixa que a temperatura torácica, embora essa diferença apareça devido a ECN em algumas crianças. Os lactentes com evidência radiográfica de ECN apresentaram menor temperatura abdominal média em relação aos lactentes sem ECN. Os autores concluíram que a termografia é viável em bebês com baixo peso, sendo útil no estudo da termorregulação em lactentes.

2.3 VISÃO COMPUTACIONAL

Backes e Júnior (2016) define a visão computacional como a área de estudo que tenta repassar para máquinas a capacidade de visão:

A visão computacional consiste em captar imagens, melhorá-las (por exemplo, com retirada de ruídos, aumento de contraste, entre outros), separar as regiões ou objetos de interesse de uma cena, extrair várias informações dependendo da imagem analisada, como, por exemplo, forma, cor e textura e, finalmente, relacionar as imagens com outras vistas previamente (BACKES; JÚNIOR, 2016).

Gonzalez e Woods (2002) classificam a visão computacional como um ramo da inteligência artificial, principalmente nas áreas de aprendizado de máquina e reconhecimento de imagens, cujo objetivo é emular a inteligência humana, dada a característica da visão computacional de “dar sentido” a um conjunto de objetos contidos em uma imagem e realizar funções cognitivas normalmente associadas à visão.

Rios (2010) afirma que o reconhecimento de imagens requer bastante conhecimento prévio sobre o mundo e bastante capacidade de julgamento para se fazer conclusões sobre os dados da imagem e, então, tomar uma ação adequada às necessidades do agente. Mas, para julgar os objetos e dados de uma imagem, o agente precisa extrair os elementos

realmente relevantes ao contexto de uma dada cena. Como ainda se sabe pouco sobre o funcionamento da visão nos seres vivos, pensar em maneiras de modelá-la no computador é um enorme desafio e, apesar de todo o estudo realizado na área, ainda não existe uma solução definitiva, única, para o problema da visão computacional.

Segundo Backes e Júnior (2016), um sistema de visão computacional é constituído de 5 fases:

- Aquisição – Responsável pela simulação da visão humana a partir da captura de imagens, através de dispositivos como *scanners*, filmadoras, máquinas fotográficas, entre outros;
- Processamento de imagens – Responsável por “melhorar” uma imagem, tendo o propósito de fornecer uma imagem mais adequada para as próximas fases;
- Segmentação – Responsável por particionar a imagem em regiões de interesse;
- Extração de características – Responsável por obter um conjunto de características do objeto de interesse e encontrar uma codificação numérica que represente determinada imagem;
- Reconhecimento de padrões – Responsável por classificar ou agrupar as imagens com base em seu conjunto de características.

Na quinta fase de um sistema de visão computacional, conhecida como reconhecimento de padrões, é comum o uso de técnicas de AM para viabilizar a classificação e descrição de regiões de interesse. Por se tratar do foco principal da tese em questão, a Aprendizagem de Máquina e a forma como ela auxilia a fase de reconhecimento de padrões na visão computacional serão descritos em maiores detalhes na seção a seguir.

2.4 APRENDIZAGEM DE MÁQUINA

Segundo Luger (2013), o aprendizado é importante para aplicações práticas de inteligência artificial. Porém, o custo e a dificuldade de se construir sistemas usando técnicas tradicionais de aquisição de conhecimento são considerados “os gargalos da engenharia do conhecimento”. Luger (2013) sugere que uma solução para tais “gargalos” seria os programas começarem com uma quantidade mínima de conhecimento e aprenderem a partir de exemplos, de aconselhamentos de alto nível ou, ainda, de suas próprias explorações de domínio. Luger (2013) define aprendizado como “qualquer mudança em um sistema que melhore o seu desempenho na segunda vez que ele repetir a mesma tarefa ou outra tarefa tirada na mesma população”.

O processo de aquisição do conhecimento normalmente envolvia entrevistas com especialistas para descobrir que regras eles utilizavam quando da tomada de decisão. Esse

processo possuía várias limitações, como subjetividade, decorrente do uso pelo especialista de sua intuição na tomada de decisão, e, muitas vezes, pouca cooperação por parte do especialista, por causa do seu receio de ser dispensado após repassar o conhecimento adquirido (FACELI et al., 2011).

Com a crescente complexidade dos problemas a serem tratados computacionalmente e do volume de dados gerados por diferentes setores, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, que fossem mais autônomas, reduzindo a necessidade de intervenção humana e dependência de especialistas. Para isso, essas técnicas deveriam ser capazes de criar por si próprias, a partir da experiência passada, uma hipótese, ou função, capaz de resolver o problema que se deseja tratar. Um exemplo simples é a descoberta de uma hipótese na forma de uma regra ou conjunto de regras para definir que clientes de um supermercado devem receber material de propaganda de um novo produto, utilizando para isso dados de compras passados dos clientes cadastrados em uma base de dados do mercado. A esse processo de indução de uma hipótese (ou aproximação de função) a partir da experiência passada dá-se o nome Aprendizagem de Máquina (AM) (FACELI et al., 2011).

Segundo Faceli et al. (2011), no Aprendizado de Máquina, computadores são programados para aprender com a experiência passada. Para tal, empregam um princípio de inferência denominado indução, no qual se obtêm conclusões genéricas a partir de um conjunto particular de exemplos. Assim, algoritmos de AM aprendem a induzir uma função ou hipótese capaz de resolver um problema a partir de dados que representam instâncias do problema a ser resolvido. Esses dados (também chamados de objetos, exemplos, padrões ou registros), formam um conjunto de dados. Cada objeto corresponde a uma tupla formada por um vetor de características ou atributos que descrevem seus principais aspectos. Para algumas tarefas de aprendizado, um dos atributos de um conjunto de dados é considerado um atributo de saída (também chamado de atributo alvo ou meta), cujos valores podem ser estimados utilizando os valores dos demais atributos, denominados atributos de entrada ou previsores. O objetivo de um algoritmo de AM é aprender, a partir de um subconjunto dos dados, denominado conjunto de treinamento, um modelo ou hipótese capaz de relacionar os valores de atributos de entrada de um objeto do conjunto de treinamento ao valor do seu atributo de saída. Uma vez induzida uma hipótese, é desejável que ela seja válida para outros objetos do mesmo domínio ou problema que não fazem parte do conjunto de treinamento, isto é, que tenha a capacidade de generalizar a hipótese. Tendo uma boa capacidade de generalização, a hipótese será útil para novos dados.

No contexto da tarefa de processamento digital de imagens, o objetivo de um vetor de características é representar o mais fielmente possível a imagem da qual foi extraído. Uma analogia imperfeita seria considerar o vetor como uma “impressão digital” da imagem, de forma que esta possa ser facilmente identificável. Na prática, entretanto, a extração de

características é um problema desafiador, tanto pela própria natureza das imagens quanto pelas várias formas de adquirir as informações (BACKES; JÚNIOR, 2016).

Além dos conjuntos de dados, uma máquina de aprendizado depende de critérios para restringir o uso de um conjunto de dados ou para selecionar atributos de um conjunto. Tais critérios são chamados de vieses indutivos, e serão discutidos em seguida.

2.4.1 Viés Indutivo

Luger (2013) afirma que os espaços de aprendizado tendem a ser grandes. Sem um modo de podá-los a partir de vieses indutivos, o aprendizado baseado em busca seria impossível na prática. Outra razão para a necessidade de um viés é a natureza da própria generalização indutiva: uma generalização não necessariamente preserva a verdade. No aprendizado indutivo, os dados de treinamento são apenas um subconjunto de todos os exemplos de domínio; conseqüentemente, qualquer conjunto de treinamento pode dar suporte a muitas generalizações diferentes. Apenas os dados não são suficientes, sendo necessário fazer suposições adicionais sobre conceitos “prováveis”.

Quando um algoritmo de AM está aprendendo a partir de um conjunto de dados de treinamento, ele está procurando uma hipótese, no espaço de possíveis hipóteses, capaz de descrever as relações entre os objetos e que melhor se ajusta aos dados de treinamento. Cada algoritmo utiliza uma forma ou representação para descrever a hipótese induzida. Por exemplo, redes neurais artificiais representam uma hipótese por um conjunto de valores reais, associados aos pesos das conexões de rede. A representação utilizada define a preferência ou viés (*bias*) de representação de um algoritmo e pode restringir o conjunto de hipóteses que podem ser induzidas pelo algoritmo de aprendizagem (FACELI et al., 2011).

Para que um conjunto de dados de treinamento seja restringido e extraído de imagens, é preciso selecionar que tipo de informação obtida a partir de uma imagem melhor definiria a hipótese alvo, como a forma de objetos apresentada na imagem (grande número de objetos pode ser identificado apenas pelo seu formato) e textura. Dependendo da escolha do critério de definição de um viés, um conjunto de métodos de extração de características estarão disponíveis.

A textura de uma imagem, definida por Tuceryan e Jain (1993) como “a variação espacial de intensidades dos pixels”, será tomada como exemplo para ilustrar a representação de dados em um conjunto: Para Backes e Júnior (2016), algumas texturas naturais (como em uma mamografia) apresentam um persistente padrão estocástico, que resulta em uma textura com aparência de nuvem. Na escolha da textura como viés indutivo, vários métodos para a extração de assinaturas de textura poderão ser adotados, como descritores baseados em histograma, matrizes de co-ocorrência (HARALICK; SHANMUGAM; DINSTEN, 1973), descritores wavelet (CHANG; KUO, 1993), descritores de Fourier (WESZKA; DYER; ROSENFELD, 1976), entre outros. Tais métodos fornecem dados estatísticos relacionados à textura da imagem alvo, como média, variância, assimetria e energia, que irão compor

o conjunto de dados de treinamento de um determinado algoritmo de aprendizado de máquina.

Além do viés de representação, os algoritmos de AM possuem também um viés de busca. O viés de busca de um algoritmo é a forma como o algoritmo busca a hipótese que melhor se ajusta aos dados de treinamento. Ele define como as hipóteses são pesquisadas no espaço de hipóteses (FACELI et al., 2011). Por exemplo, o algoritmo *backpropagation*, que é utilizado para indução de redes neurais artificiais, tem como viés de busca a preferência por redes formadas por três camadas de neurônios: uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída, conforme será apresentado no Tópico 2.4.2. “Assim, cada algoritmo de AM possui dois vieses, um viés de representação e um viés de busca. O viés é necessário para restringir as hipóteses a serem visitadas no espaço de busca. Sem viés não haveria aprendizado ou generalização” (FACELI et al., 2011).

A seguir, será apresentada a teoria associada às Redes Neurais Artificiais e alguns de seus vieses de indução. O uso de tal técnica de aprendizado de máquina serve de base para a tese em questão.

2.4.2 Redes Neurais Artificiais

Algumas técnicas de aprendizagem de máquina realizam a busca por uma hipótese que descreva dados a partir da otimização de uma determinada função. Nesse processo, um problema de aprendizado é formulado como um problema de otimização em que o objetivo consiste em minimizar (ou maximizar) uma função objetivo (FACELI et al., 2011). Segundo Faceli et al. (2011), uma RNA é uma técnica que recorre à otimização de uma função em um dado treinamento, normalmente realizado a partir de uma regra de correção de erros. Pettres (2011) afirma que RNAs apresentam a capacidade de adquirir conhecimento do meio e de poder fazer generalizações, apresentando respostas a situações inéditas. RNAs têm sido utilizadas na solução de problemas das ciências em geral, como na medicina, telecomunicações, climatologia, entre outras.

Pettres (2011) atesta a viabilidade do uso das RNAs em diversos problemas, como no reconhecimento de padrões em conjuntos nebulosos de dados, graças a sua capacidade de aprendizagem através da experiência e adaptabilidade, mesmo na existência de pequenas perturbações ou incompletude de dados.

Segundo Faceli et al. (2011), “As RNAs têm inspiração nas redes neurais biológicas presentes no cérebro”. Frohlich (1997), descreve:

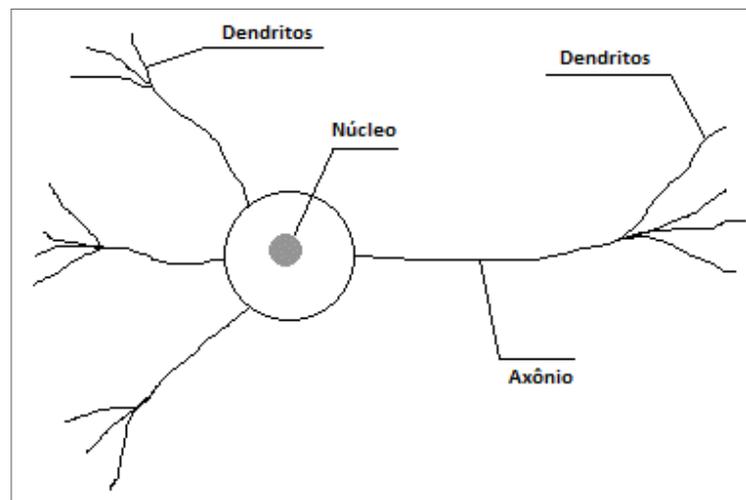
Uma rede neural é uma representação do cérebro humano que tenta simular seu processo de aprendizagem. O termo ‘artificial’ significa que redes neurais são implementadas em programas de computador capazes de lidar com o grande número de cálculos necessários durante o processo de aprendizagem (FROHLICH, 1997).

Luger (2013) afirma que a inteligência das RNAs surge em sistemas de componentes simples e interativos, chamados neurônios, por meio de um processo da adaptação pelo qual as conexões entre os componentes são ajustadas:

O processamento nesses sistemas é distribuído por meio de conjuntos ou camadas de neurônios. A solução de um problema é paralela no sentido de que todos os neurônios dentro de um conjunto ou camada processam suas entradas simultânea e independentemente (LUGER, 2013).

A Figura 13 apresenta uma célula neural que inspira a implementação do componente básico de uma RNA, composta por um núcleo, dendritos para a entrada de informação e um axônio com dendritos para a saída de informação. Segundo Frohlich (1997), tal informação é transmitida entre neurônios conectados na forma de estímulos elétricos ao longo dos dendritos. Informações recebidas por um neurônio são somadas e então transmitidas ao longo do axônio até os dendritos de saída, onde a informação é passada para outros neurônios que sejam ativados pelo estímulo elétrico transmitido. Tal ativação é baseada em um valor limiar de estímulo elétrico para cada neurônio da rede: Caso um estímulo elétrico ultrapasse o valor limiar de estímulo do neurônio que recebeu a informação, o mesmo entra no estado de ativação. Caso um estímulo elétrico seja inferior ao limiar de um neurônio, o componente entrará no modo de inibição, e a informação não será transmitida.

Figura 13 – Estrutura de uma célula neural no cérebro humano.

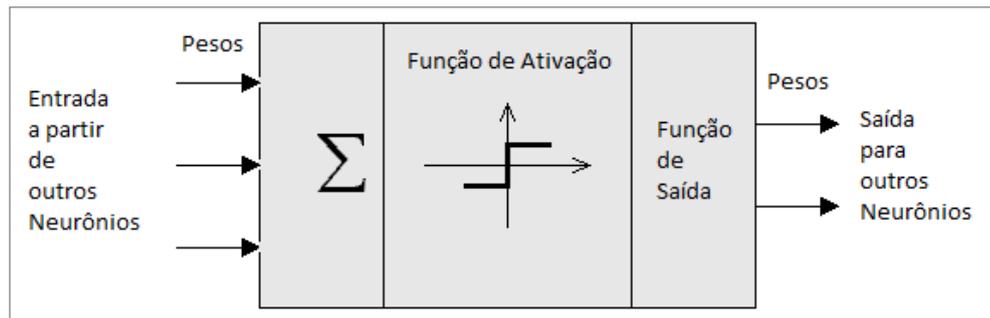


Fonte: (FROHLICH, 1997)

Um modelo idealizado de neurônio que compõe uma rede neural artificial é apresentado na Figura 14. Frohlich (1997) afirma que, assim como no cérebro humano, uma RNA é formada pela conexão de vários neurônios. Os dendritos são representados por conexões conhecidas como pesos. Impulsos elétricos são simulados a partir de valores reais específicos, armazenados nesses pesos na forma de matrizes. A informação, chamada de entrada,

é transmitida para um neurônio a partir dos pesos de entrada. A entrada é processada por uma função de propagação, que adiciona os valores de todos os pesos de entrada. O valor resultante é comparado com um determinado valor limiar pela função de ativação do neurônio. Se a entrada ultrapassa o valor limiar, o neurônio será ativado e enviará uma saída para os pesos de saída. Caso contrário, será inibido e a informação não será transmitida para os próximos neurônios conectados.

Figura 14 – Estrutura de um neurônio em uma rede neural artificial.



Fonte: (FROHLICH, 1997)

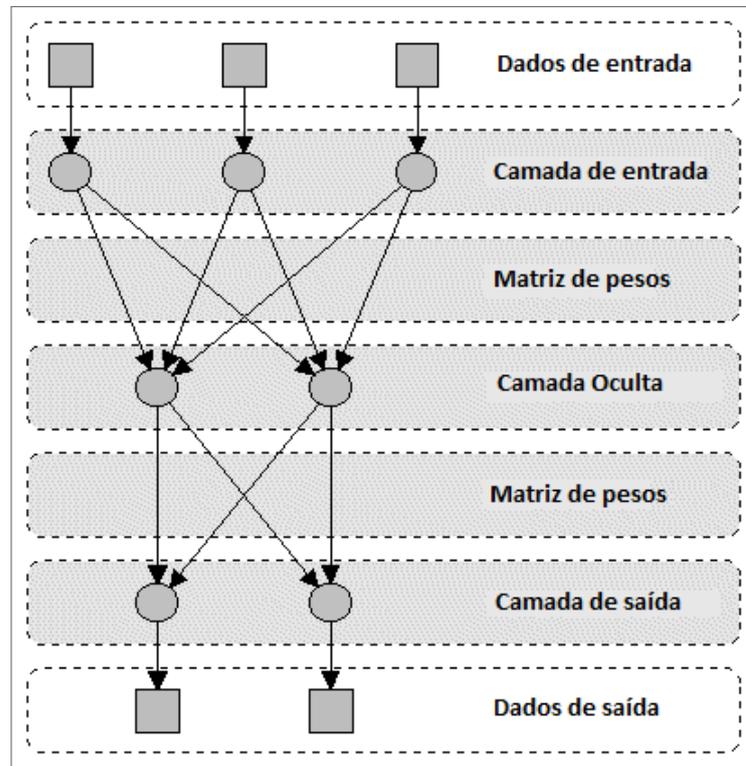
Os neurônios computam funções matemáticas. Tais componentes são dispostos em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria das arquiteturas, essas conexões, que simulam sinapses biológicas, possuem pesos associados, que ponderam a entrada recebida por cada neurônio da rede. Os pesos podem assumir valores positivos ou negativos, dependendo se o comportamento da conexão ser excitatório ou inibitório, respectivamente. Os pesos têm seus valores ajustados em um processo de aprendizado e codificam o conhecimento adquirido pela rede (FACELI et al., 2011).

A arquitetura de uma RNA genérica é apresentada na Figura 15. Segundo Frohlich (1997), cada neurônio em cada camada é conectado a todos os neurônios da camada precedente e da seguinte, exceto as camadas de entrada e saída da rede. As informações são propagadas camada por camada, a partir da camada de entrada até a camada de saída através de zero ou mais camadas intermediárias, chamadas de camadas ocultas. Dependendo do algoritmo de aprendizado, é possível que a informação também seja propagada no sentido inverso.

Uma RNA é, portanto, caracterizada por dois aspectos básicos: arquitetura e aprendizado. Enquanto a arquitetura está relacionada ao tipo e número de unidades de processamento e à forma como os neurônios estão conectados, o aprendizado diz respeito às regras utilizadas para o ajuste dos pesos da rede e que informação é utilizada pelas regras (FACELI et al., 2011).

De acordo com Frohlich (1997), em relação ao tipo de conexão adotado em uma arquitetura, é possível classificar uma RNA em duas classes:

Figura 15 – Arquitetura de uma RNA genérica.



Fonte: (FROHLICH, 1997)

- *Feedforward* – Estrutura de conexão de uma rede neural onde neurônios formam conexões apenas com neurônios de outras camadas;
- *Feedback* – Estrutura de conexão de uma rede neural onde neurônios formam conexões com neurônios da própria camada e de outras camadas.

Um algoritmo de aprendizado adotado por uma RNA pode ser baseado em um determinado método de aprendizado. Segundo (FROHLICH, 1997), tais métodos de aprendizagem podem ser classificados em duas categorias:

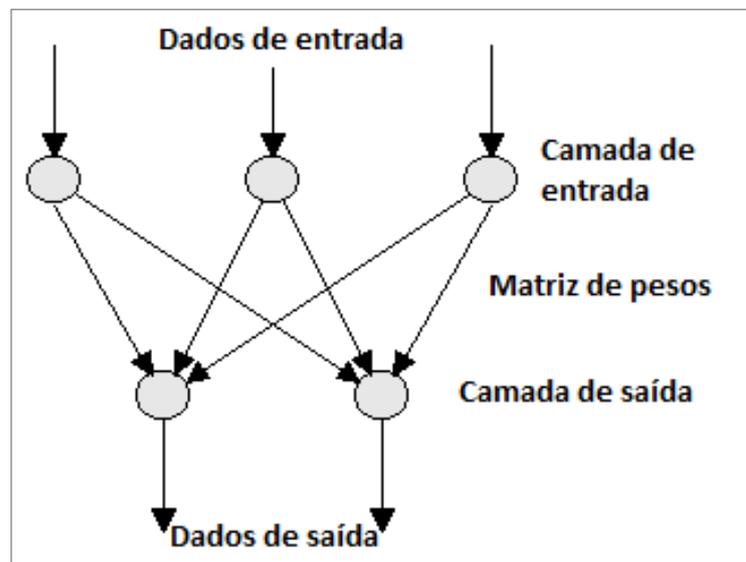
- Aprendizagem supervisionada – A saída de uma RNA é comparada com uma saída alvo ou padrão. Dependendo da diferença gerada na comparação, um erro de rede é computado;
- Aprendizagem não supervisionada – Aprendizagem baseada em auto-organização. Não existe saída alvo nesse método.

Entre exemplos de algoritmos de aprendizagem existentes na literatura, tem-se o modelo de aprendizagem de Hebb (1949), bastante utilizado em redes com o mínimo de camadas possíveis (uma camada de entrada e uma camada de saída), e o modelo *backpropagation* que, segundo Tsoukalas e Uhrig (1997), é considerada adequada para representar

qualquer mapeamento de rede neural artificial (uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída):

- Modelo de aprendizagem de Hebb – Utilizado tanto em aprendizado supervisionado quanto no modo não supervisionado. Segundo Hebb (1949), em sistemas biológicos, quando um neurônio contribui para o disparo de outro neurônio, a conexão entre eles é reforçada. O efeito do reforço da conexão entre dois neurônios pode ser simulado matematicamente ajustando-se o peso nessa conexão por uma constante multiplicada pelo sinal do produto de seus valores de saída. Tal modelo é bastante adotado em redes *feedforward* sem camadas ocultas, como a rede *Perceptron* de Roseblatt (1958), utilizado principalmente em operações lógicas simples ou na classificação de padrões. Um exemplo de uma RNA *Perceptron* é apresentado na Figura 16.

Figura 16 – Exemplo de uma RNA Perceptron.

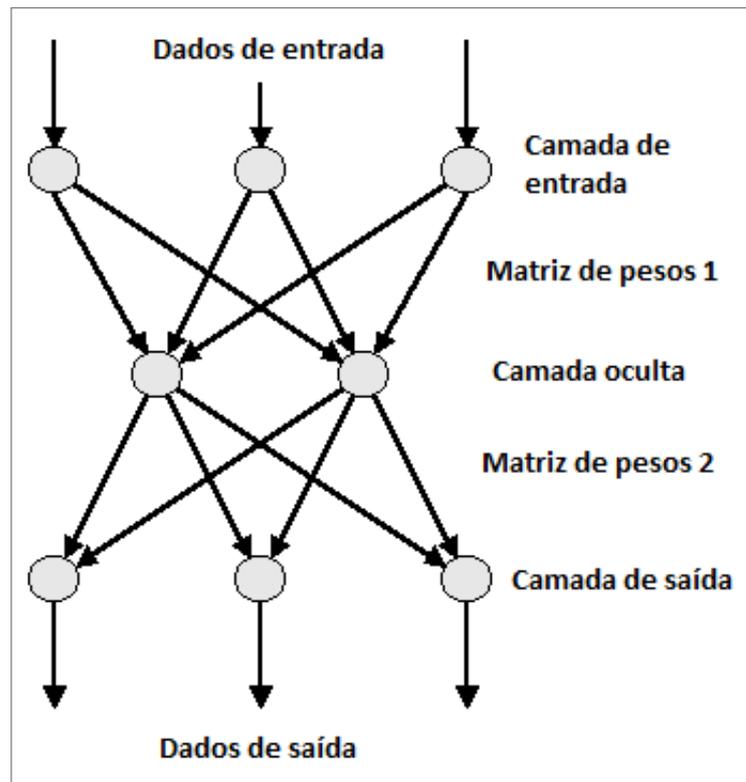


Fonte: (FROHLICH, 1997)

- *Backpropagation* (RUMELHART; HILTON; WILLIAMS, 1986) - Também conhecido por regra delta generalizada, é constituído da iteração de duas fases, uma fase para frente (*forward*) e uma fase para trás (*backward*). Na fase *forward*, cada objeto de entrada é apresentado à rede. O objeto é recebido por cada neurônio da primeira camada oculta da rede, quando é ponderado pelo peso associado a suas conexões de entrada correspondentes. Cada neurônio nessa camada aplica a função de ativação a sua entrada total e produz um valor de saída, que é utilizado como valor de entrada pelos neurônios da camada seguinte. Esse processo continua até que os neurônios da camada de saída produzam cada um seu valor de saída, que é então comparado ao valor desejado para a saída desse neurônio. A diferença entre os valores de saída produzidos e desejados para cada neurônio da camada de saída indica o erro cometido pela rede para o objeto apresentado. O valor do erro de cada

neurônio da camada de saída é então utilizado na fase *backward* para ajustar seus pesos de entrada. O ajuste prossegue da camada de saída até a primeira camada oculta (FACELI et al., 2011). Tal algoritmo é bastante utilizado em redes com camadas ocultas de neurônios, como em RNAs *Perceptron* multicamada introduzidas por Minsky e Papert (1969), gerando resultados satisfatórios em problemas que envolvem operações lógicas complexas ou na classificação de padrões. Um exemplo de uma RNA *Perceptron* multicamada é apresentado na Figura 17.

Figura 17 – Exemplo de uma RNA Perceptron multicamada.



Fonte: (FROHLICH, 1997)

Em problemas de reconhecimento de padrões, é esperado que uma rede neural classifique entradas em uma série de categorias alvo (ou classes). As entradas são normalmente as características do padrão a ser reconhecido, e as classes são representadas por vetores (normalmente binários). Na validação e testes de uma RNA, é feita uma divisão das entradas em 3 tipos de amostras:

- Amostras de treinamento – Tais amostras são apresentadas inicialmente para a rede durante a etapa de treinamento, e a rede é ajustada de acordo com o erro gerado. São utilizadas na atualização dos pesos e *bias* da rede;
- Amostras de validação – Apresentadas à rede durante a etapa de treinamento para medir a generalização da rede e para interromper o treinamento quando a generaliza-

ção não melhora. O erro é monitorado durante o processo de treinamento enquanto as amostras de validação são submetidas à rede;

- Amostras de teste – Apresentadas à rede com o objetivo de prover medição independente do desempenho da rede durante e após o treinamento. Elas não têm qualquer efeito no treinamento da rede.

A escolha sobre a quantidade de amostras de entrada a serem utilizadas para cada tipo irá variar de acordo com o padrão a ser analisado, a arquitetura de rede adotada e resultados obtidos em treinamentos anteriores. A quantidade de camadas ocultas a serem utilizadas na rede também dependerão de tais fatores, podendo interferir na precisão do reconhecimento.

Quando um algoritmo de aprendizagem segue o modelo supervisionado, a saída gerada por uma RNA é comparada com a saída alvo (vetores de classe) afim de verificar se a rede conseguiu atingir uma porcentagem de erro e/ou um erro quadrático médio mais próximo possível de zero, isto é, se o processo de reconhecimento foi preciso.

No tópico a seguir serão apresentados trabalhos com foco no uso de RNAs para a classificação de imagens térmicas. No mesmo, serão discutidas algumas arquiteturas de RNA, além dos algoritmos de aprendizagem adotados, destacando o que já foi pesquisado e desenvolvido para a área fim da referida pesquisa.

2.4.3 Uso de RNAs na Análise e Classificação de Imagens Térmicas

Chen e Wang (2002) utilizaram termogramas para o reconhecimento de faces. Na pesquisa, foram capturadas duzentas imagens térmicas da face de 20 pessoas (16 delas com óculos). A partir das imagens capturadas, foram extraídas as seguintes características: o perímetro da face, a relação comprimento/largura do menor retângulo que continha a face e o triângulo formado a partir dos três pontos de temperatura mais baixos das duas bochechas e do queixo. Uma rede neural *backpropagation feedforward* de 3 camadas (uma camada de entrada, uma camada oculta ou intermediária e uma camada de saída) foi utilizada na ferramenta de reconhecimento. Foram distribuídos 20 neurônios para a camada de saída (baseado na quantidade de faces a serem reconhecidas). Na camada de entrada, foram feitos 3 esquemas de distribuição, um para cada conjunto de características adotado nos treinamentos de rede: 11 neurônios para o treinamento baseado no perímetro do contorno de face, 20 neurônios para a relação comprimento/largura do menor retângulo que continha a face e 26 neurônios para o triângulo formado a partir dos três pontos de temperatura mais baixos das duas bochechas e do queixo. A quantidade de neurônios da camada intermediária foi igual ao número de neurônios da camada de entrada mais o número de neurônios da camada de saída dividido por 2. Os testes demonstraram que a rede neural projetada atingiu uma taxa de reconhecimento de 95% em imagens com face sem óculos e 93% em faces com óculos.

Koay, Herry e Frize (2004) desenvolveram rotinas de computador para analisar e classificar automaticamente imagens térmicas de mama, com o objetivo de detectar e/ou prever a existência de câncer. O estudo analisou imagens térmicas de 19 pacientes com resultado clínico conhecido, extraídas de um banco de dados de 86 pacientes da clínica de triagem do câncer de mama do Hospital de Moncton. As imagens foram capturadas a partir de uma câmera térmica Thermovision 680 Medical de primeira geração. Tais imagens foram capturadas seguindo um rígido protocolo para alcançar bons resultados: Os pacientes precisaram evitar álcool, cafeína, loções de medicação para dor e parar de fumar duas horas antes da captura das imagens. A região do peito foi ligeiramente arrefecida com uma ventoinha durante aproximadamente 10 minutos antes da tomada de imagens. A temperatura ambiente foi de aproximadamente 22°C em uma sala escura. De acordo com os autores, essa abordagem forneceu o melhor contraste de temperatura entre as áreas quentes e frias do corpo. Cada imagem foi capturada com resolução de 128 x 128 pixels. Valores de escala de cinza foram mapeados para valores de temperatura usando o valor de temperatura média obtido da câmera como referência. Uma segmentação parcialmente automatizada das mamas dos pacientes foi utilizada no estudo. Os seguintes parâmetros estatísticos foram computados a partir de cada imagem de mama segmentada: média, desvio padrão, mediana, máximo valor, mínimo valor, assimetria, curtose, entropia, área e calor. Desses, apenas cinco foram considerados altamente correlacionados com um ou mais parâmetros, após uma análise de correlação realizada a partir do software SPSS: média, desvio padrão, assimetria, curtose e calor. Os demais foram considerados redundantes e foram descartados. Os dados correlacionados foram utilizados como valores de entrada de uma rede neural *backpropagation* do tipo *feedforward* com uma camada de entrada, uma camada de saída e pelo menos uma camada intermediária ou oculta. Dois algoritmos de treinamento de *backpropagation* foram comparados para adequação: Levenberg-Marquardt (por gerar uma convergência mais rápida e o menor erro quadrático médio em redes relativamente pequenas) e *Resilient Backpropagation* (por ser considerado o algoritmo mais rápido em problemas de reconhecimento de padrões). A função de transferência utilizada por todos os neurônios foi a função sigmoide. Os valores dos pesos e *bias* de cada ligação de neurônio foram definidos aleatoriamente. Todas as entradas foram normalizadas para estarem na faixa de -1 e 1. Das 19 imagens utilizadas em cada sessão de testes, a rede neural utilizou 18 imagens na etapa de treinamento e uma imagem na etapa de validação. A reinicialização dos pesos e *bias* dos neurônios assegurou que a sessão de treinamento subsequente fosse independente da sessão anterior. A rede foi treinada com 342 imagens (19x18) ao todo. A configuração (sessões de teste) da rede neural foi executada 10 vezes, e o diagnóstico gerado na saída de cada configuração foi comparado com o diagnóstico clínico esperado para avaliar o desempenho global na diferenciação de termogramas normais de termogramas anormais. Caso o treinamento não atingisse a meta estabelecida, a rede neural seria reconfigurada para novos testes: existia a possibilidade de inclusão ou

exclusão de camadas intermediárias ou a redução do número de parâmetros de entrada. A rede neural que demonstrou o poder preditivo mais alto foi configurada em uma rede 1-1-1 (uma camada de entrada, uma camada oculta e uma camada de saída), com dois parâmetros de entrada a serem envolvidos no treinamento da rede: temperatura média e desvio padrão. A rede neural resultante deu o diagnóstico correto para 18 imagens das 19 utilizadas, sendo capaz de fazer todas as previsões corretas em mais da metade dos experimentos.

Palfy e Papez (2007) desenvolveram um sistema inteligente baseado em software para o diagnóstico da Síndrome do Túnel do Carpo (STC), resultado da compressão ou lesão do nervo mediano do pulso, dentro dos confins do túnel do carpo, que provoca dor, dormência, formigamento, sensação de inchaço nas mãos e alterações na regulação da circulação sanguínea na região. Foram capturadas 44 imagens térmicas das mãos de 28 pacientes, sendo 23 imagens de pacientes com STC e 21 imagens térmicas de pessoas saudáveis. Um sistema de segmentação automática, baseado em uma técnica de detecção de bordas, foi desenvolvido para que apenas as imagens das mãos tivessem influência nos cálculos de descritores. Registros de temperatura de 12 regiões das mãos foram utilizados como descritores para treinamento da rede. Foi implementada uma rede neural *perceptron multicamada feedforward* com uma camada de entrada, duas camadas ocultas e uma camada de saída. O tamanho do conjunto de dados de treinamento foi alterado durante alguns experimentos, o que fez com que a quantidade de neurônios na camada oculta variasse em cada caso de teste. No experimento que obteve a maior taxa de sucesso, foram utilizados 9 neurônios na primeira camada oculta e 5 neurônios na segunda camada oculta. Foram atribuídos 12 neurônios para a camada de entrada e 2 neurônios para a camada de saída. O sistema em questão obteve uma taxa média de sucesso de 80%. Os autores concluíram que, apesar dos resultados parecerem sólidos, a quantidade reduzida de imagens utilizadas nos treinamentos influenciou nos resultados.

Pettres (2011) desenvolveu um método não destrutivo para o diagnóstico da integridade subsuperficial de estruturas de concreto utilizando imagens térmicas estacionárias e redes neurais artificiais. As imagens térmicas utilizadas no estudo foram geradas pelo software Ansys® 12, onde foi simulado um bloco com propriedades equivalentes ao concreto contendo um elemento de alta porosidade representando um defeito em seu interior. Foram desenvolvidos algoritmos para a localização de defeitos e para o treinamento das topologias neurais a partir do software MATLAB® 2010. Um algoritmo foi elaborado para a otimização de quatro topologias do tipo *backpropagation feedforward* do tipo 1-2-1 (uma camada de entrada, duas camadas ocultas e uma camada de saída) para realização dos testes numéricos, selecionando automaticamente a quantidade de neurônios para cada camada. Duas delas apresentaram melhor desempenho (a primeira, chamada ANN1, com 13 neurônios na camada de entrada, 13 neurônios na primeira camada oculta, 8 neurônios na segunda camada oculta e 3 neurônios na camada de saída; e a segunda, chamada ANN2,

com 25 neurônios de entrada, 25 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 3 neurônios na camada de saída) e foram selecionadas para validar o método proposto, sendo sintetizadas no aplicativo *Thermography and Artificial Neural Network*, desenvolvido com o intuito de realizar o diagnóstico de estruturas de concreto a partir de imagens térmicas. O aplicativo se mostrou preciso e eficiente na análise feita em imagens simuladas em modelos de maior dimensão e contendo defeitos com geometrias irregulares, indicando satisfatoriamente a localização do defeito e apresentando em média um percentual de êxito na identificação de anomalias de 81,73% nas simulações com dados sintéticos. Resultados similares também foram observados em uma análise experimental, indicando potencialidade do método de diagnóstico não destrutivo proposto.

Rathore e Bhalerao (2015) propuseram a obtenção de parâmetros estatísticos a partir de imagens térmicas e um método de auto-deteção para o diagnóstico automático de artrite reumatoide, uma doença autoimune que ataca e destrói elementos lubrificantes e tecidos saudáveis das articulações de dedos, pulso e pés, causando dor e inflamação. Tais parâmetros estatísticos foram utilizados como dados de entrada de uma rede híbrida Neuro-Fuzzy para a predição da doença. Na pesquisa, foram capturadas imagens térmicas de pacientes com a artrite reumatoide e de pessoas normais. A região a ser diagnosticada foi exposta em um ambiente com temperatura controlada de 20°C. A câmera térmica foi colocada a uma distância de 3 metros para obter uma imagem da mão em posição relaxada. Uma imagem de fundo uniforme foi mantida para facilitar o processo de segmentação das imagens. O algoritmo Fuzzy C-Means foi utilizado para segmentar as mãos das imagens térmicas. A partir das imagens segmentadas, foram extraídos os seguintes parâmetros estatísticos (descritores) baseados em histograma: média, variância, curtose e assimetria. Foi definida uma rede neural *backpropagation feedforward* com uma camada de entrada, uma camada intermediária e uma camada de saída. Foram definidos 4 neurônios para a camada de entrada (1 para cada estatística extraída), 4 neurônios para a camada intermediária e 1 neurônio para a camada de saída. A rede foi treinada para 20 amostras de entrada com as saídas alvo correspondentes a partir do algoritmo Bayesiano de Regularização. A rede neural proposta detectou a doença corretamente com uma taxa de acerto de aproximadamente 60% para o total de 20 imagens térmicas de casos normais e anormais.

A Tabela 1 apresenta um resumo com os métodos e resultados obtidos por cada trabalho descrito na referida seção. Na mesma, é possível constatar a prevalência da arquitetura *perceptron* multicamada nas RNAs projetadas para a classificação de padrões, independente se no âmbito médico ou não. O algoritmo de aprendizado *backpropagation*, em conjunto com a função de propagação sigmoide, também foram bastante utilizados nas etapas de treinamento e indução das redes. O que variou em cada trabalho foi a escolha do viés de indução, isto é, o conjunto de dados adotado para a definição de hipóteses de indução, a forma como tais conjuntos eram extraídos das imagens térmicas, a quanti-

dade de camadas ocultas da rede e a quantidade de neurônios a serem definidos em cada camada. A quantidade de amostras utilizadas nos testes de rede também foi variada.

Tabela 1 – Métodos e resultados dos trabalhos levantados na revisão bibliográfica realizada

	(CHEN; WANG, 2002)	(KOAY; HERRY; FRIZE, 2004)	(PALFY; PAPEZ, 2007)	(PETTRES, 2011)	(RATHORE; BHALERAO, 2015)
Foco	Biometria	Câncer de Mama	STC	Estruturas de Concreto	Artrite Reumatóide
Arquitetura de RNA	Perceptron Multicamada	Perceptron Multicamada	Perceptron Multicamada	Perceptron Multicamada	Perceptron Multicamada
Camadas	1-1-1	1-1-1	1-2-1	1-2-1	1-1-1
Nº de Neurônios	11-15-20, 20-20-20, 26-23-20	1-[1,4]-1	12-[1,9]-2, 12-[1,5]-2	13-13-8-3, 25-25-15-3	4-4-1
Algoritmo de Aprendizagem	Backpropagation	Levenberg-Marquardt e Backpropagation	Backpropagation	Backpropagation	Backpropagation
Função de Ativação	Não informado	Sigmoide	Sigmoide	Tangente hiperbólica	Sigmoide
ROI	Face	Tórax	Mãos	Bloco de concreto simulado	Mãos
Taxa de Sucesso	94%	95%	80%	82%	60%
Quant. de Imagens	200	342	44	100	20

2.5 DISCUSSÃO DO CAPÍTULO

A Persistência do Canal Arterial induz a alteração do fluxo sanguíneo em neonatos, graças ao desvio na circulação sanguínea provocada por um canal que liga a artéria pulmonar à aorta. Tal canal é necessário antes do nascimento do bebê, visto que o feto ainda não utiliza os pulmões para oxigenação do sangue. Após o nascimento de um bebê, fatores químicos naturais induzem o fechamento do canal arterial. O não fechamento espontâneo desse vaso sanguíneo, conhecido como PCA, pode provocar vários problemas à recém-nascidos, como edema pulmonar, hipertensão pulmonar, hemorragia intraventricular, isquemia dos músculos papilares dos ventrículos, além de alterações no fluxo sanguíneo cerebral e de tronco.

Como observado no capítulo em questão, tais alterações de fluxo sanguíneo podem gerar regiões de aumento ou diminuição de temperatura no corpo dos neonatos, sobretudo na região do tronco. Um bebê dito "normal" terá temperatura uniforme por todo o tronco. Já um recém-nascido com alguma doença ou alteração morfológica tenderá a ter uma variação de temperatura por todo o tronco, destacando-se a diferenciação de temperatura entre o tórax e abdômen. Tais alterações de temperatura podem ser capturadas a partir de câmeras térmicas, que registram em imagens e metadados a distribuição de temperatura no corpo humano usando radiação infravermelha emitida pela pele humana. Logo, tal recurso seria de grande valia para o diagnóstico de PCA. Como visto neste capítulo, o uso de imagens térmicas é bastante difundido para o auxílio ao diagnóstico de outras doenças na neonatologia, mas no diagnóstico da PCA é algo inédito até então. A definição de regiões de interesse para avaliação da doença a partir de imagens térmicas, de quais características nessas imagens seriam úteis para representar classes de neonatos, além da estabilização de um protocolo de captura específica para obtenção de informações de temperatura da doença, também são contribuições importantes obtidas graças ao trabalho de pesquisa desenvolvido, a ser apresentado nos Capítulos 3 e 4.

Porém, basear o diagnóstico da PCA apenas pela observação das imagens não é suficiente. Analisar visualmente tais imagens é muito difícil, mesmo para um profissional experiente, visto que as alterações de temperatura provocadas pela PCA são muito sutis em neonatos, especialmente em bebês prematuros. Tal dificuldade, somada a subjetividade de quem analisa tais imagens e/ou o não respeito ao protocolo de captura, podem gerar falsos positivos, quando a análise visual da imagem indica a presença do defeito cardíaco mesmo quando ela não existe de fato, ou falsos negativos, quando o diagnóstico indica a não existência da PCA quando na verdade ela existe, não perdoáveis na medicina.

No capítulo corrente, também foi observado que o uso de ferramentas computacionais que utilizam recursos de aprendizagem de máquina são muito úteis na análise e classificação de padrões, sobretudo em imagens térmicas. A maioria dos trabalhos levantados focou na adoção de redes neurais artificiais, amplamente utilizadas e reconhecidas como valiosas ferramentas de apoio à decisão clínica, já que possuem a habilidade de descobrir padrões

que parecem despercebidos aos especialistas humanos ou para os métodos estatísticos tradicionais. Como a pesquisa em questão foi a primeira a enveredar no uso de aprendizagem de máquina para o auxílio ao diagnóstico de PCA a partir de imagens térmicas, optou-se por adotar a mesma técnica, já validada em outras pesquisas e aplicações médicas, afim de verificar se a eficácia do uso de RNAs na análise de padrões seria mantida na classificação de imagens que apresentem ou não neonatos com PCA. A escolha do uso das RNAs como técnica de AM na referida tese também foi fundamentada a partir dos resultados obtidos em testes comparativos em outros algoritmos de aprendizagem de máquina, como poderá ser observado no Capítulo 5. Mas a adoção de tal técnica, mesmo já sendo utilizada em outros trabalhos, exigiu desta pesquisa a definição de um protocolo de captura específico, de regiões de interesse que iriam gerar dados úteis na classificação, o desenvolvimento de procedimentos para a segmentação automática de tais regiões, de como os conjuntos de atributos seriam compostos e extraídos, de como a aprendizagem seria implementada, de como as amostras de classes distintas seriam balanceadas caso fosse necessário, entre outras decisões de pesquisa, tornando-a distinta em relação às demais existentes, gerando contribuições que auxiliaram o diagnóstico da PCA a partir de um sistema computacional desenvolvido graças as experiências obtidas na produção da referida tese, como poderá ser observado no Capítulo 4, tópico 4.3.

Toda teoria e trabalhos levantados no referencial teórico permitiu estruturar e fundamentar o conjunto de materiais e métodos a serem adotados na referida tese, que será descrito em detalhes no Capítulo 3.

3 METODOLOGIA

Neste capítulo serão apresentados os métodos e procedimentos adotados para o desenvolvimento do trabalho.

3.1 PROCEDIMENTOS PARA A AQUISIÇÃO DE IMAGENS TÉRMICAS

Segundo o *International Academy of Clinical Thermography* (2002), para a promoção da qualidade na captura de imagens térmicas no âmbito clínico, replicabilidade de experimentos, além da garantia de validade científica e integridade dos pacientes envolvidos, é importante que os procedimentos para a aquisição de imagens térmicas sejam padronizados em protocolos de captura. É recomendado que tais protocolos definam:

- Os requisitos para o ambiente de captura, como projeto de sala/quarto/laboratório e controles ambientais;
- As diretrizes para a escolha e configuração de equipamentos;
- O gerenciamento dos pacientes envolvidos, que trata da preparação dos pacientes antes, durante e após as capturas;
- As características das imagens capturadas, como resolução, paleta de cores, tipo de arquivo, região de interesse, entre outros.
- A documentação, isto é, como as imagens capturadas serão persistidas, interpretadas e reportadas.

A seguir, é descrito o protocolo de captura de imagens térmicas definido e adotado pela pesquisa em questão, baseado nas recomendações sugeridas pelo *International Academy of Clinical Thermography* (2002) descritas acima.

3.1.1 Diretrizes para a escolha e configuração de equipamentos

Para a pesquisa em questão, foi utilizada a câmera térmica FLIR ONE iOS, da FLIR®, apresentada na Figura 18, na captura de imagens térmicas de recém-nascidos. Trata-se de uma câmera portátil de baixo custo, que funciona conectada a um *smartphone* ou *tablet*. A mesma permite medir a temperatura de qualquer ponto em uma cena com temperaturas entre -20°C e 120°C , podendo detectar diferenças de temperatura de até 0.1°C . É possível selecionar várias paletas de cores na FLIR ONE para destacar as regiões de temperatura. O diferencial da câmera está na tecnologia proprietária MSX®, que permite combinar imagens das duas lentes que acompanham o dispositivo (RGB e térmica), resultando em

Tabela 2 – Especificações da câmera FLIR ONE iOS.

Faixa de Temperatura de Cena	-20°C a 120°C
Temperatura de Operação	0 a 35°C
Peso	29g
Dimensões	72mm x 26mm x 18mm
Capacidade da Bateria	350 mA-h
Sensitividade	Detecta diferenças de temperatura de até 0.1°C
Padrões e certificados	FCC, CE, RoHS, CAN ICES-3 (B)/NMB-3(B), UL
Compatibilidade do produto	Produtos Apple com o conector do tipo <i>lightning</i>
Dimensões de imagem	480 x 640
Resolução	72 dpi

Fonte: (FLIR, 2016)

imagens com detalhes e resolução aprimorados. Um resumo das especificações da câmera é apresentado na Tabela 2.

Figura 18 – A câmera térmica FLIR ONE iOS.



Fonte: (FLIR, 2016)

A seleção da referida câmera foi motivada pelos seguintes fatores:

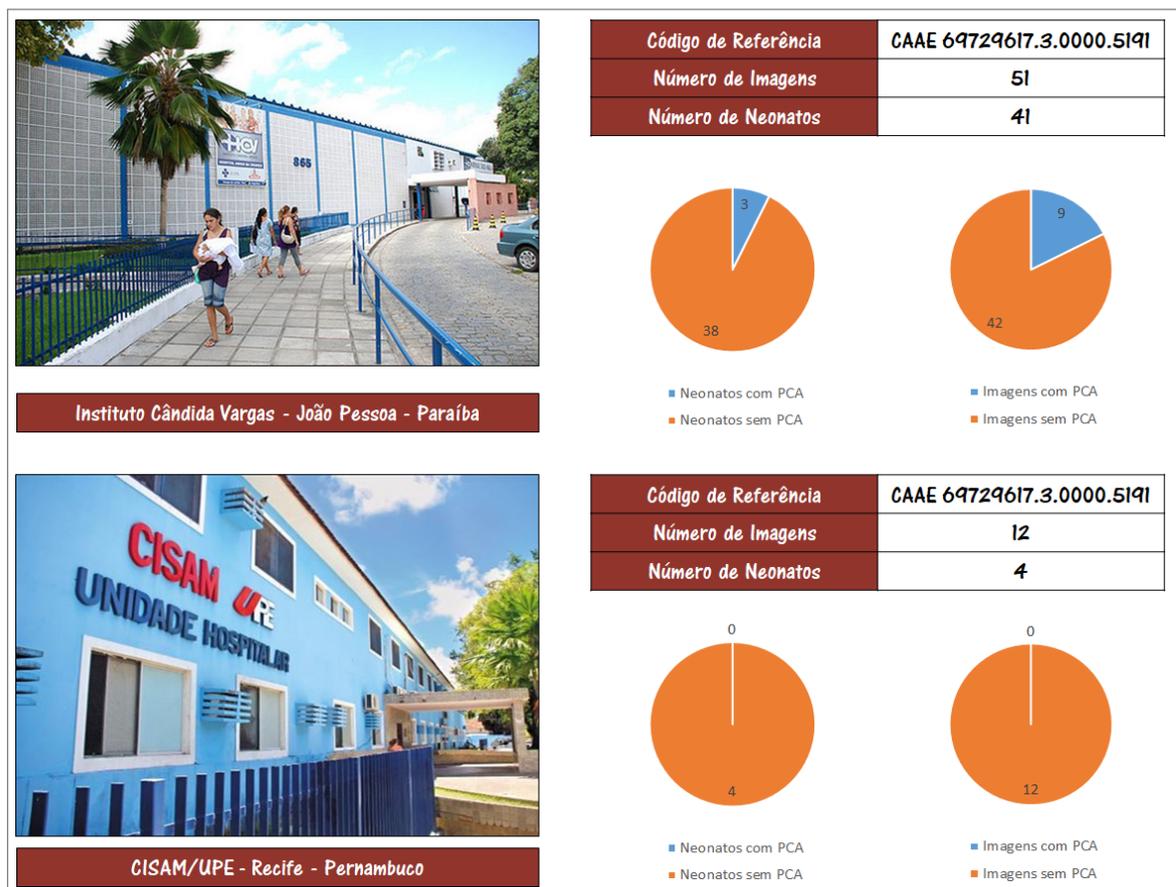
- Dispositivo não invasivo – Uma câmera térmica não emite radiação ionizante, nem necessita de contato direto com a pele;
- Mobilidade – Graças as dimensões da câmera, é possível capturar imagens dos recém-nascidos em qualquer ambiente, sendo uma solução viável em ambulâncias e em atendimentos na modalidade *Home Health Care*¹;
- Custo – Trata-se de uma câmera de baixo custo, se comparado aos preços de câmeras térmicas com especificações mais robustas.

¹ Atendimento domiciliar à saúde.

3.1.2 Ambientes de captura de imagens térmicas

Todas as capturas foram realizadas no Centro Integrado de Saúde Amaury de Medeiros da Universidade de Pernambuco (CISAM/UPE), em Recife-PE, e no Instituto Cândida Vargas (ICV), na cidade de João Pessoa-PB. Os ambientes de captura (enfermarias e Unidade de Terapia Intensiva (UTI)) estavam a uma temperatura de 25°C a 27°C. A interlocução, patrocínio e orientação no âmbito clínico da pesquisa foram realizadas pelo CirCor. O projeto foi aprovado pelo Comitê de Ética em Pesquisa (CEP) do CISAM/UPE com o código CAAE 69729617.3.0000.5191, o que permitiu a realização das capturas. O parecer consubstanciado que fundamenta a referida aprovação é apresentada no Anexo B. As cartas de anuência de cada instituição envolvida na pesquisa podem ser verificadas nos Anexos C, D e E. Informações sobre a captura de imagens são apresentadas de forma gráfica na Figura 19.

Figura 19 – Informações sobre a captura de imagens térmicas realizadas durante a pesquisa.



Fonte: Próprio Autor

3.1.3 Características das imagens capturadas e gerenciamento dos pacientes envolvidos

Foram capturadas 63 imagens térmicas de recém-nascidos a partir da referida câmera. Dessas, 56 imagens são de 38 neonatos sem PCA e 7 imagens de 3 recém-nascidos com PCA. Foram capturadas mais de uma imagem por recém-nascido para o acompanhamento da evolução da PCA e como ela interfere na distribuição de temperatura em imagens térmicas, desde sua detecção até ao tratamento do quadro clínico. A média de peso dos 41 neonatos envolvidos na pesquisa foi de 3,37Kg e a altura média foi de 48,74cm. 64% dos neonatos fotografados eram do sexo feminino e 36% eram do sexo masculino. O período entre o nascimento dos neonatos e a captura das imagens térmicas foi de 4,5 dias na média.

O conjunto *smartphone*/câmera térmica estavam em posição vertical (layout retrato) a uma distância mínima de 0,50 cm e máxima de 0,60 cm dos recém-nascidos, afim de enquadrá-los nas imagens térmicas por completo e seus troncos pudessem estar o mais centralizado possíveis nas imagens capturadas. Cada neonato foi fotografado em posição supino, para que os troncos fossem segmentados sem artefatos. Durante as capturas, os recém-nascidos não estavam usando fraudas. Os bebês também não tinham se alimentado recentemente, para que a temperatura do abdômen não fosse alterada.

Não foi possível realizar a captura de imagens térmicas de recém-nascidos em incubadoras, devido ao material acrílico utilizado não permitir o registro de emissividade por uma câmera térmica. Nesse caso, o recém-nascido foi retirado da incubadora. O tempo limite de captura não ultrapassou 10 segundos. As imagens foram capturadas em momentos padrão para a saída de bebês das incubadoras, como durante sua pesagem, para não causar nenhum impacto aos neonatos.

3.1.4 Documentação

Para cada captura, foram registradas informações sobre o neonato em uma ficha de registro clínico, afim de nortear a definição dos valores de saída alvo da RNA. Um modelo do documento utilizado nos registros está disponível no Apêndice A. Algumas imagens capturadas a partir do protocolo descrito são apresentadas na Figura 20.

3.1.5 Aspectos Éticos da Pesquisa

Neste estudo, foram capturadas várias imagens térmicas de recém-nascidos. A termografia médica não é invasiva nem ionizante. Ela meramente registra a radiação infravermelha emitida naturalmente por todos os corpos. Não há riscos conhecidos diretamente associados à termografia.

A termografia médica requer um período de leve resfriamento do neonato para estabilizar a temperatura da superfície do corpo. A temperatura ambiente foi mantida

Figura 20 – Algumas imagens térmicas obtidas a partir da aplicação do protocolo proposto.



Fonte: Próprio Autor

ligeiramente abaixo da termoneutralidade, como é geralmente o caso em uma unidade de terapia intensiva neonatal, para garantir uma imagem precisa sem induzir nenhum estresse no neonato, provocada por frio contínuo.

A tampa da incubadora foi levantada e o colchão em que o neonato reside foi retirado por um período de até 10 segundos, para permitir a gravação da radiação infravermelha naturalmente emitida pelo corpo do neonato pela câmera infravermelha. Este passo foi necessário uma vez que a radiação infravermelha não passa pelas paredes Plexiglas de uma incubadora e a pele do bebê precisa esfriar um pouco. Se a criança estiver sendo atendida em um aquecedor excedido, o aquecedor será desligado por um breve período (não mais de 1 minuto). Este passo foi necessário porque o calor emitido pelo aquecedor pode interferir com a gravação da radiação infravermelha emitida pelo bebê. Todas as roupas, quando foi o caso, foram removidas, exceto por roupas que cobriam extremidades como a cabeça, as mãos ou os pés, uma vez que não afetam a distribuição térmica sobre o tronco. Em seguida, o colchão foi empurrado de volta para a incubadora e a tampa foi fechada, ou o aquecedor excedido foi religado. Precauções necessárias foram tomadas para garantir que a diminuição da temperatura corporal do neonato durante a sessão de imagem não excedesse os limites aceitáveis. A breve remoção do neonato da incubadora também poderia aumentar o nível de estresse dos indivíduos. No entanto, uma vez que a sessão foi muito curta, não afetou o neonato mais do que procedimentos diários comuns.

As capturas foram realizadas prioritariamente pelo pesquisador principal do projeto. Como o mesmo não é profissional de saúde, as capturas foram obrigatoriamente acompanhadas por médicos e/ou enfermeiros responsáveis pelos setores envolvidos. Profissionais de saúde neonatal estavam presentes em todos os momentos para garantir que os sinais vitais do neonato estivessem dentro de limites aceitáveis. Ao todo, três profissionais que compõem a equipe de pesquisa acompanharam as capturas, sendo duas médicas cardiopediatras e uma médica intensivista neonatal. Informações adicionais sobre as mesmas podem ser obtidas no Anexo A.

Qualquer degradação dos sinais vitais de um neonato resultou na parada imediata da captura de imagens. O grupo de pesquisa se comprometeu a realizar as capturas apenas em momentos padrão para a saída de bebês das incubadoras, como em pesagens ou limpeza dos neonatos.

Os recém-nascidos que obtiverem diagnóstico de PCA pelo sistema computacional proposto foram encaminhados para a realização de exames de ecocardiografia, afim de mensurar a acurácia da rede neural artificial. Dessa forma, foi possível verificar quantos por cento o diagnóstico de termografia se aproxima do diagnóstico atualmente utilizado. As estruturas das unidades de captura atenderam as necessidades da pesquisa do ponto de vista de infraestrutura, não sendo necessário aquisição de nenhuma solicitação especial para execução da pesquisa. O pesquisador abordou os pais de neonatos potenciais e forneceu todas as informações necessárias para que os pais tomassem uma decisão informada, quer participe ou não neste estudo. Nenhuma informação sobre o assunto foi recolhida, a menos que os pais expressamente o aceitassem. Quando os pais do neonato decidiam participar do estudo, foram coletadas algumas informações para cada sessão de imagem, incluindo informações de prontuário. As imagens foram armazenadas em um computador pessoal para análise. Serão mantidos em anonimato, sob sigilo absoluto, durante e após o término do estudo, todos os dados que identifiquem o sujeito da pesquisa usando apenas, para divulgação, os dados inerentes ao desenvolvimento do estudo. Após o término da pesquisa, serão destruídos de todo e qualquer tipo de mídia que possa vir a identificá-los tais como filmagens, fotos, gravações, etc., não restando nada que venha a comprometer o anonimato de sua participação agora ou futuramente.

3.1.6 Análise de Precisão da Câmera Térmica Adotada

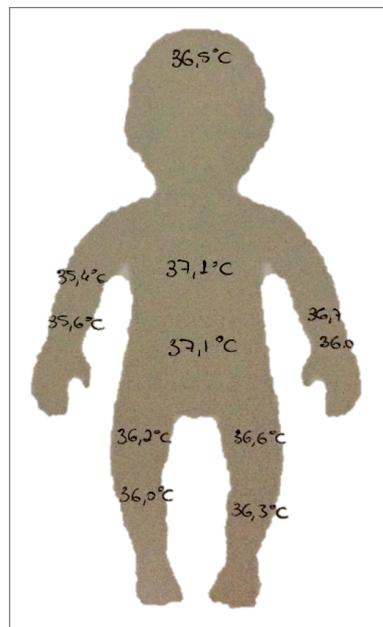
De acordo com a fabricante da câmera térmica adotada na pesquisa, a margem de erro para a captura de informações de temperatura é de $\pm 3^{\circ}\text{C}$ ou $\pm 5\%$, porcentagem típica da diferença entre a temperatura ambiente e a temperatura de cena. Além disso, a mesma não possui configurações padrão de emissividade definidas de acordo com os objetos a serem fotografados, normalmente disponíveis em câmeras mais robustas. Tais restrições poderiam provocar divergências entre as temperaturas obtidas pela câmera térmica e às obtidas por outros dispositivos utilizados para esse fim.

Como o protocolo de captura de imagens definido para a pesquisa em questão adota uma faixa específica para a temperatura ambiente (entre 25°C e 27°C), se faz necessária a análise da margem de erro médio específica para a pesquisa em questão. Obtendo-se o valor médio de erro, cálculos de equivalência poderão ser implementados em software, eliminando ou amenizando a diferença de temperatura obtida pela câmera térmica.

Para a referida análise, foram obtidas as temperaturas de 14 neonatos a termo (não prematuros) e um neonato pré-termo (prematuro) a partir de um termômetro infravermelho sem contato, antes da captura de imagens térmicas, afim de comparar os valores de

temperatura obtidos por cada dispositivo. As regiões de interesse adotadas para a análise foram: testa, tórax, abdômen, braço e antebraço esquerdo, braço e antebraço direito, coxa e perna direita, além de coxa e perna esquerda. As informações de temperatura obtidas pelo termômetro infravermelho foram registradas em um documento de registro clínico, apresentado no Apêndice A, para cada neonato. A Figura 21 apresenta um exemplo de como as temperaturas eram registradas em tal documento. As temperaturas obtidas pela câmera térmica para as mesmas regiões de interesse podiam ser consultadas a partir de aplicativo FLIR Tools, fornecida pela fabricante da câmera térmica. Com os registros de temperatura para cada dispositivo, foi possível calcular a margem de erro da câmera.

Figura 21 – Exemplo de registro de temperaturas obtidas a partir de um termômetro infravermelho.



Fonte: Próprio Autor

A Tabela 3 apresenta a média da diferença de temperatura entre o termômetro infravermelho e a câmera térmica para cada região de interesse analisada, além da média da diferença geral, considerando todas as regiões de interesse. Nela, é possível constatar que, em média, a câmera térmica registrou temperaturas 1,2°C acima das temperaturas registradas pelo termômetro térmico. Tal margem de erro será levada em conta na obtenção de temperaturas geradas pela câmera térmica em questão.

Tabela 3 – Média da diferença de temperatura entre o termômetro infravermelho e a câmera térmica FLIR One iOS.

Região de Interesse	Média da diferença de temperatura (°C)
Testa	+1°C
Tórax	+1,5°C
Abdômen	+1,5°C
Braço direito	+1,5°C
Antebraço direito	+1,2°C
Braço esquerdo	+1,4°C
Antebraço esquerdo	+1,2°C
Coxa direita	+1°C
Perna direita	+1°C
Coxa esquerda	+1°C
Perna esquerda	+1°C
Média Geral	+1,2°C

Fonte: Próprio Autor

3.2 SEGMENTAÇÃO DA REGIÃO DE INTERESSE

Apesar de apresentar grande potencial, o uso de termogramas na medicina ainda é cercado por ceticismo, devido a possíveis inconsistências na captura e análise de tais imagens. Segundo Koay, Herry e Frize (2004), as inconsistências se devem em parte ao equipamento de aquisição de imagens utilizado, aos procedimentos de uso adotados, à dificuldade em processar e interpretar dados de imagens térmicas e, mais importante, falta de protocolos padrão para orientar a revisão final. Este trabalho não está livre de tais inconsistências, uma vez que a presença de roupas, bandagens, lençóis e outros objetos durante as capturas podem alterar os dados de temperatura a serem considerados no diagnóstico. Movimentos involuntários de neonatos durante a captura de imagens também podem fazer com que os membros superiores dos recém-nascidos se sobreponham ao tronco, interferindo no valor da temperatura da região de interesse. Além disso, para garantir a consistência dos dados extraídos de tais imagens, é importante que a região de interesse seja segmentada e analisada separadamente.

Estudos relacionados demonstraram como tais inconsistências dificultam a obtenção de dados válidos a partir de imagens térmicas e confirmam a importância da segmentação automática para garantia de consistência. Nur (2013) adotou uma abordagem semi-automática para a segmentação das regiões abdominal e umbilical de neonatos em imagens térmicas, com o objetivo de extrair informações que caracterizassem a ECN. Abbas e Leonhardt (2014) desenvolveram um sensor térmico virtual que rastreia diferentes perfis geométricos e formas na anatomia externa de um recém-nascido, a fim de capturar sua

temperatura de maneira não invasiva. Já na pesquisa de Rivera, Maynez e Lázaro (2014), um algoritmo foi desenvolvido para segmentação automática de faces neonatais, também com a proposta de captura de temperatura não invasiva.

Todas as fontes de inconsistências a serem consideradas ao extrair características em imagens térmicas também tornam a segmentação automática ainda mais desafiadora. Para enfrentar tais problemas, foi implementado um algoritmo para a segmentação automática de troncos de neonatos em imagens térmicas. Tal algoritmo é baseado na aplicação de uma função limiar, associada à técnica de contornos ativos.

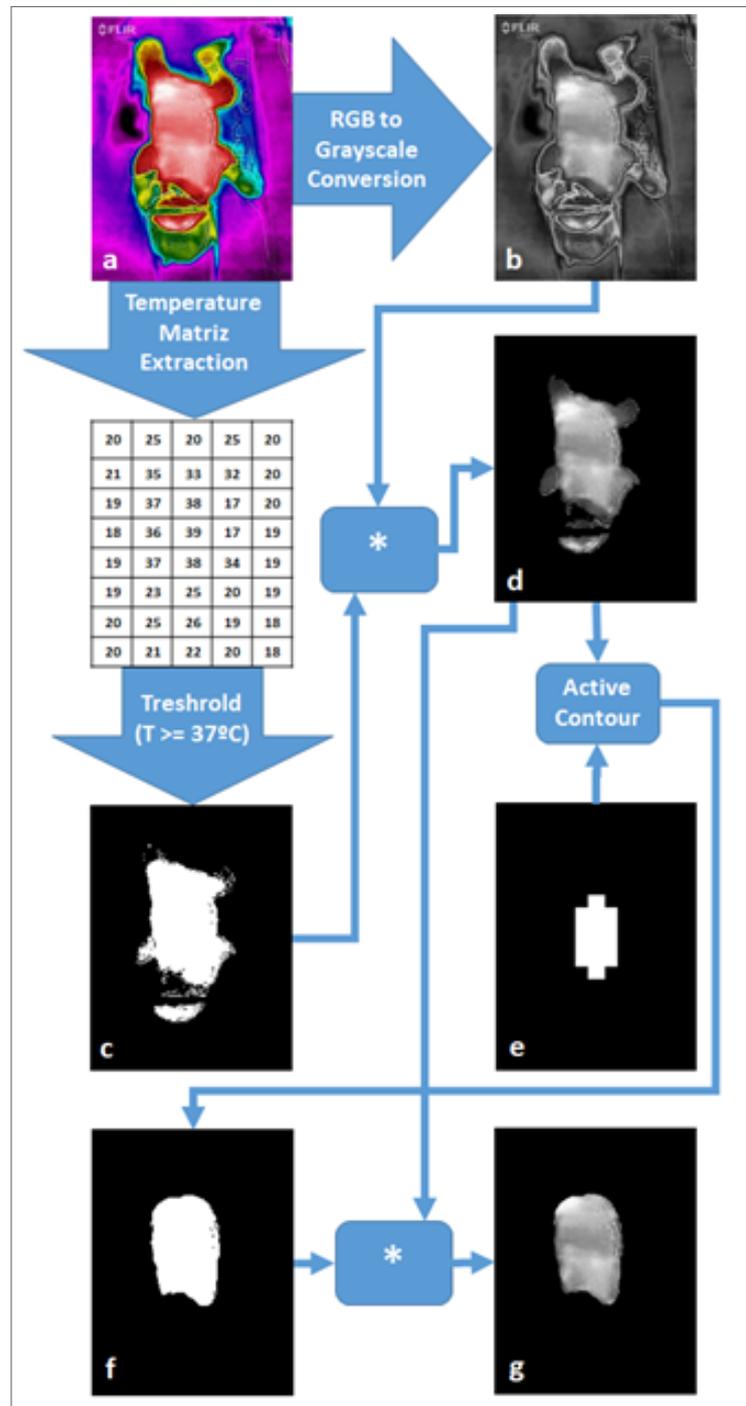
O algoritmo de segmentação automática proposto para o tronco de recém-nascidos é apresentado na Figura 22. A primeira etapa do processo de segmentação visa retirar de uma imagem térmica qualquer artefato que não represente a pele do recém-nascido, como plano de fundo, meias, luvas, bonés, bandagens, ataduras, entre outros, já que as temperaturas de tais artefatos não contribuem para a composição de conjuntos de dados que caracterizam a PCA. Além disso, se o recém-nascido executar um movimento involuntário durante a captura, essa etapa permitirá que os artefatos sejam removidos da região de interesse que se sobrepuseram ao tronco, como os membros. Para isso, uma técnica de limiar global foi implementada. De acordo com Gonzalez e Woods (2002), um valor limite T é selecionado para separar os valores de intensidade agrupados em dois grupos dominantes. Qualquer pixel (x, y) na imagem a ser segmentada em que $f(x, y)$ é maior que T é chamado de ponto do objeto, sendo atribuído o valor 1 na mesma posição (x, y) da saída imagem binária; caso contrário, é chamado de ponto de fundo e o valor 0 é atribuído à imagem binária de saída.

As imagens capturadas pela câmera térmica FLIR ONE possuem metadados com as informações de temperatura para cada pixel (x, y) e são organizadas na forma de matrizes de valores reais, acessíveis a partir de arquivos CSV. Tais metadados são usados na segmentação baseada em limiar (*threshold*). O algoritmo percorre cada célula (x, y) da matriz de temperatura extraída da imagem a ser segmentada. Para cada célula, verifica-se se a temperatura nesse ponto é maior que 36°C , que é a temperatura média aproximada dos neonatos em um ambiente em termoneutralidade (POMERANCE; LIEBERMAN; UKRAINSKI, 1977). Se verdadeiro, o valor 1 para o mesmo (x, y) da imagem binária de saída é definido. Caso contrário, o valor 0 será atribuído ao mesmo ponto na imagem binária de saída. Esse passo é ilustrado na Figura 22. Um exemplo de saída é mostrada na Figura 22 (c).

Cada pixel da imagem binária resultante é multiplicado pelos pixels da imagem a ser segmentada. Como cada pixel com valor 1 da imagem binária representa um ponto compatível com a temperatura de um neonato, o processo de multiplicação irá manter tais pixels da imagem original, desconsiderando pontos que são multiplicados por 0. Então, teremos uma segmentada imagem, semelhante à imagem mostrada na Figura 22 (d).

Na segunda etapa do processo de segmentação, objetiva-se segmentar a imagem de saída gerada na primeira etapa, como mostra a Figura 22 (d), uma vez que ela é composta

Figura 22 – Abordagem proposta para a segmentação de tronco neonatal.



Fonte: Próprio Autor

de outras regiões do neonato além do tronco, como cabeça, pescoço e membros. Para fazer isso, um procedimento de segmentação baseado em região aplica um critério predefinido de crescimento que agrupa pixels ou sub-regiões em regiões maiores. A abordagem básica para esse tipo de procedimento é começar com um conjunto de pontos "semente", para fazer com que as regiões cresçam a partir deles. Cada semente deve ser conectada aos pixels vizinhos que tenham prioridades pré-definidas semelhantes a ela, como intervalos

específicos de intensidade ou cor (GONZALEZ; WOODS, 2002).

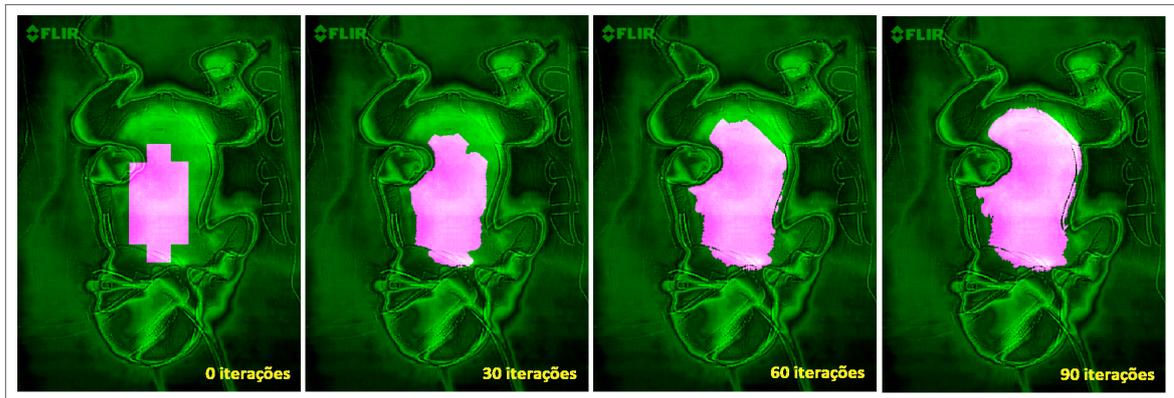
Segundo Bertuol (2007), tal abordagem é muito útil em imagens médicas, já que muitas delas, assim como imagens térmicas, possuem luminosidade localizada e bordas implícitas que dificultam a ação de detectores de borda tradicionais, fazendo com que os mesmos não reconheçam regiões de interesse com exatidão. Além disso, técnicas baseadas em crescimento de região não possuem uma forma padrão ou geometria de referência para nortear o processo de segmentação, fazendo com que a mesma varie conforme o estado atual da região de interesse a ser segmentada e a posição definida para região semente. Isso é muito útil na pesquisa em questão, visto que os troncos dos neonatos variam de tamanho, posição (já que os neonatos fazem movimentos involuntários durante as capturas) e podem possuir artefatos, como bandagens, que geram sub-regiões ou bordas nas regiões a serem segmentadas.

Os critérios de crescimento de região definidos para a pesquisa foram baseados no algoritmo Contornos Ativos definido no método de Chan-Vese (CHAN; VESE, 2001). Nesta técnica, uma máscara binária é usada para representar o estado inicial dos contornos ativos ou o conjunto de pontos iniciais. É necessário definir uma posição inicial e dimensões padrão para essa máscara, para garantir que ela esteja próxima a regiões que possam conter imagens de troncos neonatais. Este critério é importante para obter resultados de segmentação mais rápidos e precisos. Uma máscara binária com as mesmas dimensões das imagens a serem segmentadas (640x480 pixels) foi adotada, com uma região de sementes formada por dois retângulos sobrepostos com 140x100 pixels e 200x200 pixels de tamanho, posicionados no centro da máscara, como mostrado na Figura 22 (e). As dimensões da região de sementes foram definidas por testes empíricos realizados nas imagens obtidas a partir do protocolo de captura adotado. Esse procedimento permitiu que a região da máscara se sobrepusesse ao centro do tronco neonatal na maioria das imagens a serem segmentadas.

Também é necessário definir a quantidade de iterações a serem usadas no crescimento da região a partir da máscara de sementes. Evidências empíricas, observadas em testes pela pesquisa em questão, mostraram que 95 iterações resultaram em segmentações mais satisfatórias, uma vez que valores menores levaram o algoritmo a desconsiderar algumas regiões do tronco e valores mais altos incluíram regiões que não faziam parte do tronco dos neonatos, como pescoço e membros. Assim, 95 iterações foram o valor padrão adotado para o algoritmo proposto.

Uma vez que os valores de máscara e as iterações foram definidos, o algoritmo sobrepõe a máscara na imagem a ser segmentada, esticando-a em cada iteração de acordo com a similaridade de intensidade de cor entre os pixels posicionados ao lado da máscara de sementes. A forma como a máscara de sementes sobrepõe a imagem a ser segmentada e preenche a região de interesse a cada iteração do algoritmo é ilustrada na Figura 23. Como resultado, uma imagem binária, similar àquela mostrada na Figura 22 (f) é gerada.

Figura 23 – Saída do algoritmo dos contornos ativos para determinadas iterações.



Fonte: Próprio Autor

No final do processo de segmentação, o algoritmo realiza uma nova multiplicação, desta vez entre os pixels da imagem de saída gerada pelo módulo de contornos ativos, como mostrado na Figura 22 (f), e os pixels da imagem de saída gerada pelo módulo de limiar, exemplificada na Figura 22 (d). A imagem resultante representa a região do tronco do neonato, como mostrado na Figura 22 (g).

3.3 VIESES INDUTIVOS DA PESQUISA

Após a obtenção dos vetores de temperatura para cada imagem térmica de tronco obtida, observou-se que cada vetor possuía um grande número de elementos (em média, 6860 elementos por vetor), tornando o treinamento de RNA computacionalmente inviável a partir do mapa de temperatura em questão. Portanto, foi necessário reduzir a quantidade de elementos contidos nos vetores de característica e organizá-los para permitir que os mesmos pudessem ser utilizados em treinamentos de RNA.

As técnicas estatísticas que se ocupam desses aspectos constituem a análise exploratória de dados. A análise exploratória de dados consiste em resumir e organizar os dados coletados através de tabelas, gráficos ou medidas numéricas e, a partir dos dados resumidos, procurar alguma regularidade ou padrão nas observações. A partir dessa interpretação inicial, é possível identificar se os dados seguem algum modelo conhecido, que permita estudar o fenômeno em análise, ou se é necessário sugerir um novo modelo (REIS, 2018).

Segundo Reis (2018), um conjunto de dados pode ser resumido através das distribuições de frequências, que relacionam os valores que a variável pode assumir com a frequência (contagem) com que foram encontrados naquele conjunto, ou a partir das medidas ou parâmetros estatísticos. As principais medidas estatísticas são a média, o desvio padrão, a variância e a proporção.

Ainda segundo Reis (2018), as medidas estatísticas podem ser classificadas em medidas

de posição, medidas de dispersão e separatrizes:

- Medidas de Posição – Possuem valores numéricos que representam a tendência de um conjunto, ou valor típico. Dentre as medidas de posição mais importantes, têm-se a Média, Mediana e Moda;
- Medidas de Dispersão - Mensuram a disposição dos dados no conjunto ou da sua variabilidade, isto é, se os dados estão concentrados em torno de um valor ou se estão distribuídos. As medidas mais importantes são Intervalo, Variância, Desvio Padrão e Coeficiente de Variação;
- Separatrizes – São medidas que dividem um conjunto de dados em um certo número de partes iguais: Quartis (4 partes), Decis (10 partes), Centis (100 partes).

Para quantificar o grau de assimetria térmica em cada imagem segmentada de tronco, foram calculados parâmetros estatísticos de posição, dispersão e separatrizes a partir das informações de temperatura do tronco dos neonatos. A obtenção de tais parâmetros permitiu reduzir a quantidade de atributos a serem usadas nas RNAs propostas em apenas 8 parâmetros: média, variância (medida de dispersão destinada a comparar diferentes distribuições), desvio padrão (grau de dispersão das temperaturas em relação a temperatura média), assimetria (medida da desigualdade de dados em relação à temperatura média), curtose (grau de achatamento de uma distribuição), amplitude, além dos valores de temperatura mínima e máxima do tronco. Tal redução também viabilizou a simulação de conjuntos de dados característicos para neonatos com PCA, visto a quantidade reduzida de imagens no banco de imagens da pesquisa para a referida classe.

A hipótese a ser validada é que tais parâmetros possibilitariam medir o nível de assimetria da região de interesse, uma vez que uma grande dispersão das temperaturas capturadas faria com que os valores mínimo e máximo de temperatura fossem muito divergentes entre si e entre a temperatura média, ou que o parâmetro estatístico de assimetria, se obtido a partir de um tronco com temperatura simétrica, tenderia a zero, evidenciando que o neonato não teria PCA, por exemplo.

A seguir são apresentadas descrições mais detalhadas sobre as principais medidas estatísticas adotadas para definição dos conjuntos de dados de treinamento de RNA:

- Média - A média aritmética simples é definida como a soma dos valores observados dividida pelo número desses valores. Seja um conjunto de n valores de uma variável quantitativa X , a média do conjunto será representada pela fórmula

$$\bar{x} = \frac{\sum_{i=1}^n X_i}{n},$$

onde X_i é um valor qualquer do conjunto e $\sum_{i=1}^n X_i$ é a soma dos valores do conjunto.

Segundo Reis (2018), o valor da média pode ser visto como o ponto central de cada conjunto de dados, ou seja, o ponto de equilíbrio do conjunto;

- Amplitude - Consiste em identificar os valores extremos de um conjunto (mínimo e máximo) (REIS, 2018). Na pesquisa em questão, a amplitude foi expressa pela diferença entre as temperaturas mínima e máxima;
- Variância - É a média aritmética dos quadrados dos desvios de cada valor em relação à média, proporcionando uma medida da dispersão dos dados em torno da média (REIS, 2018), representada pela fórmula

$$v = \frac{\sum_{i=1}^n (X_i - \bar{x})^2}{n - 1}$$

Onde X_i é um valor qualquer de um conjunto de dados. Quanto maior a variância, mais dispersos os dados estão em torno da média, isto é, maior a dispersão do conjunto.

- Desvio Padrão - Trata-se da raiz quadrada positiva da variância, apresentando a mesma unidade dos dados e da média, permitindo avaliar melhor a dispersão dos dados (REIS, 2018), sendo representado pela fórmula

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{x})^2}{n - 1}}$$

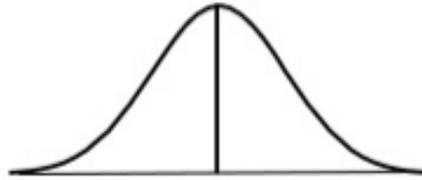
Segundo Reis (2018), as mesmas observações feitas para a variância são válidas para o desvio padrão. Mas, para fins de análise exploratória de dados, caracterizar a dispersão apenas através da variância não é muito adequado. Devido a isso, costuma-se calcular o desvio padrão associado à variância.

- Assimetria - Permite distinguir as distribuições assimétricas. Uma distribuição é simétrica quando existe uma exata repartição de valores em torno do ponto central, ou seja, a média, a mediana e a moda coincidem, como é ilustrado na Figura 24. Diz-se que a assimetria é positiva quando predominam os valores mais altos das observações, como é apresentada na Figura 25. A assimetria será negativa quando predominam os valores mais baixos, como exemplifica Figura 26. Para distribuições assimétricas, a média tende a situar-se do mesmo lado do viés (ou calda) (ARALDI, 2018). A fórmula de assimetria é dada por

$$a = \frac{1}{n} \sum \frac{X_i - \bar{x}}{s}$$

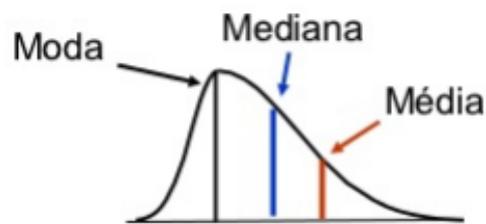
Figura 24 – Gráfico de uma distribuição simétrica.

Média = Mediana = Moda



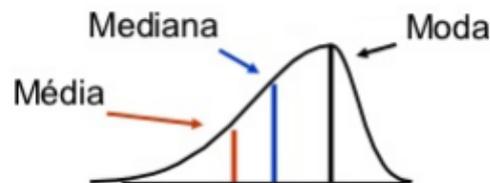
Fonte: (CUNHA, 2017)

Figura 25 – Gráfico de uma distribuição assimétrica à direita ou positiva.



Fonte: (CUNHA, 2017)

Figura 26 – Gráfico de uma distribuição assimétrica à esquerda ou negativa.



Fonte: (CUNHA, 2017)

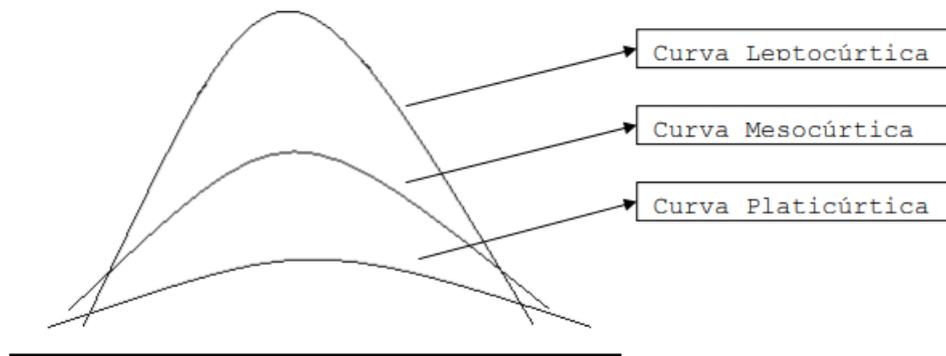
- Curtose - Analisar um conjunto quanto a curtose significa verificar sua curva de frequência. Ou seja, saber se a curva de frequência que representa o conjunto é mais afilada ou achatada em relação a uma curva padrão, também chamada de normal (BERTOLO, 2018), como exemplificado na Figura 27.

O índice percentílico de curtose tem como fórmula:

$$C = \frac{(Q_3 - Q_1)}{2(D_9 - D_1)},$$

Onde Q_3 é o terceiro quartil, Q_1 é o primeiro quartil, D_9 é o nono decil e D_1 é o primeiro decil, ou seja, serão considerados no cálculo da curtose medidas separatrizes (BERTOLO, 2018).

Figura 27 – Curvas de Curtose.



Fonte: (BERTOLO, 2018)

3.4 SIMULAÇÃO DE CONJUNTOS DE DADOS DESBALANCEADOS

Frequentemente, conjuntos de dados do mundo real são predominantemente compostos de exemplos "normais", com apenas uma pequena porcentagem de exemplos "anormais". Devido à quantidade reduzida de imagens térmicas de neonatos com PCA utilizada na pesquisa (apenas 7 casos, contra 56 casos de bebês sem PCA), o conjunto de dados obtidos a partir do módulo de segmentação automática de imagens ficou desequilibrado (as categorias de classificação não foram representadas igualmente), provocando problemas de superposição no treinamento da RNA proposta.

Segundo Chawla et al. (2002), o desempenho de um algoritmo de aprendizagem de máquina é tipicamente avaliado pela sua acurácia preditiva. No entanto, isso não é apropriado quando os dados estão desbalanceados e/ou os custos de erros diferentes variam acentuadamente. Para contornar tal situação, pesquisadores de AM abordaram a questão do desequilíbrio de classes de duas maneiras. Uma delas é atribuir custos distintos aos exemplos de treinamento (PAZZANI et al.; DOMINGOS, 1994, 1999 apud CHAWLA et al., 2002). A outra é re-amostrar o conjunto de dados original, seja por processo de *over-sampling* da classe minoritária e/ou *under-sampling* da classe majoritária (KUBAT; MATWIN; JAPKOWICZ; LEWIS; CATLETT; LING; LI, 1997, 2000, 1994, 1998 apud CHAWLA et al., 2002).

A pesquisa em questão contornou o desequilíbrio de classes a partir da técnica de *over-sampling* proposta por Chawla et al. (2002) conhecida como *Synthetic Minority Over-sampling Technique* (SMOTE), apresentada em detalhes na Figura 28. Nela, a classe minoritária é sobre-amostrada tomando cada amostra minoritária e introduzindo exemplos sintéticos ao longo dos segmentos de linha, unindo qualquer ou todos os k vizinhos mais próximos da classe minoritária, como exemplificado na Figura 29, considerando um banco de amostras reduzido, e na Figura 30, apresentando a geração de amostras simuladas para um banco de instâncias ampliado. Em resumo, o SMOTE gera amostras sintéticas da seguinte forma:

- Toma-se a diferença entre o vetor de característica (amostra) em consideração e seu vizinho mais próximo;
- Multiplica-se a diferença por um número aleatório entre 0 e 1, adicionando-o ao vetor de característica que está sendo considerado;

Figura 28 – O algoritmo SMOTE.

```

Algorithm SMOTE(T, N, k)
Input: Number of minority class samples T; Amount of SMOTE N%; Number of nearest
         neighbors k
Output: (N/100) * T synthetic minority class samples
1.  (* If N is less than 100%, randomize the minority class samples as only a random
    percent of them will be SMOTEd. *)
2.  if N < 100
3.    then Randomize the T minority class samples
4.      T = (N/100) * T
5.      N = 100
6.  endif
7.  N = (int)(N/100) (* The amount of SMOTE is assumed to be in integral multiples of
    100. *)
8.  k = Number of nearest neighbors
9.  numattrs = Number of attributes
10. Sample[[ ]]: array for original minority class samples
11. newindex: keeps a count of number of synthetic samples generated, initialized to 0
12. Synthetic[[ ]]: array for synthetic samples
    (* Compute k nearest neighbors for each minority class sample only. *)
13. for i ← 1 to T
14.   Compute k nearest neighbors for i, and save the indices in the nnarray
15.   Populate(N, i, nnarray)
16. endfor

    Populate(N, i, nnarray) (* Function to generate the synthetic samples. *)
17. while N ≠ 0
18.   Choose a random number between 1 and k, call it nn. This step chooses one of
    the k nearest neighbors of i.
19.   for attr ← 1 to numattrs
20.     Compute: dif = Sample[nnarray[nn]][attr] - Sample[i][attr]
21.     Compute: gap = random number between 0 and 1
22.     Synthetic[newindex][attr] = Sample[i][attr] + gap * dif
23.   endfor
24.   newindex++
25.   N = N - 1
26. endwhile
27. return (* End of Populate. *)
    End of Pseudo-Code.

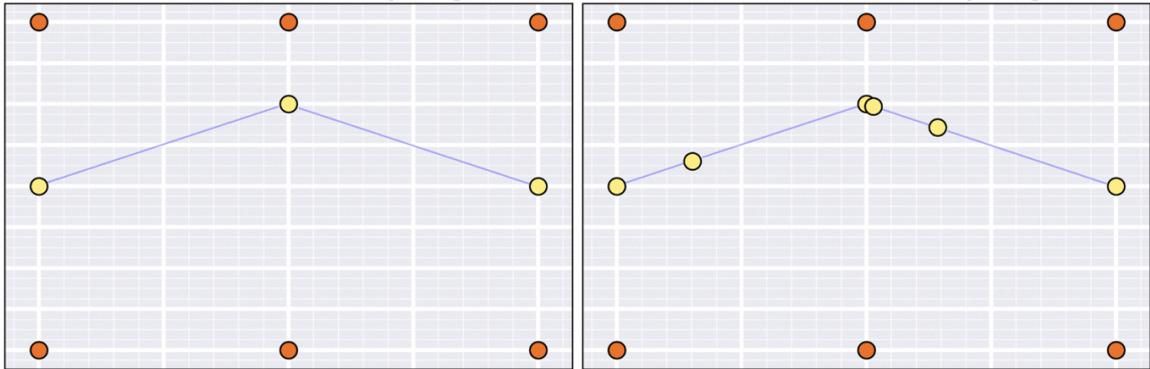
```

Fonte: (CHAWLA et al., 2002)

A multiplicação permite a seleção randômica de um ponto ao longo de um segmento de linha entre duas características específicas. Essa abordagem força a região de decisão da classe minoritária a se tornar mais genérica. Como exemplo, vamos considerar o vetor de característica $v1 = (6,4)$ e $v2 = (4,3)$ como seu vizinho mais próximo. Desta forma:

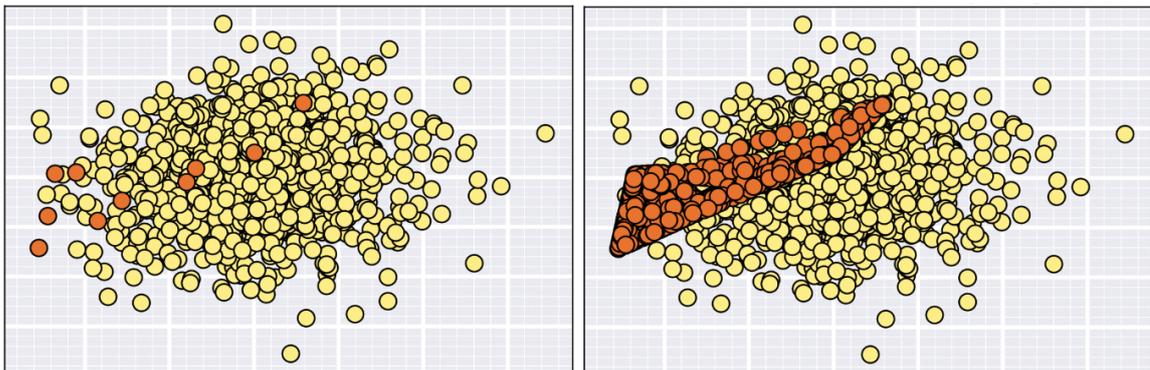
- $v1(1) = 6$ e $v2(1) = 4 \Rightarrow v2(1) - v1(1) = -2$

Figura 29 – Exemplo ilustrativo de como o SMOTE gera amostras simuladas, considerando um banco de instâncias reduzido.



Fonte: (CHÁVEZ, 2019)

Figura 30 – Exemplo ilustrativo de como o SMOTE gera amostras simuladas, considerando um banco de instâncias ampliado.



Fonte: (CHÁVEZ, 2019)

- $v1(2) = 4$ e $v2(2) = 3 \Rightarrow v2(2) - v1(2) = -1$

A amostra sintética $v3 = (x,y)$ será gerada da seguinte forma:

- $v3 = v1 + \text{random}(0,1) * (-2,-1)$

3.5 QUANTIDADE DE AMOSTRAS E ESTIMATIVA DE DESEMPENHO

Segundo Brownlee (2019), um dos principais desafios da aprendizagem de máquina supervisionada é definir a quantidade de amostras ou o tamanho do conjunto de dados a ser utilizado no treinamento de redes neurais artificiais. Poucas instâncias resultarão em baixa precisão em treinamentos de RNAs. Também podem ser obtidas precisões “otimistas” demais, talvez porque o modelo “decorou” o conjunto de treinamento (problema conhecido pelo termo em inglês *underfitting*) ou o conjunto não seja suficientemente representativo para o problema a ser investigado. Muitas instâncias resultarão em boa precisão, mas

talvez um pouco menor do que o ideal, talvez porque o modelo escolhido não tenha a capacidade de aprender as nuances de um conjunto de dados de treinamento tão grande, ou o conjunto seja super-representativo (*overfitting*), provocando inclusive lentidão no processo de aprendizagem.

Porém, saber se um conjunto possui dados suficientes ou não depende de vários fatores, como a natureza dos dados que formam o conjunto, os tipos e a quantidade de atributos de cada instância, além do algoritmo de aprendizagem adotado. Logo, é necessário investigar a quantidade de amostras ideal em um processo de aprendizagem supervisionada, avaliando o desempenho de modelos de aprendizagem a partir de testes de treinamento em conjuntos de dados com tamanhos diferentes.

Não há um consenso sobre melhor técnica para realizar tal investigação, devido as mesmas questões descritas. Porém, Brownlee (2017) sugere a análise de estudos sobre problemas similares como estimativa para a quantidade de dados necessária. É comum a realização de estudos sobre como o desempenho de um dado algoritmo é influenciado com o tamanho de um conjunto de dados. Tais estudos podem informar, na média, quantos dados são necessários para o uso de um determinado algoritmo. Seguindo tal método e considerando os trabalhos levantados no Capítulo 2, tópico 2.4.3, foram adotados conjuntos de dados compostos por 141 instâncias na média em problemas de classificação de imagens térmicas a partir de RNAs. O trabalho com melhor desempenho na classificação de imagens térmicas obteve 95% de precisão com 345 amostras (KOAY; HERRY; FRIZE, 2004), enquanto o trabalho com pior desempenho obteve 60% com apenas 20 instâncias (RATHORE; BHALERAO, 2015). Tal levantamento demonstrou também que RNAs tendem a ter desempenho acima de 80% quando conjuntos de dados possuem o mínimo de 100 amostras.

Outra forma de fundamentar a dimensão de um conjunto de dados de treinamento sugerida por Brownlee (2019) é a partir da plotagem de um gráfico de linha que apresente a relação entre a quantidade de amostras de um conjunto de dados e a precisão de classificação obtida a partir do mesmo conjunto, conhecida como curva de aprendizagem. Tal gráfico deve mostrar uma tendência crescente a um ponto de retorno decrescente e, talvez, até mesmo uma pequena queda final no desempenho, similar a uma curva exponencial. A partir desse gráfico, é possível projetar a quantidade de dados necessária antes de atingir um ponto de inflexão de retornos decrescentes.

O trabalho em questão, a partir dos métodos sugeridos por Brownlee (2019), delimitou o conjunto de dados a ser utilizado nos treinamentos de aprendizagem de rede em 112 instâncias, sendo 7 instâncias extraídas a partir de imagens térmicas de neonatos com PCA, 49 instâncias simuladas de bebês com PCA (por questões de balanceamento de classe, discutidas anteriormente na Seção 3.4) e 56 instâncias extraídas a partir de imagens térmicas de recém-nascidos sem PCA. Tal quantidade supera a média adotada nos trabalhos relacionados levantados. Além disso, a curva de aprendizagem gerada, a ser

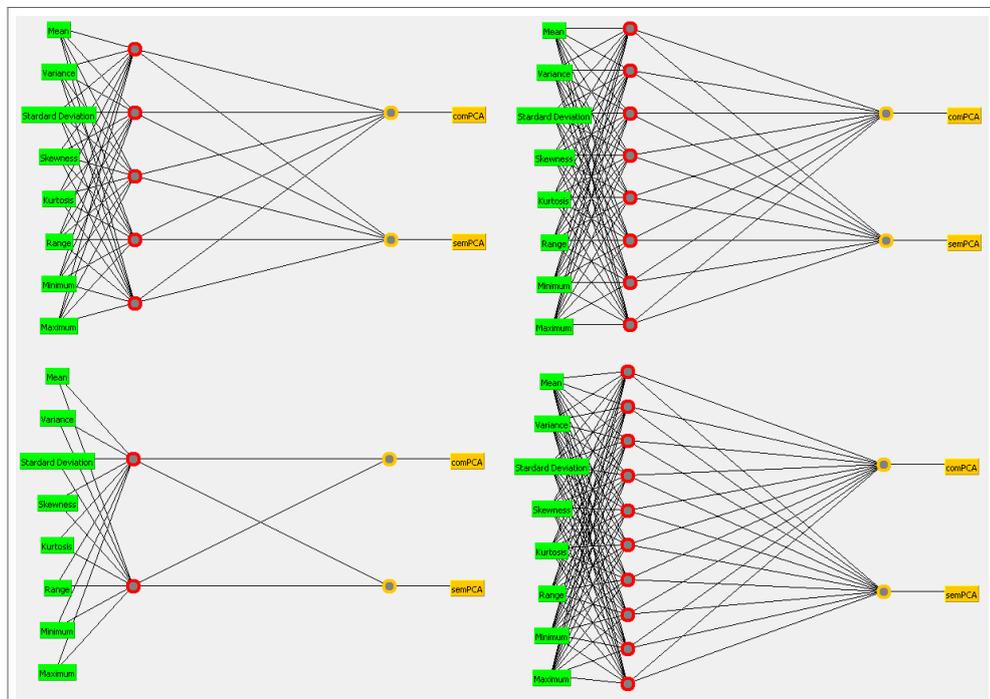
apresentada em detalhes no Capítulo 4, sugere que a RNA proposta, descrita a seguir no tópico 3.6, pode aprender o problema de classificação razoavelmente bem, sem riscos de *overfitting*, com 112 amostras.

3.6 REDE NEURAL ARTIFICIAL PROPOSTA

A rede neural artificial proposta possui uma arquitetura *Perceptron* Multicamada *Feedforward*, uma vez que é um RNA que cumpre bem os processos de reconhecimento de padrões em imagens térmicas (KOAY; HERRY; FRIZE, 2004; PALFY; PAPEZ, 2007; RATHORE; BHALERAO, 2015). Uma rede 1-1-1 foi definida (uma camada de entrada, uma camada oculta ou intermediária e uma camada de saída).

Em relação ao número de neurônios por camada, 8 neurônios foram definidos para a camada de entrada (com base no número de atributos) e 2 neurônios para a camada de saída (o número de classes existentes, com e sem PCA). Três configurações de neurônios foram testadas para a camada oculta, a fim de verificar melhoras na taxa de precisão da rede: 5 neurônios (a soma do número de neurônios de entrada e saída divididos por dois), 8 neurônios (o número de atributos), 2 neurônios (o número de classes) e 10 neurônios (a soma entre o número de atributos e o número de classes), como mostrado na Figura 31.

Figura 31 – Configurações de RNA testadas em experimentos.



Fonte: Próprio Autor

Cada configuração de RNA foi treinada a partir de uma implementação do algoritmo *backpropagation* (RUMELHART; HILTON; WILLIAMS, 1986) e cada neurônio da rede possuía uma função sigmoide como função de ativação. Segundo (FACELI et al., 2011), para que

um algoritmo baseado em retropropagação possa ser usado em uma rede, a função de ativação de cada neurônio deve ser contínua, diferenciável e, de preferência, não decrescente. A função sigmoide obedece a tais requisitos. As taxas de aprendizado e de momentum definidas para o algoritmo de retropropagação é de 0,3 e 0,2, respectivamente.

Segundo Haykin (2001 apud SILVA, 1998), uma das dificuldades de uso de RNAs consiste em identificar o melhor ponto de parada de treinamento, pois o erro de treinamento inicia com um valor alto, decresce rapidamente, e continua diminuindo lentamente, tendendo a atingir um mínimo local na superfície de erro. Segundo Shepherd (1997 apud SILVA, 1998), os métodos de treinamento de rede mais eficientes nesse sentido para RNAs do tipo *Perceptron* Multicamada são conhecidos como métodos de segunda ordem. Segundo Silva (1998), tais algoritmos recorrem a um rigor matemático baseado em modelos de otimização não-linear irrestrita bem definidos, não apresentando assim um vínculo natural com a inspiração biológica inicialmente proposta para as RNAs. Dentre os métodos de segunda ordem existentes, a que gerou melhores resultados no treinamento das RNAs propostas na pesquisa foi o Método de Gradiente Conjugado, especificamente uma variação proposta por Moller (1993), chamado de Método do Gradiente Conjugado Escalonado (SGC).

Silva (1998) afirma que parte dos métodos de segunda ordem existentes utilizam um procedimento de busca unidimensional para a determinação da taxa de aprendizagem. Como uma busca unidirecional envolve um grande número de iterações de avaliação, acaba tornando tais métodos muito custosos no ponto de vista computacional. O algoritmo SGC, apresentado na forma de descrição narrativa na Figura 32 evita a busca unidimensional a cada iteração.

Basicamente, o algoritmo SGC interrompe o treinamento de RNA quando uma dessas condições ocorrer:

- Quando um limite de repetições, ou *epochs*, for alcançado;
- Quando um tempo limite para iterações for excedido;
- Quando o desempenho de treinamento minimizar um valor alvo;
- Quando o gradiente de desempenho fica abaixo do gradiente mínimo.

Figura 32 – Algoritmo do Gradiente Conjugado Escalonado.

1. Escolha um vetor de parâmetros inicial θ_0 e escalares $0 < \sigma \ll 1$ e $\lambda_0 = 0$;
2. Faça: $p_0 = r_0 = -\nabla J(\theta_0); j = 0$; sucesso = 1
3. Se sucesso = 1, calcule a informação de 2ª ordem: $\sigma_j = \frac{\sigma}{\|d_j\|}$

$$s_j = \frac{\nabla J(\theta_j + \sigma_j d_j) - \nabla J(\theta_j)}{\sigma_j} + \lambda_j d_j; \quad \delta_j = p_j^T s_j$$
4. Se $\delta_j \leq 0$, então faça a matriz hessiana definida positiva:

$$\lambda_j^N = 2 \left[\lambda_j - \frac{\delta_j}{\|d_j\|^2} \right]; \quad \delta_j = \delta_j + (\lambda_j^N - \lambda_j) \|d_j\|^2; \quad \lambda_j = \lambda_j^N$$
5. Calcule a taxa de ajuste:

$$\mu_j = p_j^T r_j; \quad \alpha_j = \mu_j / \delta_j$$
6. Calcule o parâmetro de comparação:

$$\Delta_j = \frac{2\delta_j [J(\theta_j) - J(\theta_j + \alpha_j d_j)]}{\mu_j^2}$$
7. Se $\Delta_j \geq 0$ (o erro pode ser reduzido), então atualize o vetor de pesos:

$$\theta_{j+1} = \theta_j + \alpha_j d_j; \quad r_{j+1} = -\nabla J(\theta_{j+1});$$
8. Se $(j \bmod P) = 0$, então reinicialize o algoritmo:

$$p_{j+1} = r_{j+1}.$$
 Senão, defina uma nova direção conjugada:

$$\beta_j = \frac{\|r_{j+1}\|^2 - r_{j+1}^T r_j}{\mu_j}; \quad p_{j+1} = r_{j+1} + \beta_j p_j$$
9. Se $\Delta_j \geq 0.75$, então faça $\lambda_j = 0.5\lambda_j$.
10. Se $\Delta_j \leq 0.25$, então faça $\lambda_j = 4\lambda_j$.
 Senão, uma redução no erro não é possível: sucesso = 0;
11. Se $r_{j+1} > \epsilon$, onde $\epsilon \rightarrow 0$, então faça: $j = j+1$; retorne ao passo 3.
12. Senão, o procedimento de ajuste chegou ao fim e θ_{j+1} é o ponto de mínimo.

Fonte: (SILVA, 1998)

3.7 DISCUSSÃO DO CAPÍTULO

Segundo Raudys e Jain (1991), o projeto de um sistema de reconhecimento de padrões consiste em várias fases: coleção de dados, formação de classes de padrões, seleção de características ou atributos, especificação do algoritmo de classificação e estimativa de erro na classificação. O Capítulo 3 descreveu os materiais e métodos utilizados no trabalho de pesquisa para a execução de cada fase de projeto necessária para a concepção da RNA proposta, além do sistema computacional a ser utilizado no auxílio ao diagnóstico de PCA.

Detalhes das fases de coleção de dados e formação de classes foram descritos no tópico 3.1. Foram apresentadas as características dos neonatos que participaram da pesquisa, os locais onde as capturas foram realizadas, o protocolo definido para a captura de imagens, além da câmera térmica utilizada.

Métodos utilizados na fase de seleção de características foram apresentados nos tópicos 3.2, 3.3 e 3.4. Foi apresentada a região de interesse selecionada para a classificação de neonatos com e sem PCA, a forma como tal região foi extraída automaticamente das imagens, a motivação para a obtenção de parâmetros estatísticos a partir dessa região de interesse, além do uso de um algoritmo que permitiu simular instâncias da classe menos representativa (com PCA), balanceando o conjunto de dados para melhoria na precisão durante os treinamentos de rede.

A especificação do algoritmo de classificação foi definida no tópico 3.6. Foi apresentada cada configuração de RNA a ser avaliada durante os testes de treinamento, o algoritmo de aprendizagem adotado, a função de ativação que simula a transmissão de impulsos de um neurônio artificial, além do critério para definição do ponto de parada de treinamento.

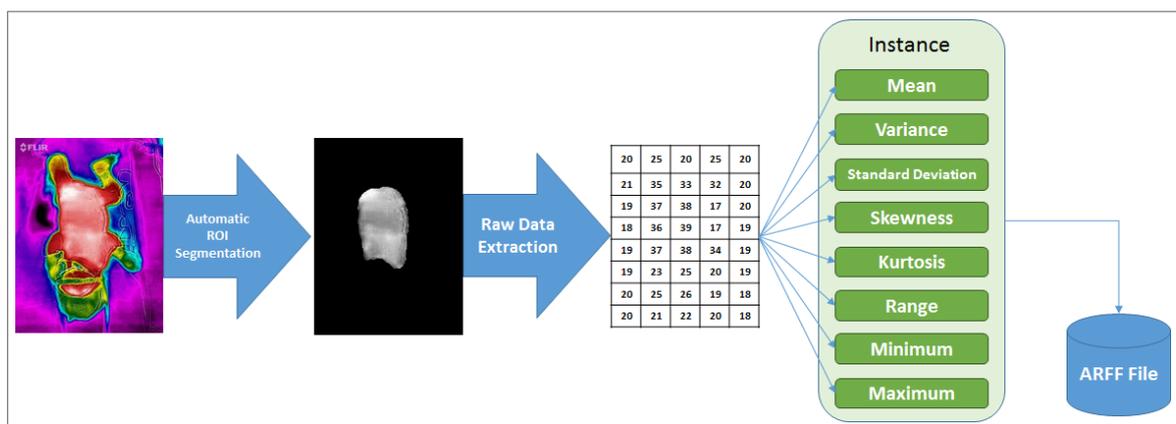
A partir da estimativa de precisão apresentada no tópico 3.5, foi possível colocar em prova a eficácia do número de instâncias contido no conjunto de dados a ser utilizado em treinamentos de rede, fundamentando sua atribuição. Tal estimativa também confirmou a importância do balanceamento de classes na melhora da precisão de classificação.

Concluída a definição e fundamentação da metodologia de pesquisa, foi possível conceber o conjunto de instâncias de neonatos com e sem PCA, modelar a RNA proposta, iniciar os testes de classificação de rede e, a partir das experiências obtidas, desenvolver o sistema computacional para auxílio ao diagnóstico da PCA. Tais etapas são descritas em maiores detalhes no capítulo a seguir.

4 AVALIAÇÃO E RESULTADOS

Para validar a arquitetura do sistema computacional proposto, foi desenvolvida uma aplicação independente no MATLAB R2013a como modelo de referência para a segmentação automática de imagens térmicas de neonatos e a obtenção de temperaturas de tronco (FARIAS et al., 2018), além dos testes iniciais de RNA. A partir das imagens segmentadas, a aplicação extrai a matriz de temperatura disponível em seus metadados. Média, variância, desvio padrão, coeficiente de assimetria, curtose, amplitude, valores mínimo e máximo são calculados a partir das matrizes de temperatura, formando o conjunto de atributos que representam as temperaturas de tronco de cada neonato a serem utilizados nos processos de aprendizagem da máquina. A Figura 33 exibe graficamente o fluxo do modelo de referência descrito. A seguir, são apresentados cada módulo que compõe a aplicação desenvolvida.

Figura 33 – Fluxo do extrator de características das imagens de tronco de neonatos.



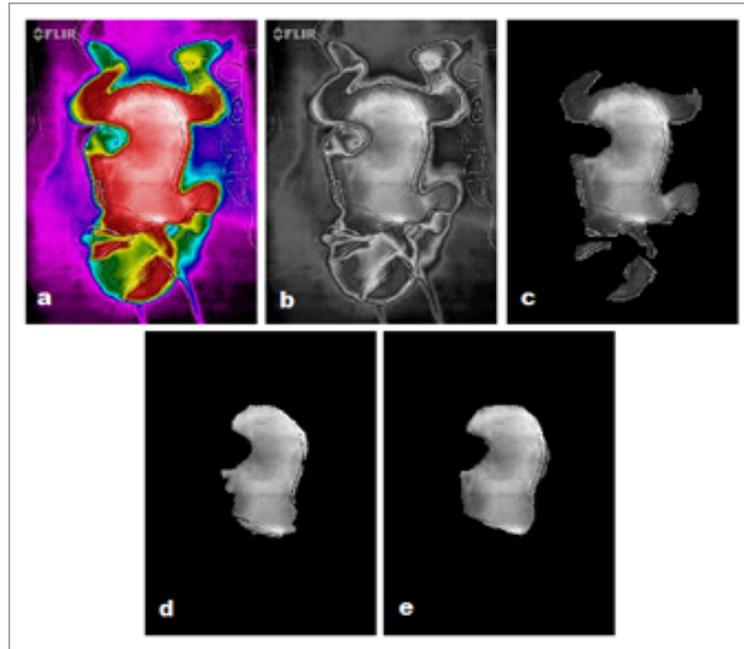
Fonte: Próprio Autor

4.1 MÓDULO PARA SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS

A partir do modelo de referência desenvolvido para a segmentação das imagens térmicas capturadas para a pesquisa, profissionais de saúde segmentaram manualmente as mesmas imagens térmicas utilizadas nos testes de segmentação automática, para fins de comparação. Ao todo, quatro médicos que compõem a equipe de pesquisa participaram dos testes de segmentação, sendo duas médicas cardiopediatras, uma médica intensivista neonatal e um médico doutor em biologia aplicada à saúde. Informações adicionais sobre os mesmos podem ser obtidas no Anexo A. Um exemplo de saída da referida aplicação após as etapas de segmentação manual e automática é apresentada na Figura 34. Além disso, a aplicação também apresenta uma sobreposição das regiões de interesse obtidas por cada processo de segmentação, afim de apresentar de forma visual possíveis regiões

divergentes entre as segmentações manual e automática, como é ilustrada na Figura 35. Nas imagens apresentadas na Figura 34 (d) e na Figura 35, é possível constatar que a saída obtida na segmentação automática para o teste em questão foi bastante satisfatória, visto que é muito similar a saída obtida na segmentação manual, demonstrada na Figura 34 (e).

Figura 34 – Exemplo de saída da aplicação desenvolvida.



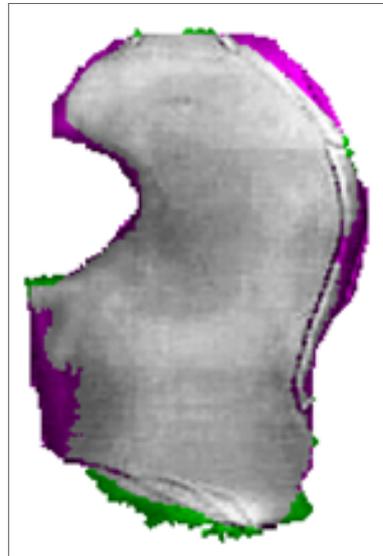
Fonte: Próprio Autor

Afim de mensurar quantitativamente possíveis perdas de informação na segmentação automática, foram calculadas a média de temperatura para cada região de interesse obtida a partir das segmentações manual e automática, além da diferença de temperatura entre as duas técnicas. Por fim, foi calculada a média da diferença de temperatura obtida durante os testes, que foi igual a $0,292^{\circ}\text{C}$. Para o teste apresentado na Figura 34, a diferença de temperatura foi de $0,263^{\circ}\text{C}$. A média obtida, considerada um valor baixo, confirma que a segmentação automática obteve uma baixa taxa de perda de informações de temperatura.

4.1.1 Módulo de Extração e Simulação de Características

A Figura 36 exhibe o fluxo adotado para a extração e simulação de características. A partir das imagens térmicas de tronco obtidas a partir do modelo de referência para a segmentação automática, o módulo de extração de características gera um arquivo no Formato *Attribute-Relation File Format* (ARFF), um arquivo de texto ASCII que descreve uma lista de instâncias que compartilham um conjunto de atributos. Os arquivos ARFF foram desenvolvidos pelo *Machine Learning Project* no Departamento de Ciências da Computação da Universidade de Waikato para uso com o *software* de aprendizado de

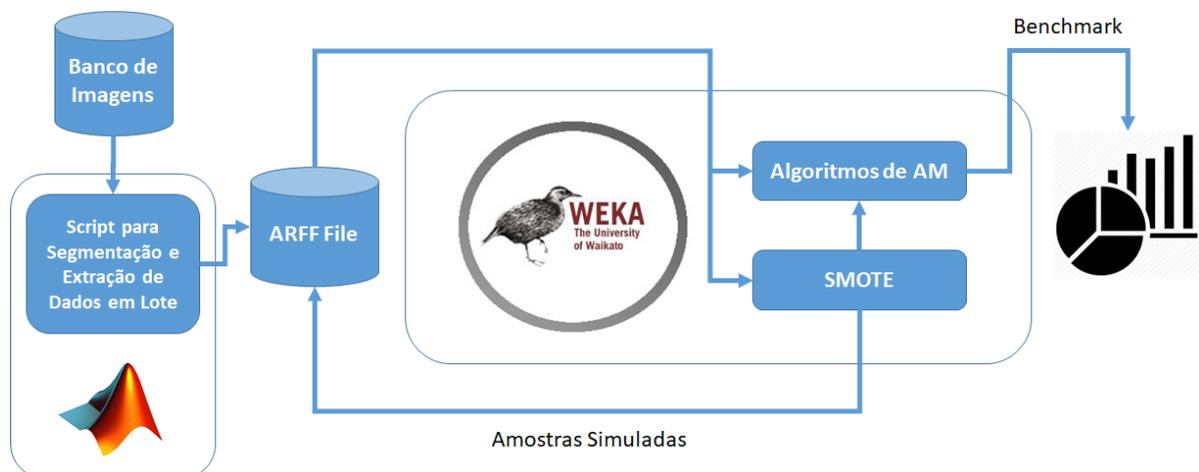
Figura 35 – Diferença visual entre as segmentações manual e automática do tronco do neonato da Figura 34, onde as regiões coloridas representam as regiões divergentes para cada técnica.



Fonte: Próprio Autor

máquina Weka (HALL et al., 2009), usado nos testes iniciais das arquiteturas de RNAs propostas. Uma implementação do algoritmo SMOTE foi utilizada para a geração sintética de vetores de características com o objetivo de ampliar as instâncias relacionadas a neonatos com PCA, visto a quantidade reduzida de imagens dessa classe. O pré-processamento, realizado no arquivo ARFF a partir do software Weka (HALL et al., 2009), permitiu a geração de 49 instâncias sintéticas para neonatos com PCA. Assim, foram obtidas 56 instâncias de neonatos com PCA e 56 casos de bebês sem PCA.

Figura 36 – Fluxo adotado para a extração e simulação de características.



Fonte: Próprio Autor

A partir do Weka, foi possível realizar testes iniciais de desempenho para as arquitetu-

Tabela 4 – Estudo do Teste de Precisão Vs. Tamanho do Conjunto de Dados.

Com PCA	Sem PCA	Precisão (%)	Amostras	Tempo (s)
7	56	89	63	0,15
56	56	94	112	0,24
112	112	95	224	0,44
224	224	98	448	0,83
448	448	99	896	1,70

ras de RNA propostas pela pesquisa, além de criar um conjunto de dados base utilizados na calibração da aplicação *PCA Diagnostic*, sistema computacional desenvolvido para o auxílio ao diagnóstico de PCA, descrito em detalhes no Tópico 4.3.

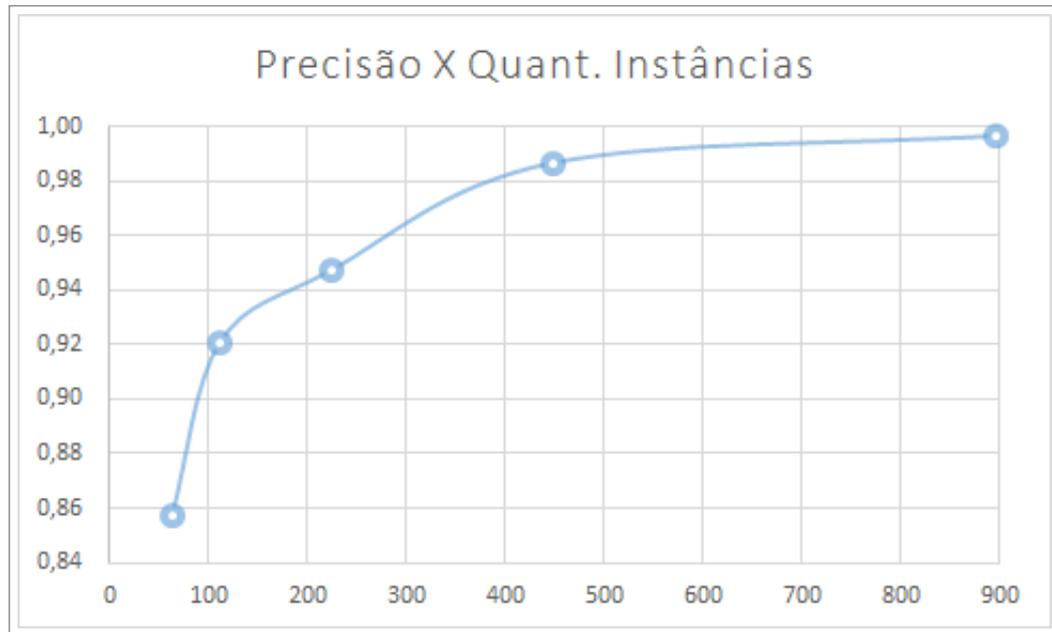
4.1.2 Definição da Quantidade de Instâncias

De acordo com o que foi estabelecido na Seção 3.5, o conjunto de amostras adotado nos testes de treinamento de RNA foi dimensionado em 112 amostras. Um dos critérios adotados para fundamentar tal escolha foi a plotagem da curva de aprendizagem a partir da relação entre a quantidade de instâncias de *dataset* e a precisão na classificação da RNA adotada.

O Weka também foi utilizado, tanto na obtenção de dados de precisão em RNA quanto na geração de instâncias simuladas via SMOTE para composição de conjunto de dados com tamanhos diferentes. Nos testes, foi adotada a RNA citada na Seção 3.6, com 8 neurônios na camada oculta. As amostras foram selecionadas para as etapas de treinamento e testes de rede a partir da técnica de Validação Cruzada com 10 partições (*10-fold*), considerada padrão ouro na avaliação de desempenho de modelos de AM. Nela, as instâncias são divididas em k -partições ou dobras (*folds*) de mesmo tamanho. A RNA é treinada a partir de $k - 1$ partições e testada a partir da última partição restante. Esse processo é repetido k vezes, alternando as k partições em cada iteração. Ao final das k iterações, calcula-se a precisão média do modelo. Também foram computados o tempo em segundos que o Weka precisou para construir o modelo, considerando cada conjunto de dados. Os resultados obtidos podem ser verificados na Tabela 4 e a curva de aprendizagem gerada a partir de tais dados é apresentada na Figura 37.

Tais testes confirmaram que o balanceamento das instâncias de classe no conjunto de dados da pesquisa melhorou a precisão de classificação, de 89% para 94%, sem um aumento significativo no tempo de construção do modelo. Também era prevista uma melhora ainda mais significativa na precisão de classificação graças ao treinamento realizado a partir de conjuntos de instância maiores, porém o tempo de construção do modelo também aumentou. Também deve ser considerado a presença de ruído nos testes realizados em conjuntos de dados com mais de 112 instâncias, visto a quantidade de amostras si-

Figura 37 – Curva de Aprendizagem - Teste de Precisão Vs. Tamanho do Conjunto de Dados.



Fonte: Próprio Autor

muladas em maior quantidade. O conjunto composto por 112 instâncias, formado por uma quantidade menor de amostras simuladas, gerou um treinamento com uma precisão de classificação considerada satisfatória, sendo adotado como o tamanho mínimo do conjunto de dados a ser considerado nos testes de treinamento de rede, que serão descritos em detalhes a seguir.

4.2 TESTES DE CLASSIFICAÇÃO

Após o balanceamento do banco de amostras, foram realizados testes de classificação, também a partir do software Weka, afim de verificar seu desempenho na classificação das instâncias de neonatos a partir da metodologia proposta para a pesquisa. As amostras foram selecionadas para as etapas de treinamento e testes de rede a partir da técnica de Validação Cruzada com 10 partições. Os resumos de saída para cada configuração de RNA são apresentados na Tabela 5. Nela, é possível verificar os melhores resultados obtidos para cada arquitetura de RNA testada, destacados em negrito. As matrizes de confusão associadas a cada teste são apresentadas na Figura 38.

O Weka adota as seguintes medidas de desempenho nos testes de classificação (KUMAR; SAHOO, 2012):

- Estatística *Kappa* - Pode ser definida como medida do grau de concordância entre dois conjuntos de dados categorizados. O resultado do *Kappa* varia entre os valores 0 e 1. Quanto maior for o valor do *Kappa*, maior a concordância/vínculo. Se *Kappa*

Tabela 5 – Resumo das saídas para cada configuração de RNA testada.

	5 neurônios	8 neurônios	2 neurônios	10 neurônios
Classificou Corretamente	93,75%	93,75%	87,5%	92,8571%
Classificou Incorretamente	6,25%	6,25%	12,5%	7,1429%
Estatística Kappa	0,875	0,875	0,75	0,8571
Erro Absoluto Médio	0,0845	0,0734	0,1736	0,0757
<i>Root Mean Squared Error</i>	0,2418	0,2333	0,3251%	0,2422
Erro absoluto relativo	16,897%	14,6624%	34,6885%	15,1217%
Root Relative Squared Error	48,3262%	46,616%	64,9721%	48,3982%

Figura 38 – Matrizes de confusão para cada configuração de RNA testada.

5 neurons				8 neurons			
a	b	<--	classified as	a	b	<--	classified as
55	1		a = comPCA	55	1		a = comPCA
6	50		b = semPCA	6	50		b = semPCA
2 neurons				10 neurons			
a	b	<--	classified as	a	b	<--	classified as
55	1		a = comPCA	55	1		a = comPCA
13	43		b = semPCA	7	49		b = semPCA

Fonte: Próprio Autor

é igual a 1, então a concordância é perfeita. Se *Kappa* é igual a 0, então não há concordância. Os valores de *Kappa* entre 0.40 e 0.59 são considerados moderados, entre 0.60 e 0.79 são considerados substanciais e acima de 0.80 são considerados pendentes;

- Erro Absoluto Médio - É definido como a soma do erro absoluto dividido pelo número de previsões. Quanto mais próximo de 0, mais preciso é o modelo;
- *Root Mean Squared Error* (RMSE) - É definido como a raiz quadrada da soma dos quadrados dividida pelo número de previsões. Quanto mais próximo de 0 for o RMSE, mais preciso é o modelo;
- Erros Absoluto Relativo e Quadrático Relativo da Raiz - São porcentagens de erro obtidas pelo modelo, que indicam a taxa de desvio na previsão de classes. Quanto menor a taxa de erro, melhor o desempenho do modelo.

Também foram realizados testes de comparação de desempenho entre a melhor configuração de RNA (com camada oculta composta por 8 neurônios) e outros algoritmos de AM com implementações disponíveis no software Weka. Foram considerados as configurações de treinamento padrão para os 43 algoritmos de AM comparados com a arquitetura de RNA proposta. As amostras foram selecionadas para as etapas de treinamento e testes de rede a partir da técnica de Validação Cruzada com 10 partições. As técnicas de AM foram ranqueadas de acordo com cada medida de desempenho do Weka, já discutidas anteriormente. Um resumo dos resultados obtidos nos testes, além do ranqueamento entre as 20 técnicas com melhor acurácia preditiva, é apresentado na Tabela 6. O ranqueamento geral, baseado no desempenho de todas as técnicas envolvidas nos testes, está disponível no Apêndice C, em forma de tabela, e no Apêndice D, de forma gráfica.

Tabela 6 – Resumo dos resultados obtidos nos testes de desempenho por cada técnica de AM disponíveis no Weka.

Pos.	Técnica de AM	ICC(%)	MAE	RMSE
1º	HoeffdingTree	96,4286	0,0550	0,1986
2º	NaiveBayes	96,4286	0,0552	0,1987
3º	NaiveBayesUpdateable	96,4286	0,0552	0,1987
4º	AdaBoostM1	95,5357	0,1382	0,2475
5º	BayesNet	94,6429	0,0468	0,1917
6º	MultilayerPerceptron	93,7500	0,0734	0,2333
7º	RandomForest	93,7500	0,0865	0,1945
8º	RandomCommittee	92,8571	0,0732	0,2151
9º	IBk	92,8571	0,0798	0,2648
10º	LogitBoost	92,8571	0,1041	0,2309
11º	IterativeClassifierOptimizer	92,8571	0,1112	0,2360
12º	RandomSubSpace	92,8571	0,1523	0,2344
13º	KStar	91,9643	0,0796	0,2682
14º	RandomTree	91,9643	0,0804	0,2835
15º	AttributeSelectedClassifier	91,9643	0,0866	0,2722
16º	RandomizableFilteredClassifier	91,9643	0,0885	0,2809
17º	JRip	91,9643	0,0996	0,2770
18º	LMT	91,0714	0,0926	0,2923
19º	J48	91,0714	0,0944	0,2913

20º	PART	90,1786	0,1051	0,3052
-----	------	---------	--------	--------

É possível constatar na Tabela 6 que a arquitetura de RNA selecionada pela pesquisa obteve o sexto melhor desempenho, atrás de técnicas como Naive Bayes (JOHN; LANGLEY, 1995) e Hoeffding Tree (HULTEN; SPENCER; DOMINGOS, 2001). Tal resultado era previsto, visto que RNAs tentem a ter melhor desempenho preditivo na existência de banco de amostras com grande quantidade de instâncias. As técnicas com melhor ranqueamento foram favorecidas pela baixa quantidade de instâncias utilizadas nos testes. Para validar essa hipótese, foram realizados novos testes de desempenho a partir da técnica de Validação Cruzada com 10 partições, desta vez considerando um banco de instâncias composto por 2688 amostras. Mais amostras foram simuladas a partir do algoritmo SMOTE, afim de ampliar o banco de instâncias para a quantidade em questão. Um resumo dos resultados obtidos nos testes com o banco de instâncias ampliado, além do ranqueamento entre as 20 técnicas com melhor acurácia preditiva, é apresentado na Tabela 7. O ranqueamento geral, baseado no desempenho de todas as técnicas envolvidas nos testes, está disponível no Apêndice E, em forma de tabela, e no Apêndice F, de forma gráfica.

Tabela 7 – Resumo dos resultados obtidos nos testes de desempenho por cada técnica de AM disponíveis no Weka, considerando 2688 amostras.

Pos.	Técnica de AM	ICC(%)	MAE	RMSE
1º	IBk	99,9628	0,0008	0,0193
2º	RandomizableFilteredClassifier	99,9628	0,0008	0,0193
3º	KStar	99,8512	0,0014	0,0313
4º	MultilayerPerceptron	99,8140	0,0048	0,0403
5º	RandomForest	99,8140	0,0056	0,0437
6º	LMT	99,7768	0,0023	0,0459
7º	J48	99,7396	0,0035	0,0510
8º	RandomCommittee	99,7396	0,0036	0,0434
9º	RandomSubSpace	99,7024	0,0123	0,0542
10º	PART	99,6280	0,0045	0,0609
11º	AttributeSelectedClassifier	99,6280	0,0057	0,0611
12º	BayesNet	99,5164	0,0061	0,0652
13º	Bagging	99,5164	0,0110	0,0643
14º	RandomTree	99,4792	0,0052	0,0722
15º	JRip	99,4792	0,0060	0,0713

16 ^o	REPTree	99,4048	0,0089	0,0775
17 ^o	ClassificationViaRegression	99,3676	0,0231	0,0789
18 ^o	FilteredClassifier	98,5863	0,0170	0,1116
19 ^o	HoeffdingTree	98,2515	0,0298	0,1301
20 ^o	IterativeClassifierOptimizer	98,1771	0,0461	0,1211

A arquitetura de RNA selecionada pela pesquisa não só subiu duas posições no ranqueamento, como também manteve-se constante entre as 10 melhores técnicas de AM envolvidas nos testes. As técnicas Naive Bayes e Hoeffding Tree, que obtiveram o melhor desempenho preditivo a partir de um banco de instâncias reduzido, sequer são listados entre as 20 melhores técnicas nos testes com banco de instâncias ampliado. Também é possível verificar na Tabela 7 que técnicas com desempenho inferior, verificado em testes realizados com poucas instâncias, também foram favorecidas pela ampliação de amostras, como as técnicas IBk (AHA; KIBLER, 1991), *Randomizable Filtered Classifier* e KStar (CLEARY; TRIGG, 1995). A diferença de desempenho entre as 20 melhores técnicas também é bastante reduzida, sendo definida por décimos.

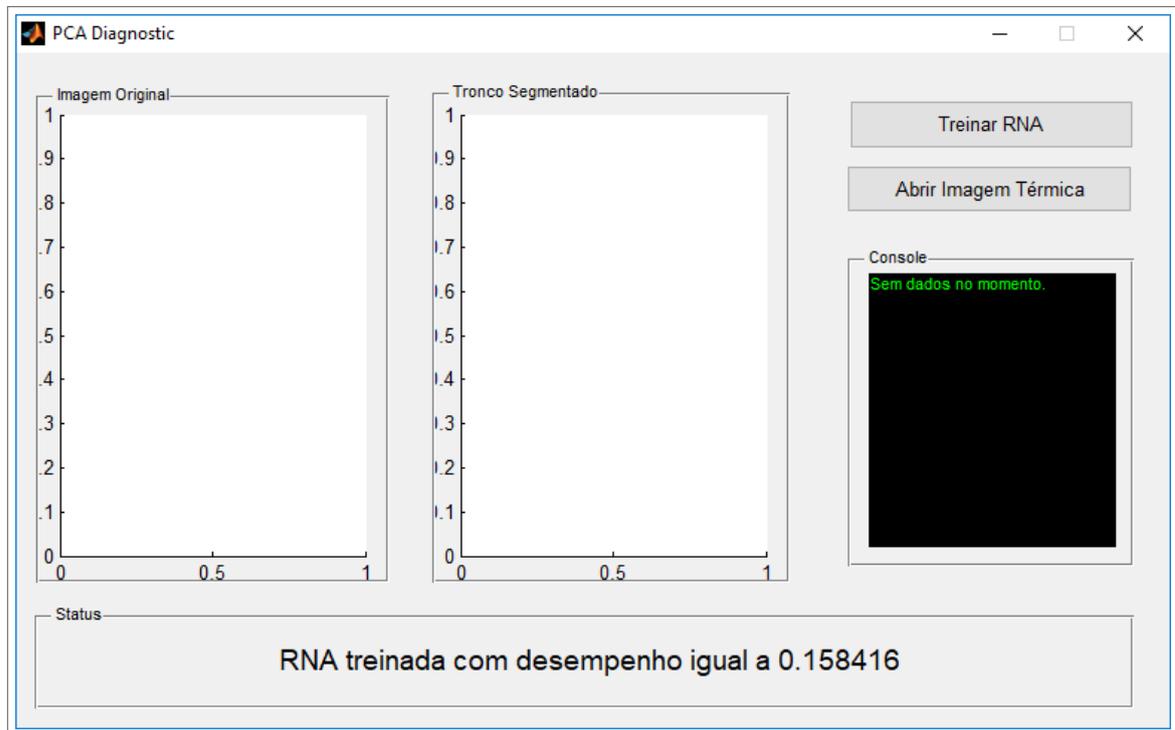
Tais testes comprovaram que um treinamento de rede, considerando uma quantidade maior de instâncias, pode fazer com que a RNA alvo da pesquisa tenha um desempenho de predição com boas taxas. Mesmo com um banco de instâncias reduzido, a RNA conseguiu não só se manter constante entre as melhores técnicas de AM, mas também com taxa de acerto satisfatórias, fundamentando a seleção desta como técnica de aprendizagem de máquina adotada para o sistema computacional desenvolvido, a ser descrito em maiores detalhes a seguir.

4.3 O PCA DIAGNOSTIC

O PCA *Diagnostic* é um sistema *standalone* que permite ao usuário ter um auxílio automatizado ao diagnóstico da PCA a partir do processamento de imagens térmicas de neonatos com suspeita da doença. O mesmo foi desenvolvido a partir do MATLAB R2013a em parceria com MATLAB *Neural Network Toolbox*, para a implementação da RNA que obteve os melhores resultados nos testes iniciais de desempenho no Weka (RNA *Perceptron* Multicamada 1-1-1, com 8 neurônios para a camada de entrada, 8 neurônios para a camada oculta e 2 neurônios para a camada de saída), e o MATLAB *Graphical User Interface Development Environment* (GUIDE), para a criação da interface gráfica do sistema. A tela inicial do sistema é apresentada na Figura 39.

O GUIDE permite o desenvolvimento de aplicações com *Graphical User Interface* (GUI) a partir da linguagem script *m* disponível no MATLAB. Projetos de software no GUIDE seguem o paradigma de programação orientada a eventos, onde o fluxo de código é guiado por ações do usuário na interface gráfica, chamadas de eventos. Cada evento,

Figura 39 – Tela inicial do sistema PCA Diagnostic.



Fonte: Próprio Autor

que representa um subprograma a ser disparado de acordo com uma interação do usuário na interface, é associada a uma função chamada *callback*. Na Figura 40, é apresentado o diagrama de transição de estados do PCA *Diagnostic*, destacando os *callbacks* existentes no sistema e os eventos que os disparam. Já na Figura 41 é apresentado o fluxograma da aplicação, afim de apresentar em maiores detalhes seu fluxo de execução. Cada *callback* e evento ilustrado nos diagramas em questão serão descritos em maiores detalhes a seguir.

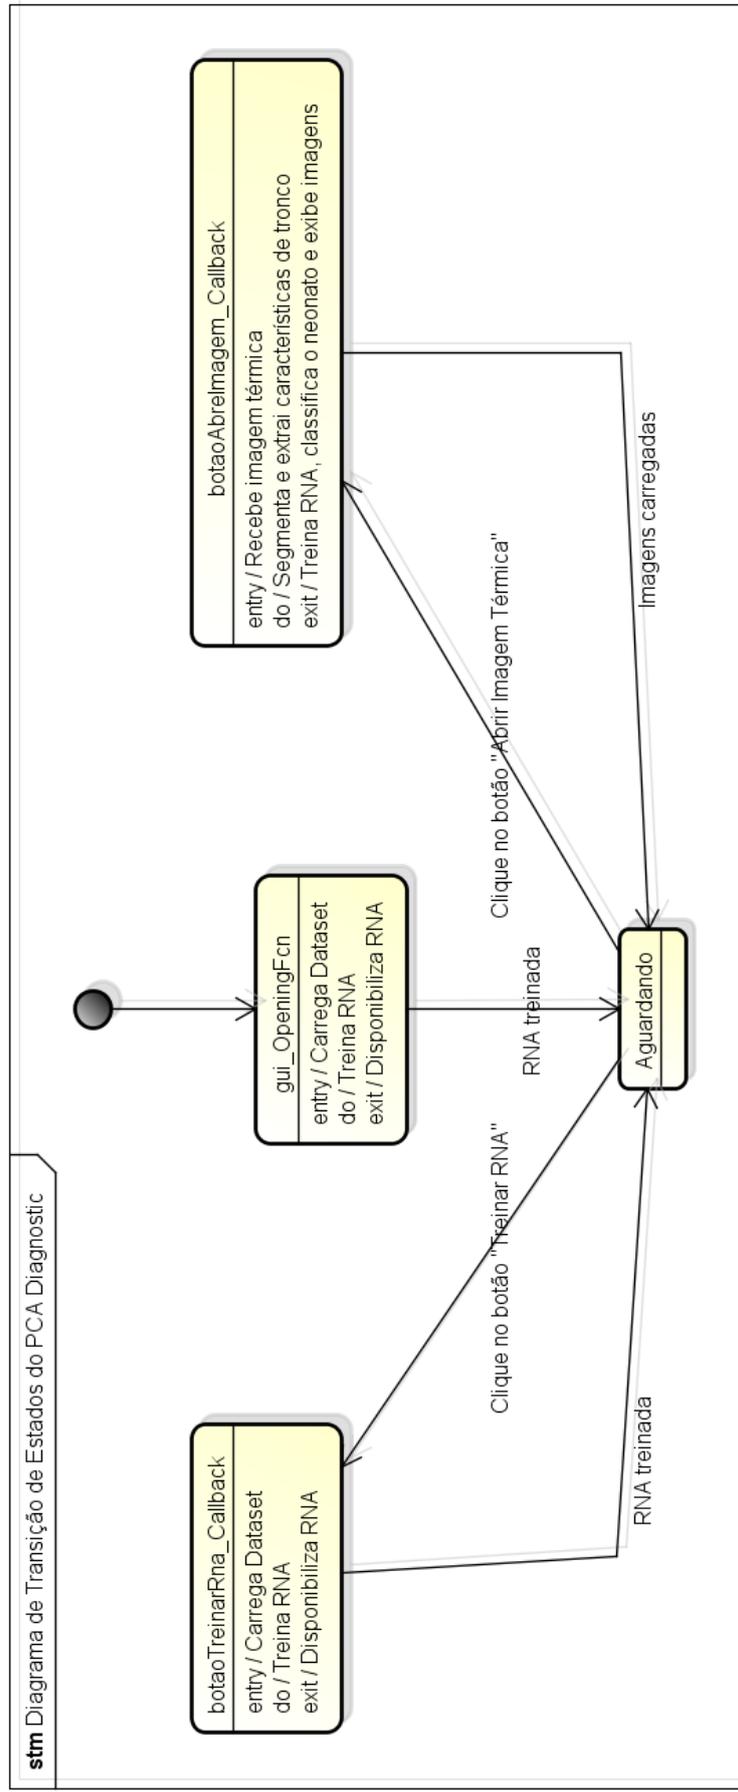
Quando o software é executado, um treinamento de RNA é realizado de acordo com o que foi explanado no Tópico 3.6 a partir de um banco de instâncias, gerado pelo modelo de referência descrito no Tópico 4.1.1. Informações sobre a qualidade de predição que a RNA adquiriu após o *callback* de carregamento é exibida no painel de *Status* do programa. O usuário tem a opção de realizar um novo treinamento a partir do botão “Treinar RNA”, caso o último desempenho de treinamento obtido, baseado na taxa de erro de predição, não tenha sido satisfatório (quanto mais próximo de zero for o desempenho, mais precisa será a predição da rede). Para que o sistema possa prever se um neonato tem ou não PCA, o usuário poderá abrir uma imagem térmica a partir do botão “Abrir Imagem Térmica”. Após a seleção da imagem térmica a ser classificada, o PCA *Diagnostic* a exibe no painel “Imagem Original”, inicia o processo de segmentação automática de tronco a partir da implementação do algoritmo descrito no Tópico 3.2 e obtém as características de temperatura descritas no Tópico 3.3. A imagem resultante do processo de segmentação é apresentada no painel “Tronco Segmentado” e as características extraídas a partir da

saída da segmentação são exibidas no painel “Console”. Com as características da imagem térmica disponíveis, o sistema realiza um novo treinamento de RNA, capturando a saída gerada pelos seus dois neurônios (N_1 e N_2) que compõem a camada de saída da rede: dois valores reais a serem utilizadas na classificação da imagem térmica. Caso N_1 tenda para o valor 1 e N_2 tenda para o valor 0, o sistema classifica a imagem como sendo de um neonato saudável. O inverso faz com que a aplicação considere a imagem como sendo de um recém-nascido com PCA. O resultado da classificação da rede é apresentado logo em seguida no painel de *Status*, como ilustrado na Figura 42.

A última saída da RNA implementada a retroalimenta, aumentando seu poder preditivo, fazendo com que ela aprenda com os próprios erros, caso ocorram, e melhore sua taxa de acurácia em classificações futuras. Para isso, após cada classificação realizada, o PCA *Diagnostic* questiona o usuário se a classificação realizada pelo sistema foi coerente com um diagnóstico clínico relacionado, como apresentado na Figura 43. Confirmado o diagnóstico correto, o vetor de características utilizado no treinamento da rede é integrado ao banco de instâncias, sendo marcado com a classe definida pelo sistema. Caso contrário, será integrado com uma marcação para a classe oposta.

Como o treinamento de RNA seleciona de forma aleatória 80% das instâncias contidas no banco de características, o desempenho de predição do PCA *Diagnostic* pode variar. Em testes realizados, a média de classificações corretas durante o treinamento de RNA no *callback* de execução inicial do aplicativo, quando são consideradas características extraídas do banco de instâncias já rotuladas por classes, foi de 92,14%, enquanto que a média de classificações incorretas foi de 7,87%. A RNA classificou corretamente 98,1% das instâncias no melhor caso e 81,9% no pior caso.

Figura 40 – Diagrama de Transição de Estados do PCA Diagnostic.



Fonte: Próprio Autor

Figura 41 – Fluxograma do PCA Diagnostic.

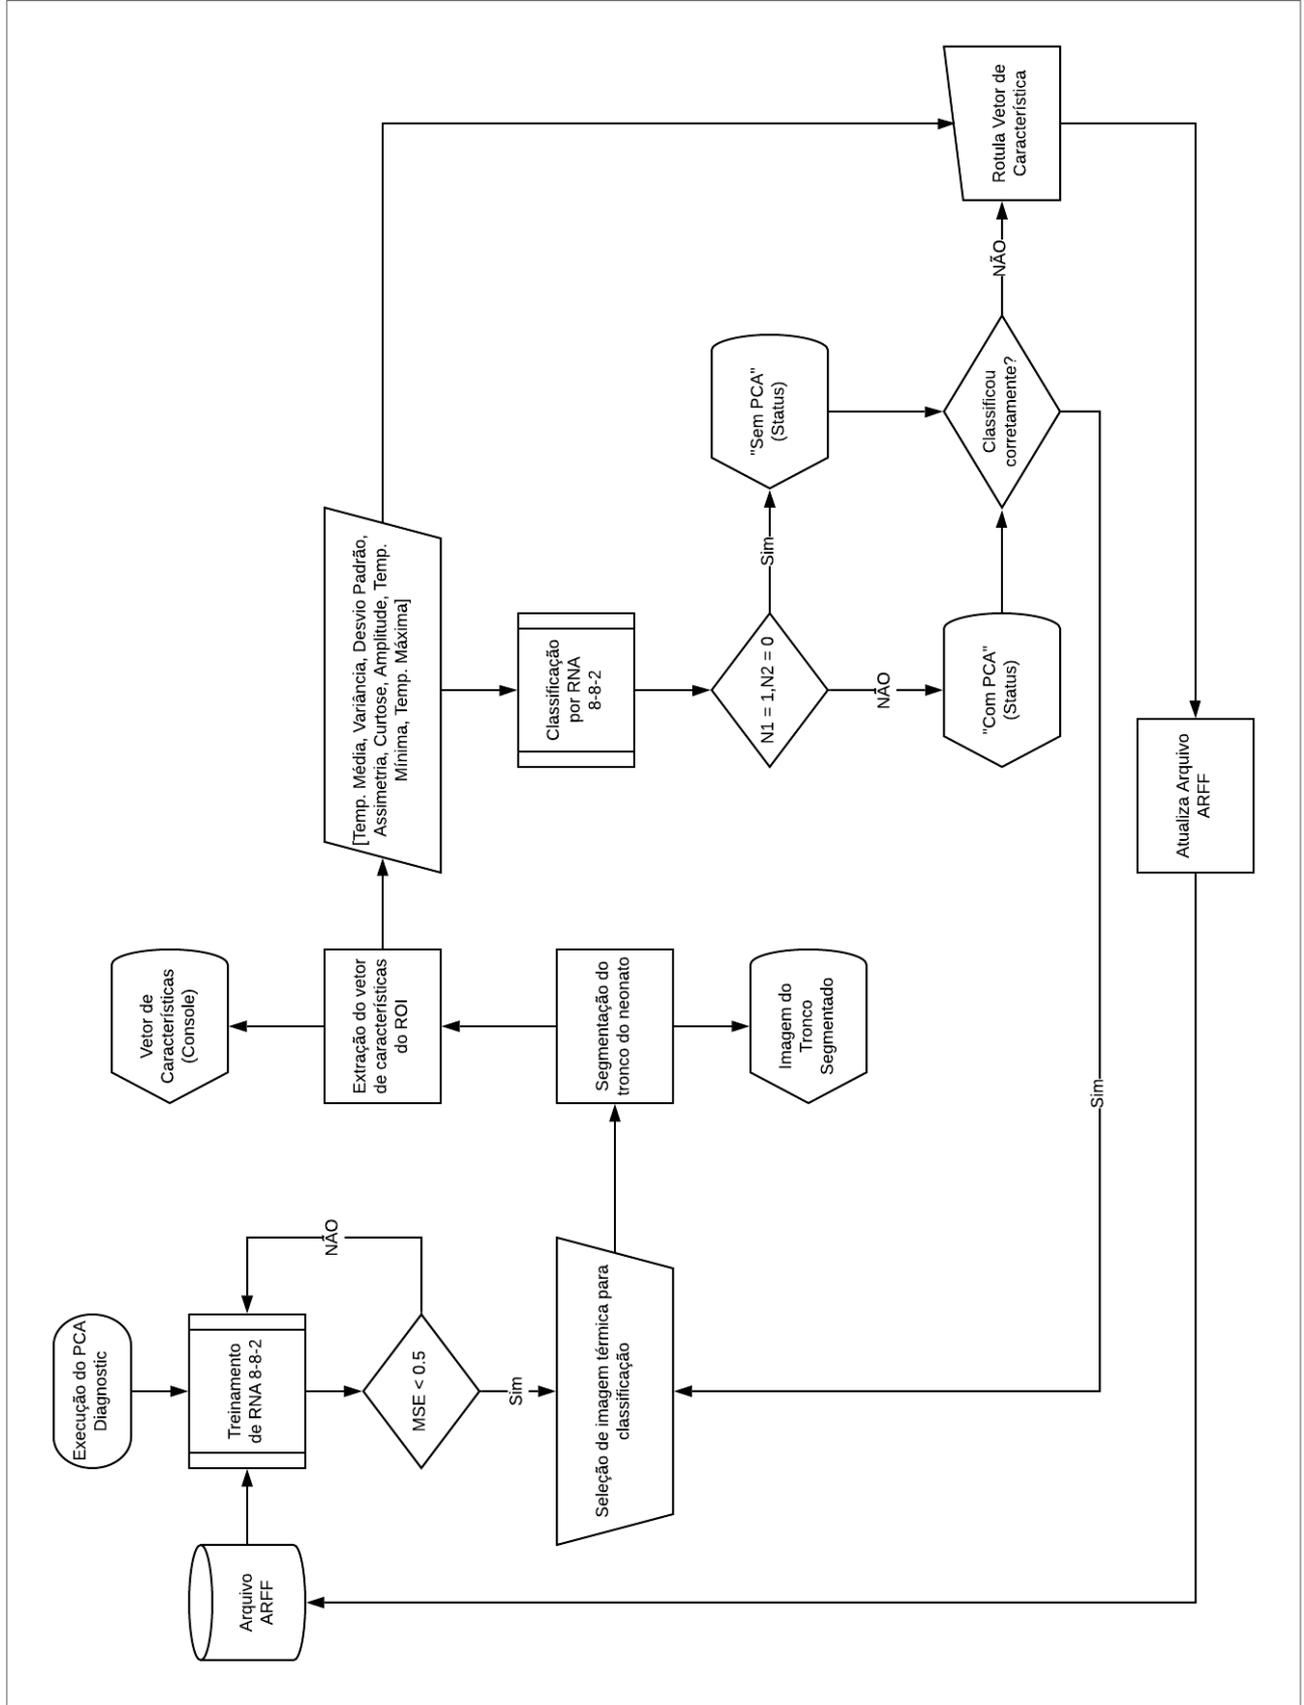
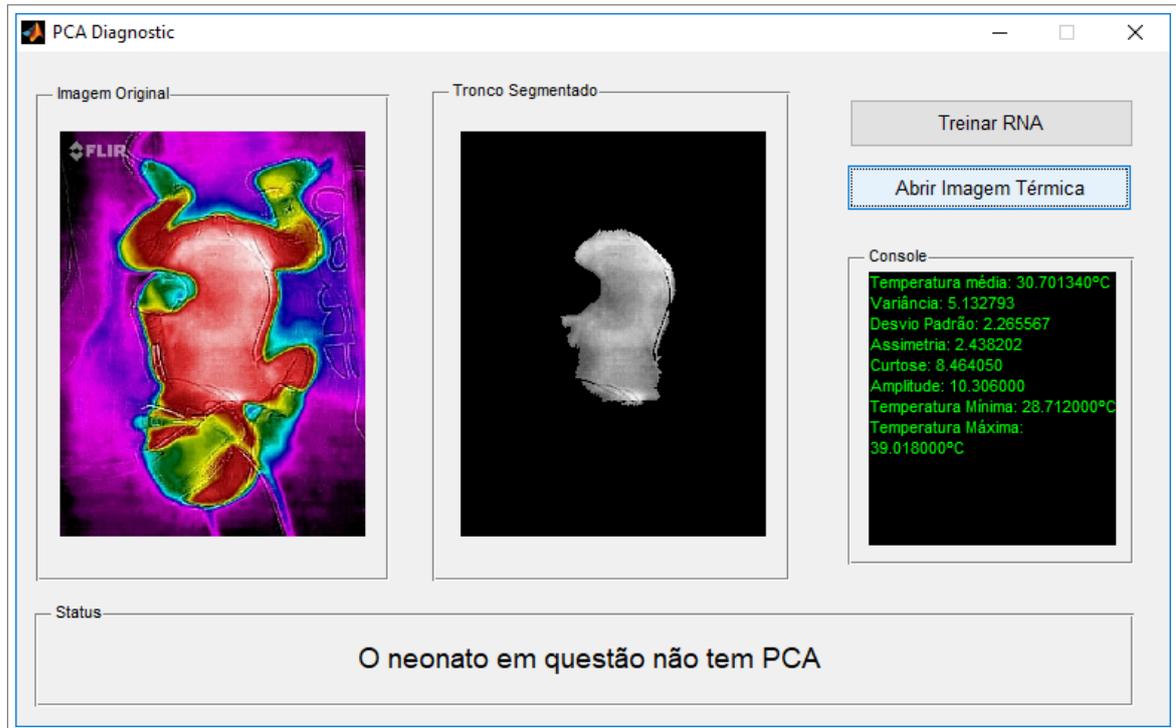
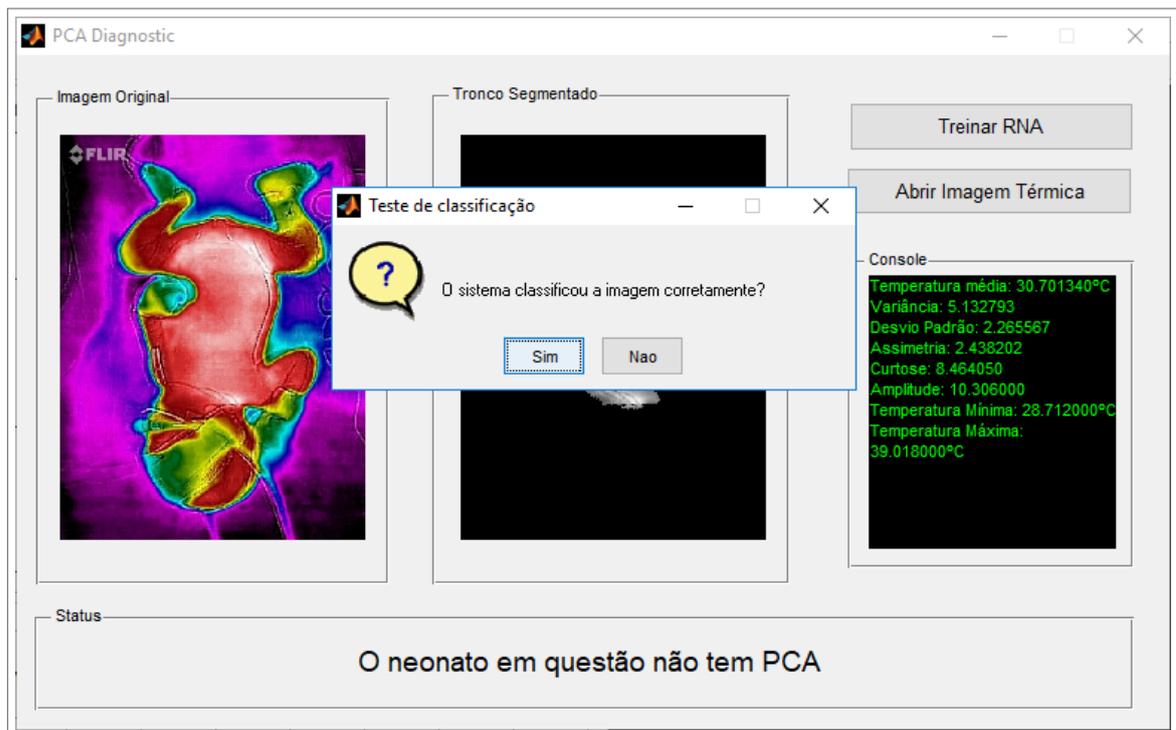


Figura 42 – PCA Diagnostic realizando uma classificação de imagem térmica.



Fonte: Próprio Autor

Figura 43 – Janela de diálogo do PCA Diagnostic para teste de classificação.



Fonte: Próprio Autor

5 CONCLUSÕES E TRABALHOS FUTUROS

5.1 RESUMO DOS RESULTADOS

Os trabalhos de pesquisa realizados produziram resultados relevantes, que serviram de base para a validação das hipóteses de pesquisa, dos modelos de referência e fundamentaram o desenvolvimento de um sistema computacional preditivo para o auxílio ao diagnóstico da PCA.

As imagens térmicas do tronco de recém-nascidos com PCA de fato refletiram regiões assimétricas de calor. Nas imagens térmicas de bebês sem PCA, a distribuição de calor foi mais uniforme no tórax e abdômen, comprovando que neonatos normais tendem a ter uma distribuição de temperatura mais simétrica. Durante a captura de imagens térmicas, muitos recém-nascidos prematuros usavam luvas, gorros, ataduras e meias, alterando a temperatura da cabeça, mãos e pés, o que dificultou a realização de testes de análise de simetria térmica considerando tais regiões de interesse. O protocolo de captura de imagens precisou ser atualizado para considerar tais fatores. Também foi necessário segmentar as imagens térmicas capturadas para que apenas a temperatura corporal do neonato influenciasse nos cálculos de descritores de características. Foram então desenvolvidos módulos de segmentação manual e automática para a remoção de tais artefatos.

O modelo de referência para a segmentação automática do tronco de neonatos em imagens térmicas obteve boas margens de erro, gerando resultados muito semelhantes aos obtidos na segmentação manual. A técnica de segmentação por limiar, associada com o método dos contornos ativos, apresentaram um grande potencial para a segmentação automática de imagens térmicas, removendo várias fontes de inconsistência que prejudicariam a extração de características da região de interesse objeto da pesquisa. O modelo em questão permitiu a criação de bancos de instâncias que foram utilizados tanto nos testes de treinamento de RNA quanto no sistema computacional desenvolvido. O modelo de referência em questão deu origem a uma publicação internacional, intitulada *Automatic Segmentation of Neonates Thermal Imaging for Evaluation of Trunk Thermal Asymmetry*, nos anais da *International Conference on Bioinformatics and Biomedicine* (BIBM 2018), realizada entre os dias 3 e 6 de dezembro de 2018, em Madrid, Espanha.

O modelo de referência associado aos testes de RNA também obteve boas taxas de predição. A melhor configuração de RNA testada foi a que possuía uma camada oculta com 8 neurônios, com aproximadamente 93,75% de classificações corretas de instâncias. A melhor configuração de RNA também teve o melhor desempenho, comparada com outras técnicas de aprendizagem de máquina, difundidas em outros trabalhos de pesquisa que atuaram na classificação de padrões, quando considerado testes com divisão percentual de amostras. No entanto, devido à existência de um pequeno conjunto de imagens, prin-

principalmente devido à reduzida quantidade de imagens térmicas de neonatos com PCA, o treinamento da rede foi realizado considerando instâncias simuladas. Tal conjunto reduzido de amostras fez com que o desempenho preditivo da RNA fosse superado por outras técnicas de AM em testes com Validação Cruzada. Para garantir que as taxas de precisão sejam otimizadas para imagens térmicas de recém-nascidos com PCA, serão necessários novos treinamentos, considerando um número maior de instâncias não simuladas de imagens de bebês com PCA. Devido à dificuldade em capturar imagens de recém-nascidos com PCA, ocorreram atrasos que impediram capturas a curto prazo e em grande quantidade. Dentre as dificuldades encontradas, lista-se:

- Atrasos na liberação das capturas por parte do Comitê de Ética em Pesquisa do CISAM/UPE - Para que seja possível capturar imagens térmicas de recém-nascidos e publicar os resultados do projeto em periódicos e/ou conferências, se faz necessária a aprovação da pesquisa na Comissão Nacional de Ética em Pesquisa (CONEP) em pelo menos um CEP coparticipantes do projeto. Todo protocolo de solicitação para avaliação e acompanhamento de aspectos éticos em pesquisa no Brasil devem submetidos e geridos a partir da Plataforma Brasil¹, uma base nacional e unificada de registros de pesquisas envolvendo seres humanos para todo o sistema CONEP. Ela permite que as pesquisas sejam acompanhadas em seus diferentes estágios - desde sua submissão até a aprovação final pelo CEP e pela CONEP, quando necessário - possibilitando inclusive o acompanhamento da fase de campo, o envio de relatórios parciais e dos relatórios finais das pesquisas (quando concluídas). O sistema permite, ainda, a apresentação de documentos também em meio digital, propiciando ainda à sociedade o acesso aos dados públicos de todas as pesquisas aprovadas. Os trâmites para os Comitês de Ética iniciaram após a obtenção da documentação necessária para o início do processo, exigidas pelos termos de apresentação da Plataforma Brasil, disponibilizadas pelas instituições coparticipantes a partir do dia 22 de Maio de 2017. Infelizmente, A CEP responsável pela avaliação do projeto levou cerca de 9 meses para dar parecer favorável a pesquisa, tendo o processo finalizado no dia 29 de Janeiro de 2018 (o parecer consubstanciado do CEP pode ser averiguado no Apêndice B), o que impediu a captura de imagens térmicas durante o período descrito;
- Liberação dos pais para a realização das capturas - Qualquer captura de imagem térmica só poderia ser realizada a partir da assinatura de um termo de consentimento, apresentado no apêndice B, pelo responsável do neonato. Muitos pais não permitiram ou não estavam presentes na UTI durante a aplicação dos protocolos de captura. Dado o estado de saúde e a fragilidade de alguns neonatos, alguns pais não se sentiram a vontade para participar da pesquisa;

¹ Disponível em <http://plataformabrasil.saude.gov.br>

- Reação dos neonatos durante aplicação do protocolo de captura - Alguns neonatos com PCA tiveram taquicardia (aceleração dos batimentos cardíacos) durante sua preparação para a captura de imagens, fazendo com que o protocolo de captura fosse interrompido imediatamente.

No entanto, experimentos preliminares, baseados em descritores estatísticos e na simulação de instâncias, demonstraram o potencial do banco de instâncias definido pela pesquisa para a representação dos padrões de simetria e assimetria térmica em imagens térmicas de recém-nascidos, motivando a expansão do conjunto de imagens térmicas e a realização de novos treinamentos de RNA.

Todo trabalho de pesquisa também viabilizou a criação do PCA *Diagnostic*, principal objetivo proposto na tese em questão. O referido sistema permitiu aos profissionais de saúde envolvidos na pesquisa terem acesso a uma ferramenta que de fato foi bem precisa no diagnóstico de PCA em vários casos de testes, classificando imagens de forma correta em 92,14% dos casos. Mesmo quando cometeu erros de classificação, em 7,86% dos casos de teste, gerou novas instâncias para seu *dataset*, permitindo ao mesmo aprender com os próprios erros e a ser mais preciso em classificações futuras. Portanto, pode-se afirmar que a pesquisa em questão atendeu as finalidades objetivadas.

5.2 TRABALHOS FUTUROS

Como trabalhos futuros, propõe-se a aplicação de um limiar local na primeira etapa de segmentação, baseada em *threshold*, que permitirá a extração de regiões de interesse em imagens de neonatos com temperaturas que fujam da temperatura média devido à margem de erro na câmera térmica, e a atribuição dinâmica tanto da posição inicial e dimensão da máscara de sementes, quanto do número de iterações no algoritmo dos contornos ativos aplicados no segundo estágio de segmentação da pesquisa, para que a segmentação automática baseada em contornos ativos seja ainda mais precisa.

Além disso, é importante a definição de vetores de instâncias que caracterizem outras doenças e/ou sintomas dos pacientes que também repercutam na sua distribuição de temperatura. É normal que neonatos prematuros, quando possuem PCA, tenham outros problemas que possam provocar assimetria térmica. Também foi observado durante a pesquisa que o simples fato dos bebês terem se alimentado momentos antes do protocolo de captura possa gerar falsos-positivos (aumentar a temperatura do abdômen). Outras doenças cardíacas também podem ter as mesmas características de temperatura que as encontradas em bebês com PCA. Definidos os vetores de características para cada caso citado aumentaria ainda mais a confiabilidade do sistema, não só na predição da PCA, mas também para o auxílio no diagnóstico de outras doenças e na verificação de ocorrência de falsos positivos ou negativos.

Também é proposto como trabalho futuro a realização de testes em outros algoritmos de classificação, bem como refinar os atributos que compõem o atual conjunto de instâncias definido para a classificação de PCA, a fim de avaliar possíveis melhorias nas taxas de acurácia na classificação de imagens com e sem PCA. Foi visto a partir dos resultados obtidos que o algoritmo Naive Bayes, por exemplo, teve resultados similares aos adquiridos a partir da melhor arquitetura de RNA definida pela pesquisa em questão, mesmo utilizando parâmetros padrão para seu aprendizado.

No âmbito clínico, como trabalho futuro, é sugerido a realização de trabalhos de correlação entre as classificações geradas pelo sistema computacional desenvolvido com resultados clínicos obtidos a partir de ecocardiografia, que é o padrão-ouro no diagnóstico de PCA. Tal correlação iria equiparar o *feedback* dado pelo sistema computacional proposto com características de repercussão hemodinâmica passíveis de serem observadas nesse tipo de exame, gerando inclusive dados que poderiam compor novos conjuntos de dados a serem utilizados como entrada em técnicas de aprendizagem de máquina.

REFERÊNCIAS

- ABBAS, A. K.; HEIMANN, K.; JERGUS, K.; ORLIKOWSKY, T.; LEONHARDT, S. Neonatal non-contact respiratory monitoring based on real-time infrared thermography. *BioMedical Engineering OnLine*, 2011.
- ABBAS, A. K.; LEONHARDT, S. Intelligent neonatal monitoring based on a virtual thermal sensor. *BMC Medical Imaging*, 2014.
- ABCMED. *Insuficiência cardíaca congestiva. O que é isso?* 2017. [Http://www.abc.med.br/p/sinais.-sintomas-e-doencas/251830/insuficiencia-cardiaca-congestiva-o-que-e-isso.htm](http://www.abc.med.br/p/sinais.-sintomas-e-doencas/251830/insuficiencia-cardiaca-congestiva-o-que-e-isso.htm). Acesso em: 25 Fev. 2017.
- AHA, D.; KIBLER, D. Instance-based learning algorithms. *Machine Learning*, v. 6, p. 37–66, 1991.
- ARALDI, A. A. R. *Estatística e Probabilidade*. 2018. [Http://www.ensinoeinformacao.com/estatist-prob-curso-assimetria](http://www.ensinoeinformacao.com/estatist-prob-curso-assimetria). Acesso em: 15 Nov. 2018.
- BACKES, A. R.; JÚNIOR, J. J. M. S. *Introdução à visão computacional usando MATLAB*. [S.l.]: Alta Books, 2016.
- BERTOLO, L. A. *Curtose*. 2018. [Http://www.bertolo.pro.br/AdminFin/AnalInvest/Curtose.pdf](http://www.bertolo.pro.br/AdminFin/AnalInvest/Curtose.pdf). Acesso em: 15 Nov. 2018.
- BERTUOL, G. *Análise e aplicação da técnica de contornos ativos com métodos de segmentação tradicionais em imagens médicas*. 2007. Monografia (Bacharel em Ciência da Computação), UFSC (Universidade Federal de Santa Catarina), Florianópolis, Brasil.
- BRAGANÇA, C. A. *Canal arterial patente em recém-nascidos prematuros: perfil de apresentação e eficácia das terapêuticas clínica e cirúrgica*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, 2011.
- BROWNLEE, J. *How Much Training Data is Required for Machine Learning?* 2017. [Https://machinelearningmastery.com/much-training-data-required-machine-learning/](https://machinelearningmastery.com/much-training-data-required-machine-learning/). Acesso em: 24 Jan. 2019.
- BROWNLEE, J. *Impact of Dataset Size on Deep Learning Model Skill And Performance Estimates*. 2019. [Https://machinelearningmastery.com/impact-of-dataset-size-on-deep-learning-model-skill-and-performance-estimates/](https://machinelearningmastery.com/impact-of-dataset-size-on-deep-learning-model-skill-and-performance-estimates/). Acesso em: 24 Jan. 2019.
- CATALAN, L. B. *Neonatal Infrared Thermography Image Processing*. Dissertação (Mestrado) — HELMHOLTZ-INSTITUTE FOR BIOMEDICAL ENGINEERING, RWTH AACHEN, 5 2009.
- CHAN, T. F.; VESE, L. A. Active contours without edges. *IEEE Transactions on Image Processing*, v. 10, n. 2, p. 266–277, 2001.
- CHANG, T.; KUO, C. Texture analysis and classification with tree-structure wavelet transform. In: *IEEE Transactions on Image Processing*. [S.l.: s.n.], 1993.

- CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. Smote: synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, v. 16, n. 1, p. 321–357, 2002.
- CHEN, Y. T.; WANG, M. S. Human face recognition using thermal image. *Journal of Medical and Biological Engineering*, v. 22, n. 2, p. 97–102, 2002.
- CHRISTIDIS, I.; MD, H. Z.; ROSEGGER, H.; ENGELE, H.; KURZ, R.; KERBL, R. Infrared thermography in newborns: the first hour after birth. *PubMed*, 2003.
- CHÁVEZ, G. *The main issue with identifying Financial Fraud using Machine Learning (and how to address it)*. 2019. <https://towardsdatascience.com/the-main-issue-with-identifying-financial-fraud-using-machine-learning-and-how-to-address-it-3b1bf8fa1e0c>. Acesso em: 19 Jun. 2019.
- CLEARY, J. G.; TRIGG, L. E. K*: An instance-based learner using an entropic distance measure. In: *12th International Conference on Machine Learning*. [S.l.: s.n.], 1995. p. 108–114.
- CUNHA, L. S. da. *Assimetria e Curtose*. 2017. [http://www.uel.br/pessoal/lscunha/pages/arquivos/uel/Economia%20Noturno/Aula%206%20-%20Assimetria%20e%20Curtose\(1\).pdf](http://www.uel.br/pessoal/lscunha/pages/arquivos/uel/Economia%20Noturno/Aula%206%20-%20Assimetria%20e%20Curtose(1).pdf). Acesso em: 15 Nov. 2018.
- DIAKIDES, N. A.; BRONZINHO, J. D. *Medical Infrared Imaging*. [S.l.]: CRC Press, 2008.
- DOMINGOS, P. Metacost: A general method for making classifiers cost-sensitive. In: *Fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. [S.l.: s.n.], 1999.
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. *Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina*. [S.l.]: LTC, 2011.
- FARIAS, T. M. T. de; LIMA, M. E. de; MATTOS, S. da S.; ARAUJO, J. S. S. de; MOZER, L. R. D. N.; MOURATO, F. A. Automatic segmentation of neonates thermal imaging for evaluation of trunk thermal asymmetry. In: *2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. [S.l.: s.n.], 2018. p. 989–992.
- FLIR. *FLIR One*. 2016. <https://www.flir.com.br/flir-one/>. Acesso em: 01 Nov. 2018.
- FROHLICH, J. *Neural Networks with Java*. 1997. <http://rfhs8012.fh-regensburg.de/saj39122/jfroehl/diplom/e-index.html>. Acesso em: 10 Jan. 2017.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (2nd Ed)*. [S.l.]: Prentice Hall, 2002.
- GRUNAU, R.; HOLSTI, L.; PETERS, J. W. Long-term consequences of pain in human neonates. *Seminars in Fetal and Neonatal Medicine*, n. 11, p. 268–275, 2006.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software: an update. *SIGKDD Explorations*, v. 11, n. 1, p. 10–18, 2009.

- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. In: *IEEE Transactions on Systems, Man, and Cybernetics*. [S.l.: s.n.], 1973.
- HAYKIN, S. *Redes Neurais: Princípios e Prática*. [S.l.]: Porto Alegre: Bookman, 2001.
- HEBB, D. O. *The Organization of Behavior*. [S.l.]: Wiley, 1949.
- HOEKSTRA, P. *Screening for Breasts Cancer and Heart Disease*. 2016. [Http://youthermalimaging.com/node/33](http://youthermalimaging.com/node/33). Acesso em: 14 Abr. 2016.
- HULTEN, G.; SPENCER, L.; DOMINGOS, P. Mining time-changing data streams. In: *ACM SIGKDD Intl. Conf. on Knowledge Discovery and Data Mining*. [S.l.]: ACM Press, 2001. p. 97–106.
- INTERNATIONAL ACADEMY OF CLINICAL THERMOGRAPHY. Standards and Protocols in Clinical Thermographic Imaging*. 2002. [Https://www.iact-org.org/professionals/thermog-guidelines.html](https://www.iact-org.org/professionals/thermog-guidelines.html). Acesso em: 19 Jun. 2019.
- JAPKOWICZ, N. The class imbalance problem: Significance and strategies. In: *2000 International Conference on Artificial Intelligence (IC-AI'2000): Special Track on Inductive Learning*. [S.l.: s.n.], 2000.
- JOHN, G. H.; LANGLEY, P. Estimating continuous distributions in bayesian classifiers. In: *Eleventh Conference on Uncertainty in Artificial Intelligence*. [S.l.: s.n.], 1995. p. 338–345.
- KLAESSENS, J. H.; BORN, M. van den; VEEN, A. van der; KRAATS, J. S. van de; DUNGEN, F. A. van den; VERDAASDONK, R. M. Development of a baby friendly non-contact method for measuring vital signs: First results of clinical measurements in an open incubator at a neonatal intensive care unit. In: *SPIE 2014*. [S.l.: s.n.], 2014.
- KOAY, J.; HERRY, C.; FRIZE, M. Analisis of breast thermography with na artificial neural network. In: *Proceedings of the 26th Annual International Conference of the IEEE EMBS*. [S.l.: s.n.], 2004.
- KOTB, M. A.; ELMAHDY, H. N.; MOSTAFA, F. E. Z.; SHAKER, C. W.; REFAEY, M. A.; RJOOB, K. W. Y. Recognition of heart murmur based on machine learning and visual based analysis of phonocardiography. In: ARAI, K.; KAPOOR, S.; BHATIA, R. (Ed.). *Intelligent Computing*. Cham: Springer International Publishing, 2019. p. 188–202. ISBN 978-3-030-01177-2.
- KUBAT, M.; MATWIN, S. Addressing the curse of imbalanced training sets: One sided selection. In: *Fourteenth International Conference on Machine Learning*. [S.l.: s.n.], 1997.
- KUMAR, Y.; SAHOO, G. Analysis of parametric e non parametric classifiers for classification technique using weka. *International Journal of Information Technology and Computer Science*, v. 4, p. 43–49, 07 2012.
- LEWIS, D.; CATLETT, J. Heterogeneous uncertainty sampling for supervised learning. In: *Eleventh International Conference of Machine Learning*. [S.l.: s.n.], 1994.
- LING, C.; LI, C. Data mining for direct marketing problems and solutions. In: *Fourth International Conference on Knowledge Discovery and Data Mining (KDD-98)*. [S.l.: s.n.], 1998.

- LUGER, G. F. *Inteligência Artificial*. [S.l.]: Pearson Education do Brasil, 2013.
- MINSKY, M. L.; PAPER, S. *Perceptrons*. [S.l.]: MIT Press, 1969.
- MOLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, v. 6, p. 525–533, 1993.
- NUR, R. *Identification of Thermal Abnormalities by Analysis of Abdominal Infrared Thermal Images of Neonatal Patients*. Dissertação (Mestrado) — Carleton University, 2013.
- Open Osmosis. *Patent Ductus Arteriosus (PDA)*. 2016. <https://open.osmosis.org/>. Acesso em: 02 Set. 2016.
- PALFY, M.; PAPEZ, B. J. Diagnoses of carpal tunnel syndrome from thermal images using artificial neural networks. *Computer-Based Medical Systems*, p. 59–64, 2007.
- PAZZANI, M.; MERZ, C.; MURPHY, P.; ALI, K.; HUME, T.; BRUNK, C. Reducing misclassification costs. In: *Eleventh International Conference on Machine Learning*. [S.l.: s.n.], 1994.
- PETTRES, R. *Reconhecimento de Padrões de Defeitos em Concreto a partir de Imagens Térmicas Estacionárias e Redes Neurais Artificiais*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, 2011.
- POMERANCE, J. J.; LIEBERMAN, R. L.; UKRAINSKI, C. T. Neonatal thermography. *PEDIATRICS*, 1977.
- RATHORE, S.; BHALERAO, S. V. Designing of neuro-fuzzy based thermal imaging system on matlab for detection of rheumatoid arthritis. *International Journal of Engineering Research and General Science*, v. 3, n. 2, 2015.
- RAUDYS, S. J.; JAIN, A. K. Small sample size effects in statistical pattern recognition: Recommendations for practitioners. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 13, n. 3, p. 252–264, 1991.
- REIS, M. M. *Introdução e Análise Exploratória de Dados*. 2018. <https://www.inf.ufsc.br/marcelo.menezes.reis/INE7001.html>. Acesso em: 15 Nov. 2018.
- RICE, H. E.; HOLLINGSWORTH, C. L.; BRADSHAW, E.; DANKO, M. E.; CROSBY, S. M.; GOLDBERG, R. N.; TANAKA, D. T.; KNOBEL, R. B. *Infrared Thermal Imaging (Thermography) of the Abdomen in Extremely Low Birthweight Infants*. [S.l.]: Progressive Science, 2015.
- RIOS, L. R. S. *Visão Computacional*. 2010. [http://homes.dcc.ufba.br/luizromario/A-presenta%C3%A7%C3%A3o%20de%20IA/Artigo%20\(final\).pdf](http://homes.dcc.ufba.br/luizromario/A-presenta%C3%A7%C3%A3o%20de%20IA/Artigo%20(final).pdf). Acesso em: 07 Jul. 2016.
- RIVERA, L. B. C.; MAYNEZ, L. O.; LÁZARO, R. C. A. Determination of temperature in neonates based in a face ir thermography image segmentation algorithm. In: *11th International Conference on Electrical Engineering, Computing Science and Automatic Control*. [S.l.: s.n.], 2014.

- ROABERT, S. *Radiação infravermelha e energia. Aprender Ciências*. 2017. [Http://www.aprenderciencias.com/2011/10/uma-onda-eletromagnetica-na-faixa-do.html](http://www.aprenderciencias.com/2011/10/uma-onda-eletromagnetica-na-faixa-do.html). Acesso em: 17 Fev. 2017.
- ROSEMBLATT, F. *The perceptron: A probabilistic model for information storage and organization in the brain*. [S.l.]: Psychological Review, 1958.
- RUMELHART, D. E.; HILTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: *THE PDP Research Group. Parallel Distributed Processing*. [S.l.: s.n.], 1986.
- SANCHES, I. J. *Sobreposição de Imagens de Termografia e Ressonância Magnética: Uma Nova Modalidade de Imagem Médica Tridimensional*. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, 2009.
- SCALISE, L. Non contact heart monitoring. *Advances in Electrocardiograms – Methods and Analysis*, 2012.
- SERAFIN, V.; MOREIRA, A.; MARGOTTO, P. *Persistência do canal arterial (PCA)*. 2011. [Http://paulomagotto.com.br/documentos/PCA-2011.doc](http://paulomagotto.com.br/documentos/PCA-2011.doc). Acesso em: 17 Fev. 2017.
- SHEPHERD, A. J. *Second-Order Methods for Neural Networks – Fast and Reliable Methods for Multi-Layer Perceptrons*. [S.l.]: Springer, 1997.
- SILVA, L. N. de C. *Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais*. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação - UNICAMP, Campinas - SP, 9 1998.
- THIRUVENGADAM, J.; ANBURAJAN, M.; VENKATRAMAN, B. Potential of thermal imaging as a tool for prediction of cardiovascular disease. *Journal of Medical Physics*, 2014.
- TSOUKALAS, L. H.; UHRIG, R. E. *Fuzzy and Neural Approaches in Engineering*. [S.l.]: Wiley-Interscience, 1997.
- TUCERYAN, M.; JAIN, A. K. *Handbook of Pattern Recognition and Computer Vision*. [S.l.]: World Scientific, 1993.
- VILLARROEL, M.; GUAZZI, A.; JORGE, J.; DAVIS, S.; WATKINSON, P.; GREEN, G.; SHENVI, A.; MCCORMICK, K.; TARASSENKO, L. Continuous non-contact vital sign monitoring in neonatal intensive care unit. *Healthcare Technology Letters*, 2014.
- WESZKA, J. S.; DYER, C. R.; ROSENFELD, A. A comparative study of texture measures for terrain classification. In: *IEEE Transactions on Systems, Man, and Cybernetics*. [S.l.: s.n.], 1976.
- WILLIAMS, T. *Thermal Imaging Cameras - Characteristics and Performance*. [S.l.]: CRC Press, 2009.
- YANG, E. M.; SONG, E. S.; CHOI, Y. Y. Comparação do ibuprofeno via oral e indometacina intravenosa no tratamento da persistência do canal arterial em neonatos com extremo baixo peso ao nascer. *Jornal de Pediatria*, v. 89, p. 33–39, 2013.

APÊNDICE A – MODELO DA FICHA DE REGISTRO CLÍNICO**FICHA DE REGISTRO DE NEONATO**

Local da Coleta: _____

Nome do Neonato:		
Nº de Registro:		
Data de Nascimento:		
Data e Hora de Captura:		
Peso:	Altura:	Sexo:



APÊNDICE B – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Convidamos V.Sa. a participar da pesquisa CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIS ARTIFICIAIS, sob responsabilidade do pesquisador THYAGO MAIA TAVARES DE FARIAS e sua equipe SANDRA DA SILVA MATTOS, LUCIA ROBERTA DIDIER NUNES MOZER, JULIANA SOUSA SOARES DE ARAÚJO e FELIPE ALVES MOURATO, orientado pelo Professor MANOEL EUSEBIO DE LIMA, tendo por objetivo desenvolver um sistema de computador que permita identificar a existência ou não da persistência do canal arterial (PCA) em bebês a partir de informações de temperatura obtidas em imagens térmicas.

Se não tratada adequadamente, a PCA pode resultar em mortalidade, sobretudo entre os recém-nascidos de muito baixo peso. A PCA aumenta em até 30% o fluxo sanguíneo nos pulmões, elevando a velocidade de fluxo da artéria pulmonar. Esse "roubo de fluxo" deixa áreas da circulação sistêmica com déficit, podendo levar a sérias complicações. Evidências sugerem que alterações no fluxo sanguíneo geram aumento de temperatura corporal localizada, provocando o surgimento de regiões de calor em imagens térmicas. Tais regiões podem evidenciar a ocorrência de alguma alteração no organismo ou doenças.

Para realização deste trabalho, usaremos o(s) seguinte(s) método(s): recém-nascidos, com e sem PCA, serão fotografados a partir de uma câmera térmica. A mesma permite a captura de imagens com informações de temperatura representadas por cores que destacam regiões de calor na pele dos bebês. Tais imagens irão fornecer dados de temperatura que serão utilizados pela aplicação a ser desenvolvida durante nossa pesquisa. A partir de tais dados, é previsto a possibilidade do sistema prever se cada imagem analisada apresenta um bebê que possui PCA ou não. Será utilizada a câmera térmica FLIR ONE iOS, da FLIR® na captura de imagens térmicas dos recém-nascidos. Trata-se de uma câmera portátil de baixo custo, conectada a um *smartphone* ou *tablet*.

Esclarecemos que manteremos em anonimato, sob sigilo absoluto, durante e após o término do estudo, todos os dados que identifiquem o sujeito da pesquisa usando apenas, para divulgação, os dados inerentes ao desenvolvimento do estudo. Informamos também que após o término da pesquisa, serão destruídos de todo e qualquer tipo de mídia que possa vir a identificá-lo tais como filmagens, fotos, gravações, etc., não restando nada que venha a comprometer o anonimato de sua participação agora ou futuramente.

Em relação ao desconforto e riscos possíveis, não é possível tirar fotos térmicas de recém-nascidos em incubadoras, devido ao material acrílico utilizado não permitir o registro de emissividade por uma câmera térmica. Nesse caso, o bebê deverá ser retirado da incubadora. A breve retirada do bebê da incubadora pode aumentar seu nível de estresse. Portanto, o tempo limite de captura não deverá ultrapassar 1 minuto. Profissionais de saúde neonatal deverão estar presentes em todos os momentos para garantir que os sinais vitais do bebê estejam dentro de limites aceitáveis durante o procedimento. É recomendado que as fotografias sejam capturadas em momentos padrão para a saída de bebês das incubadoras, como em pesagens. Não há risco diretos de infecção para o responsável e para o dependente, já que a câmera utilizada não depende de contato direto com a pele humana e não emprega radiação ionizante.

Não há benefícios médicos imediatos para os recém-nascidos envolvidos neste estudo, pois este é um estudo investigativo para determinar o possível valor do uso de imagens térmicas no auxílio ao diagnóstico da PCA. No entanto, ser capaz de compreender melhor o mecanismo fisiológico associado à PCA poderá levar a um melhor gerenciamento da doença e reduzir as taxas de mortalidade no futuro. Se pudermos demonstrar que a termografia pode "ver" as alterações no fluxo sanguíneo dos neonatos provocados pela PCA, isso proporcionaria um meio objetivo de avaliar a PCA de forma não invasiva, algo atualmente não disponível e de grande impacto, potencial, nesta população. O meio de diagnóstico mais utilizado para a PCA é a ecocardiografia, sendo possível a realização de tomografia computadorizada e ecografia intravascular. A criação de um novo meio de

diagnóstico para a PCA, baseado em processos de inteligência artificial, utilizado em conjunto com os demais meios tradicionais de diagnóstico, tornará a investigação ainda mais precisa.

O (A) senhor (a) terá os seguintes direitos: a garantia de esclarecimento e resposta a qualquer pergunta; a liberdade de abandonar a pesquisa a qualquer momento sem prejuízo para si ou para o tratamento do dependente (se for o caso); a garantia de que em caso haja algum dano a sua pessoa (ou o dependente), os prejuízos serão assumidos pelos pesquisadores ou pela instituição responsável. Inclusive, acompanhamento médico e hospitalar integral e gratuito pelo tempo que for necessário em caso de danos decorrentes direta ou indiretamente da participação do estudo; a garantia do acesso aos resultados da pesquisa sempre que solicitado e/ou indicado; a garantia de indenização em casos de danos, comprovadamente, decorrentes da sua participação na pesquisa, por meio de decisão judicial ou extrajudicial. Não há qualquer valor econômico, a receber ou a pagar, pela sua participação. Caso haja gastos adicionais, os mesmos serão absorvidos pelo pesquisador.

Nos casos de dúvidas e esclarecimentos o (a) senhor (a) deve procurar o pesquisador THYAGO MAIA TAVARES DE FARIAS no Centro de Informática (CIn) da UFPE, localizado na Av. Jornalista Aníbal Fernandes, s/n, Cidade Universitária (Campus Recife), CEP: 50740-560, Recife-PE, Telefone: (83) 99979-6179. Caso suas dúvidas não sejam resolvidas pelos pesquisadores ou seus direitos sejam negados, favor recorrer ao **Comitê de Ética em Pesquisa do CISAM- Centro Integrado de Saúde Amaury de Medeiros / Universidade de Pernambuco-UPE, localizado à Rua Visconde de Mamanguape s/n, 1º andar, bairro: Encruzilhada, CEP: 52030-010 Recife - PE, Telefone: (81) 3182 77 38 ou ainda através do email: cep.cisam@upe.br**. O Comitê de Ética em Pesquisa (CEP) é um colegiado interdisciplinar e independente, que deve existir nas instituições que realizam pesquisas envolvendo seres humanos no Brasil, criado para defender os interesses dos sujeitos em sua integridade e dignidade e para contribuir no desenvolvimento da pesquisa dentro dos padrões éticos.

Consentimento Livre e Esclarecido

Eu _____, responsável por _____, após ter recebido todos os esclarecimentos e ciente dos meus direitos, autorizo o meu filho(a) a participar desta pesquisa, bem como autorizo a divulgação e a publicação de toda informação por mim transmitida, exceto dados pessoais, em publicações e eventos de caráter científico. Desta forma, assino este termo, juntamente com o pesquisador, em duas vias de igual teor, ficando uma via sob meu poder e outra em poder do(s) pesquisador (es).

Local:

Data: __/__/__

Assinatura do sujeito (ou responsável)

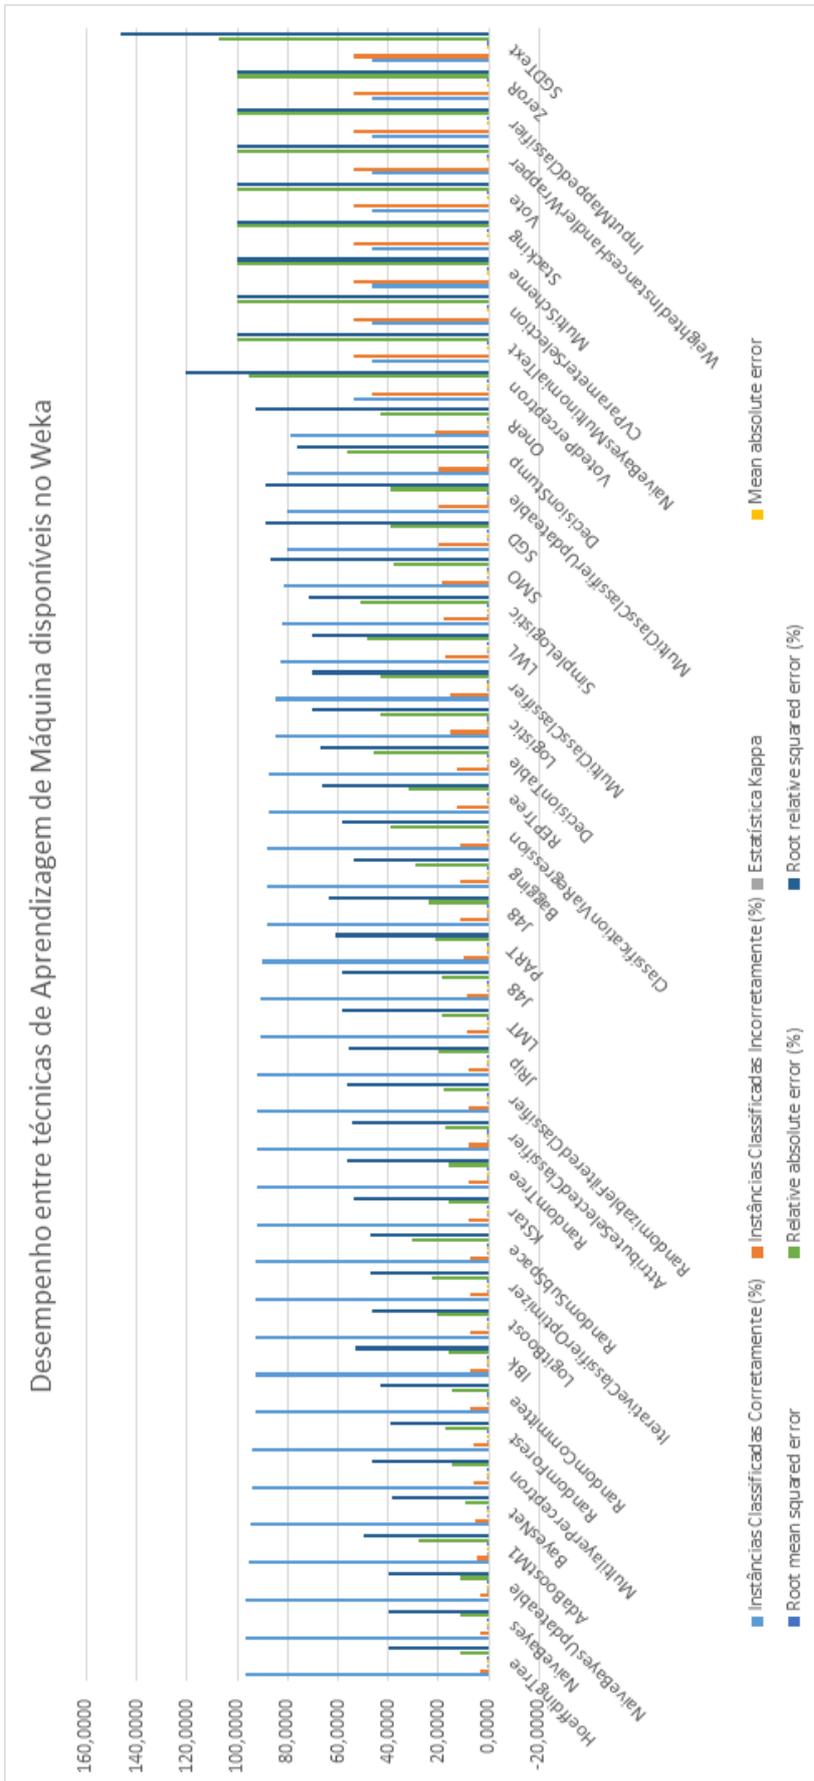
Assinatura do pesquisador

**APÊNDICE C – TABELA - TESTES DE DESEMPENHO ENTRE TÉCNICAS
DE APRENDIZAGEM DE MÁQUINA DISPONÍVEIS NO WEKA
CONSIDERANDO 112 AMOSTRAS**

Tabela 8 – Testes de Desempenho entre Técnicas de Aprendizagem de Máquina Disponíveis no Weka considerando 112 amostras

	Instâncias Classificadas	Corretamente (%)	Estatística Kappa	Mean Absolute Error	Root Mean Squared Error	Relative Absolute Error (%)	Root Relative Squared Error (%)
HoeffdingTree	96,4286	0,9286	0,0550	0,1986	10,9884	39,6866	
NaiveBayes	96,4286	0,9286	0,0552	0,1987	11,0370	39,7033	
NaiveBayesUpdateable	96,4286	0,9286	0,0552	0,1987	11,0370	39,7033	
AdaBoostM1	95,5357	0,9107	0,1382	0,2475	27,6235	49,4726	
BayesNet	94,0429	0,8929	0,0468	0,1917	9,3443	38,3164	
MultiLayerPerceptron	93,7500	0,8750	0,0734	0,2333	14,6624	46,6160	
RandomForest	93,7500	0,8750	0,0865	0,1945	17,2916	38,8675	
RandomCommittee	92,8571	0,8571	0,0732	0,2151	14,6327	42,9802	
IBk	92,8571	0,8571	0,0798	0,2648	15,9421	52,9259	
LogitBoost	92,8571	0,8571	0,1041	0,2309	20,8126	46,1464	
IterativeClassifierOptimizer	92,8571	0,8571	0,1112	0,2360	22,2346	47,1667	
RandomSubSpace	92,8571	0,8571	0,1523	0,2344	30,4307	46,8474	
KStar	91,9643	0,8393	0,0796	0,2682	15,9053	53,5987	
RandomTree	91,9643	0,8393	0,0804	0,2835	16,0603	56,6533	
AttributeSelectedClassifier	91,9643	0,8393	0,0866	0,2722	17,3056	54,3944	
RandomizableFilteredClassifier	91,9643	0,8393	0,0885	0,2809	17,6919	56,1324	
JRip	91,9643	0,8393	0,0996	0,2770	19,9002	55,3673	
LMT	91,0714	0,8214	0,0926	0,2923	18,5127	58,4261	
J48	91,0714	0,8214	0,0944	0,2913	18,8671	58,2262	
PART	90,1786	0,8036	0,1051	0,3052	20,9957	60,9994	
J48	88,3929	0,7679	0,1204	0,3183	24,0549	63,6140	
Bagging	88,3929	0,7679	0,1446	0,2685	28,8916	53,6674	
ClassificationViaRegression	88,3929	0,7679	0,1945	0,2926	38,8631	58,4717	
REPTree	87,5000	0,7500	0,1600	0,3313	31,9836	66,2121	
DecisionTable	87,5000	0,7500	0,2295	0,3334	45,8612	66,6352	
Logistic	84,8214	0,6964	0,2141	0,3506	42,7931	70,0654	
MultiClassClassifier	84,8214	0,6964	0,2141	0,3506	42,7931	70,0654	
LWL	83,0357	0,6607	0,2408	0,3507	48,1263	70,0837	
SimpleLogistic	82,1429	0,6429	0,2560	0,3594	51,1602	71,8293	
SMO	81,2500	0,6250	0,1875	0,4330	37,4740	86,5393	
SGD	80,3571	0,6071	0,1964	0,4432	39,2585	88,5758	
MultiClassClassifierUpdateable	80,3571	0,6071	0,1964	0,4432	39,2585	88,5758	
DecisionStump	80,3571	0,6071	0,2802	0,4322	56,0017	76,3842	
OneR	78,5714	0,5714	0,2143	0,4629	42,8274	92,5145	
VotedPerceptron	53,5714	0,0714	0,4769	0,6027	95,3197	120,4482	
NaiveBayesMultinomialText	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
CVParameterSelection	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
MultiScheme	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
Stacking	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
Vote	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
WeightedInstancesHandlerWrapper	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
InputMappedClassifier	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
ZeroR	46,4286	-0,0714	0,5003	0,5004	100,0000	100,0000	
SGDText	46,4286	-0,0714	0,5357	0,7319	107,0686	146,2782	

**APÊNDICE D – GRÁFICO - TESTES DE DESEMPENHO ENTRE TÉCNICAS
DE APRENDIZAGEM DE MÁQUINA DISPONÍVEIS NO WEKA,
CONSIDERANDO 112 AMOSTRAS**

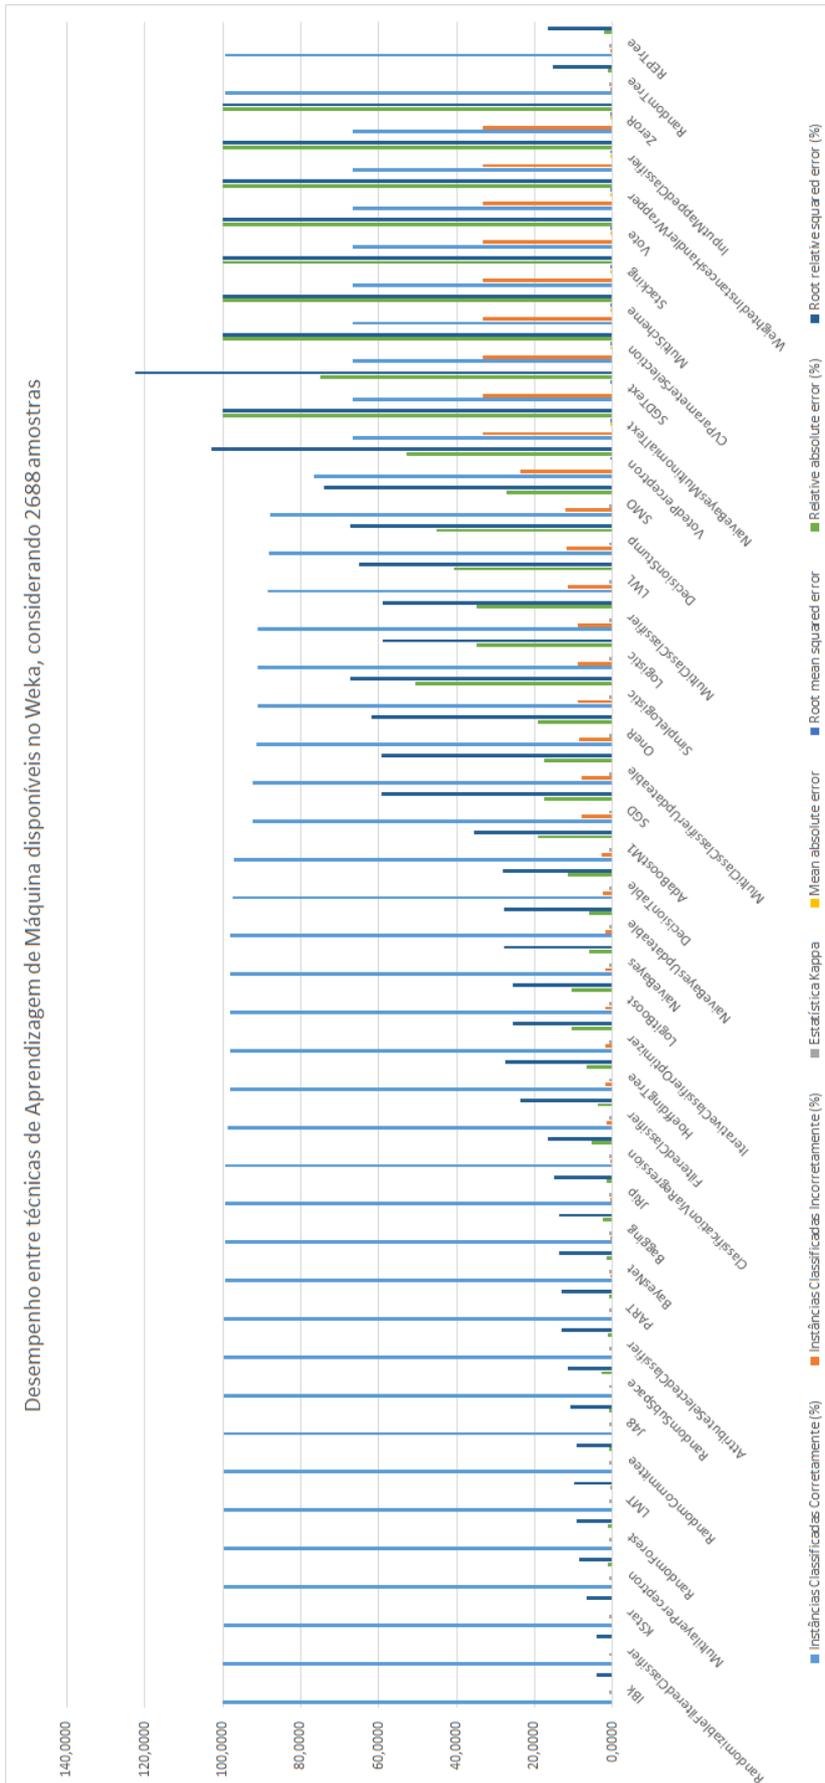


**APÊNDICE E – TABELA - TESTES DE DESEMPENHO ENTRE TÉCNICAS
DE APRENDIZAGEM DE MÁQUINA DISPONÍVEIS NO WEKA
CONSIDERANDO 2688 AMOSTRAS**

Tabela 9 – Testes de Desempenho entre Técnicas de Aprendizagem de Máquina Disponíveis no Weka considerando 2688 amostras

	Instâncias Classificadas Corretamente (%)	Estatística Kappa	Mean Absolute Error	Root Mean Squared Error	Relative Absolute Error (%)	Root Relative Squared Error (%)
IBk	99,9628	0,9992	0,0008	0,0193	0,1765	4,0908
RandomizableFilteredClassifier	99,9628	0,9992	0,0008	0,0193	0,1765	4,0908
KStar	99,8512	0,9966	0,0014	0,0313	0,3086	6,6494
MultiLayerPerceptron	99,8140	0,9958	0,0048	0,0403	1,0719	8,5528
RandomForest	99,8140	0,9958	0,0056	0,0437	1,2596	9,2794
LMT	99,7768	0,9950	0,0023	0,0459	0,5239	9,7399
J48	99,7396	0,9941	0,0035	0,0510	0,7861	10,8141
RandomCommittee	99,7396	0,9941	0,0036	0,0434	0,8119	9,2129
RandomSubSpace	99,7024	0,9933	0,0123	0,0542	2,7710	11,5013
PART	99,6280	0,9916	0,0045	0,0609	1,0191	12,9209
AttributeSelectedClassifier	99,6280	0,9916	0,0057	0,0611	1,2716	12,9645
BayesNet	99,5164	0,9891	0,0061	0,0652	1,3706	13,8389
Bagging	99,5164	0,9891	0,0110	0,0643	2,4806	13,6336
RandomTree	99,4792	0,9883	0,0052	0,0722	1,1718	15,3093
JRip	99,4792	0,9883	0,0060	0,0713	1,3576	15,1350
REPTree	99,4048	0,9866	0,0089	0,0775	2,0034	16,4324
ClassificationViaRegression	99,3676	0,9857	0,0231	0,0789	5,1974	16,7367
FilteredClassifier	98,5863	0,9679	0,0170	0,1116	3,8313	23,6675
HoeffdingTree	98,2515	0,9604	0,0298	0,1301	6,7071	27,5992
IterativeClassifierOptimizer	98,1771	0,9586	0,0461	0,1211	10,3781	25,6858
LogitBoost	98,1771	0,9586	0,0461	0,1211	10,3781	25,6858
NaiveBayes	98,1399	0,9578	0,0272	0,1311	6,1297	27,8120
NaiveBayesUpdateable	98,1399	0,9578	0,0272	0,1311	6,1297	27,8120
DecisionTable	97,3958	0,9405	0,0509	0,1331	11,4450	28,2418
AdaBoostM1	97,2098	0,9363	0,0850	0,1669	19,1261	35,4038
SGD	92,1875	0,8133	0,0781	0,2795	17,5763	59,2926
MultiClassClassifierUpdateable	92,1875	0,8133	0,0781	0,2795	17,5763	59,2926
OneR	91,5179	0,8034	0,0848	0,2912	19,0828	61,7815
SimpleLogistic	91,1830	0,7876	0,2254	0,3168	50,7065	67,2057
Logistic	90,9970	0,7913	0,1557	0,2778	35,0209	58,9331
MultiClassClassifier	90,9970	0,7913	0,1557	0,2778	35,0209	58,9331
LWL	88,5417	0,7181	0,1806	0,3064	40,6375	64,9999
DecisionStump	88,2068	0,7091	0,2002	0,3168	45,0425	67,1955
SMO	87,8720	0,6998	0,1213	0,3483	27,2851	73,8754
VotedPerceptron	76,4881	0,3577	0,2352	0,4849	52,9102	102,8610
SGDText	66,6667	0,0000	0,3333	0,5774	74,9922	122,4743
NaiveBayesMultinomialText	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
CVParameterSelection	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
MultiScheme	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
Stacking	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
Vote	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
WeightedInstancesHandlerWrapper	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
InputMappedClassifier	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000
ZeroR	66,6667	0,0000	0,4445	0,4714	100,0000	100,0000

**APÊNDICE F – GRÁFICO - TESTES DE DESEMPENHO ENTRE TÉCNICAS
DE APRENDIZAGEM DE MÁQUINA DISPONÍVEIS NO WEKA,
CONSIDERANDO 2688 AMOSTRAS**



ANEXO A – PLATAFORMA BRASIL - INFORMAÇÕES BÁSICAS DO PROJETO



MINISTÉRIO DA SAÚDE - Conselho Nacional de Saúde - Comissão Nacional de Ética em Pesquisa – CONEP
PROJETO DE PESQUISA ENVOLVENDO SERES HUMANOS

Projeto de Pesquisa:
 CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIS ARTIFICIAIS

Informações Preliminares

Responsável Principal

CPF/Documento: 053.853.514-82	Nome: THYAGO MAIA TAVARES DE FARIAS
Telefone: 83999796179	E-mail: thyagomaia@gmail.com

Instituição Proponente

CNPJ:	Nome da Instituição: CENTRO DE INFORMÁTICA
-------	--

É um estudo internacional? Não

■ **Assistentes**

CPF/Documento	Nome
053.853.514-82	THYAGO MAIA TAVARES DE FARIAS
141.722.244-15	Sandra da Silva Mattos

■ **Equipe de Pesquisa**

CPF/Documento	Nome
693.207.644-68	LUCIA ROBERTA DIDIER NUNES MOZER
023.390.404-26	JULIANA SOUSA SOARES DE ARAÚJO
069.894.584-02	Felipe Alves Mourato
141.722.244-15	Sandra da Silva Mattos
053.853.514-82	THYAGO MAIA TAVARES DE FARIAS

Área de Estudo

Grandes Áreas do Conhecimento (CNPq)

- Grande Área 1. Ciências Exatas e da Terra
- Grande Área 2. Ciências Biológicas
- Grande Área 3. Engenharias

Título Público da Pesquisa: CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIS ARTIFICIAIS

Contato Público

CPF/Documento	Nome	Telefone	E-mail
053.853.514-82	THYAGO MAIA TAVARES DE FARIAS	83999796179	thyagomaia@gmail.com

Contato Científico: THYAGO MAIA TAVARES DE FARIAS

ANEXO B – PARECER CONSUBSTANCIADO DO CEP

**CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.**



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIS ARTIFICIAIS

Pesquisador: THYAGO MAIA TAVARES DE FARIAS

Área Temática:

Versão: 3

CAAE: 69729617.3.0000.5191

Instituição Proponente: CENTRO DE INFORMÁTICA

Patrocinador Principal: CIRCULO DO CORACAO DE PERNAMBUCO
Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 2.477.448

Apresentação do Projeto:

Tese de doutorado da UFPE, com projeto atualizado após avaliações e solicitações da CONEP e comissão de ética do CISAM-UPE. Ele contém as respostas necessárias além do orçamento, currículos atualizados e anuências. Trata-se de pesquisa na área da saúde e tecnologia de informação com recém-nascidos prematuros, com idade gestacional menor que 30 semanas e com peso de nascimento inferior a 1000g, para as fotografias a tampa da incubadora será levantada e o colchão em que o neonato reside e será retirado por um período de 1 minuto, para permitir a gravação da radiação infravermelha naturalmente emitida pelo corpo do neonato pela câmera infravermelha. Este passo é necessário uma vez que a radiação infravermelha não passa pelas paredes Plexiglas de uma incubadora e a pele do bebê precisa esfriar um pouco. Se a criança estiver sendo atendida em um aquecedor excedido, o aquecedor será desligado por um breve período (não mais de 1 minuto). Este passo é necessário porque o calor emitido pelo aquecedor pode interferir com a gravação da radiação infravermelha emitida pelo bebê. Todas as roupas, se houverem, serão removidas, exceto por roupas que cubram extremidades como a cabeça, as mãos ou os pés, uma vez que não afetarão a distribuição térmica sobre o abdômen. Várias imagens térmicas serão capturadas. Em seguida, o colchão será empurrado de volta para a incubadora e a tampa será fechada, ou o aquecedor excedido será religado. O breve período de tempo durante o

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar

Bairro: Encruzilhada

CEP: 52.030-010

UF: PE

Município: RECIFE

Telefone: (81)3182-7738

Fax: (81)3182-7738

E-mail: cep.cisam@upe.br

**CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.**



Continuação do Parecer: 2.477.448

qual o neonato estará fora da incubadora não excederá um minuto. Todas as capturas serão realizadas no Centro Integrado de Saúde Amaury de Medeiros da Universidade de Pernambuco (CISAM/UPE), em Recife-PE, e no Instituto Cândida Vargas, na cidade de João Pessoa-PB. É prevista a captura de 200 imagens térmicas de recém-nascidos a partir da referida câmera. Dessas, 100 imagens serão de neonatos normais e 100 imagens de recém-nascidos com a persistência do canal arterial. O conjunto smartphone/câmera térmica deverão estar a uma distância mínima de 1,40m do recém-nascido. O ambiente deverá estar a uma temperatura de 25°C a 27°C. Durante a captura, o recém-nascido não deverá estar usando fraudas. Os bebês também não devem ter se alimentado recentemente, para que a temperatura do abdômen não seja alterada. Não é possível realizar a captura de imagens térmicas de recém-nascidos em incubadoras, devido ao material acrílico utilizado não permitir o registro de emissividade por uma câmera térmica. Nesse caso, o recém-nascido deverá ser retirado da incubadora. O tempo limite de captura não deverá ultrapassar 10 segundos. É recomendado que as imagens sejam capturadas em momentos padrão para a saída de bebês das incubadoras, como durante sua pesagem, para não causar nenhum impacto aos neonatos. Para cada captura, serão registradas informações sobre o neonato em uma ficha de registro clínico, afim de nortear a definição dos valores de saída alvo da rede neural artificial.

Objetivo da Pesquisa:

Objetivo Geral

Desenvolver um sistema computacional preditivo para a caracterização da persistência do canal arterial em imagens térmicas de recém-nascidos a partir do uso de redes neurais artificiais.

1.2.2 Objetivos Específicos

São objetivos específicos do projeto:

Definir infraestrutura e protocolo para a captação de imagens térmicas de recém-nascidos;

Capturar imagens térmicas de neonatos saudáveis e com a persistência do canal arterial, afim de definir mapas de temperatura característicos para as duas classes;

Determinar e extrair vetores de características a serem correlacionadas com a persistência do canal arterial e com controles normais;

Aplicar uma arquitetura de rede neural artificial, definida especificamente para classificação de imagens térmicas de recém-nascidos com e sem a persistência

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar

Bairro: Encruzilhada

CEP: 52.030-010

UF: PE

Município: RECIFE

Telefone: (81)3182-7738

Fax: (81)3182-7738

E-mail: cep.cisam@upe.br

**CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.**



Continuação do Parecer: 2.477.448

do canal arterial;

Comparar as classificações realizadas pela rede neural artificial com avaliações clínicas, afim de validar a metodologia adotada.

Avaliação dos Riscos e Benefícios:

Avaliou e descreveu:

Riscos:

Não é possível realizar a captura de imagens térmicas de recém-nascidos em incubadoras, devido ao material acrílico utilizado não permitir o registro de emissividade por uma câmera térmica. Nesse caso, o recém-nascido deverá ser retirado da incubadora. A breve remoção do sujeito da incubadora pode aumentar o nível de estresse dos indivíduos. Logo, o tempo limite de captura não deverá ultrapassar 1 minuto. Uma vez que a sessão é muito curta, isso não afetará o sujeito mais do que procedimentos diários comuns. Profissionais de saúde neonatal estarão presentes em todos os momentos para garantir que os sinais vitais do sujeito estejam dentro de limites aceitáveis. É recomendado que as imagens sejam capturadas em momentos padrão para a saída de bebês das incubadoras, como durante sua pesagem, para não causar nenhum impacto aos neonatos. Não há riscos diretos de infecção para o responsável e para os voluntários, já que a câmera utilizada na captura das imagens térmicas não é invasiva, não depende de contato direto com a pele humana e não emprega radiação ionizante.

Benefícios:

Não há benefícios médicos imediatos para os recém-nascidos envolvidos neste estudo, pois este é um estudo investigativo para determinar o possível valor do uso de imagens térmicas no auxílio ao diagnóstico da PCA. No entanto, ser capaz de compreender melhor o mecanismo fisiológico associado à PCA poderá levar a um melhor gerenciamento da doença e reduzir as taxas de mortalidade no futuro. Se pudermos demonstrar que a termografia pode "ver" as alterações no fluxo sanguíneo dos neonatos provocados pela PCA, isso proporcionaria um meio objetivo de avaliar a PCA de forma não invasiva, algo atualmente não disponível e de grande impacto, potencial, nesta população. O meio de diagnóstico mais utilizado para a PCA é a ecocardiografia, sendo possível a realização de tomografia computadorizada e ecografia

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar

Bairro: Encruzilhada

CEP: 52.030-010

UF: PE

Município: RECIFE

Telefone: (81)3182-7738

Fax: (81)3182-7738

E-mail: cep.cisam@upe.br

CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.



Continuação do Parecer: 2.477.448

intravascular. A criação de um novo meio de diagnóstico para a PCA, baseado em processos de inteligência artificial, utilizado em conjunto com os demais meios tradicionais de diagnóstico, tornará a investigação ainda mais

Comentários e Considerações sobre a Pesquisa:

Pesquisa muito importante pois, descreveu que:

A caracterização clínica da persistência do canal arterial é difícil, mesmo na presença de um desvio ductal significativo. A termografia vem se tornando uma importante técnica no auxílio ao diagnóstico clínico, permitindo avaliar diversas doenças. Trata-se de uma modalidade de imagem que está sendo usada em muitas áreas médicas. Segundo pesquisadores, a PCA aumenta em até 30% o fluxo sanguíneo pulmonar, elevando a velocidade de fluxo da artéria pulmonar. Esse "roubo de fluxo" deixa áreas da circulação sistêmica com déficit. Evidências descritas na literatura sugerem que alterações no fluxo sanguíneo provocam o aumento de temperatura corporal localizada. Algumas pesquisas já evidenciaram a existência de simetria térmica em termogramas captados após a primeira hora de vida de 41 recém-nascidos saudáveis. Pesquisadores já observaram a ocorrência de assimetria térmica em termogramas de um recém-nascido com canal arterial persistente e insuficiência cardíaca congestiva (temperatura do tórax mais fria graças a diminuição do fluxo sanguíneo da artéria pulmonar devido a ligadura ductal), e em imagens térmicas de outro bebê com o rim direito moderadamente hipoplásico (temperatura do flanco esquerdo mais quente). A partir da termografia médica, é possível quantificar a temperatura da superfície do corpo, medindo a radiação infravermelha emitida pela pele humana. Logo, o uso de imagens térmicas viabilizaria a análise de alterações de fluxo sanguíneo a partir da classificação de regiões de calor. Porém, apesar de apresentar um grande potencial, o uso de termogramas na medicina ainda está envolto de ceticismo, devido a possíveis inconsistências na captação e na análise de tais imagens. Segundo pesquisadores, as inconsistências são em parte devido ao equipamento de aquisição de imagem utilizado e aos procedimentos de uso adotados, a dificuldade em processar e interpretar dados provenientes de imagens térmicas e, mais importante, devido à falta de protocolos padrão para orientar a revisão final. A avaliação dos termogramas foi frequentemente feita de forma manual e, portanto, afetada pela subjetividade humana. Com a computação e ferramentas de processamento de imagem disponíveis hoje, a análise das imagens poderia ser feita mais rápida e de forma mais precisa a partir de programas de computador especializados e do uso de redes neurais artificiais (RNAs). As RNAs já foram utilizadas com sucesso em problemas que envolviam o reconhecimento de padrões. Uma vez que

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar
Bairro: Encruzilhada **CEP:** 52.030-010
UF: PE **Município:** RECIFE
Telefone: (81)3182-7738 **Fax:** (81)3182-7738 **E-mail:** cep.cisam@upe.br

CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.



Continuação do Parecer: 2.477.448

uma rede neural é devidamente treinada, ela pode ser utilizada para gerar resultados consistentes para novos conjuntos de entradas de forma confiável e objetiva. Segundo pesquisadores, as redes neurais artificiais são amplamente reconhecidas como valiosas ferramentas de apoio à decisão clínica e, portanto, poderão ser úteis no escopo da proposta em questão. Frente à magnitude do problema e a falta de investigações envolvendo a análise preditiva da persistência do canal arterial em imagens térmicas de recém-nascidos a partir de técnicas de reconhecimento de padrões e aprendizagem de máquina, justifica-se um aprofundamento no conhecimento científico associado ao uso de imagens térmicas e redes neurais artificiais, proporcionando uma nova ferramenta que viabilizará uma análise não invasiva e sem contato da persistência do canal arterial em neonatos.

Considerações sobre os Termos de apresentação obrigatória:

Todos os documentos foram anexados adequadamente: FR, Anuências, confidencialidade, protocolo, orçamento, TCLE.

- "TCLE. Foi reformulado tendo como referência o capítulo IV da Resolução CNS 466/2012: em linguagem clara, acessível e conforme as normas gramaticais de português, descrevendo claramente a justificativa, os objetivos, os procedimentos, os desconfortos e riscos possíveis, os benefícios esperados, os métodos alternativos existentes, a forma de acompanhamento e assistência bem como seus responsáveis, a garantia de sigilo, as formas de ressarcimento de despesas decorrentes da participação na pesquisa, as formas de indenização diante de eventuais danos decorrentes da pesquisa. (RESPONDIDO ADEQUADAMENTE)

Recomendações:

Seguir o método proposto e lembrar de só fazer a imagem junto a equipe de saúde no momento do procedimento diário.

Conclusões ou Pendências e Lista de Inadequações:

Aprovado pois respondeu aos itens abaixo:

1-Área temática de "Equipamentos e dispositivos terapêuticos, novos ou não registrados no País", tendo em vista que todos os equipamentos e dispositivos terapêuticos utilizados no estudo já estão registrados no Brasil. (RESPONDIDO ADEQUADAMENTE)

2- Termos de apresentação obrigatória: 1. Na "folharosto.pdf", o campo Patrocinador Principal Já está preenchido, conforme Norma Operacional CNS 001/2013 item 3.3.a): "todos os campos devem ser preenchidos, datados e assinados, com identificação dos signatários".. (RESPONDIDO ADEQUADAMENTE)

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar
Bairro: Encruzilhada **CEP:** 52.030-010
UF: PE **Município:** RECIFE
Telefone: (81)3182-7738 **Fax:** (81)3182-7738 **E-mail:** cep.cisam@upe.br

**CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.**



Continuação do Parecer: 2.477.448

3-"Pesquisador Responsável" Projeto de pós-graduação de autoria do pesquisador "Thyago Maia Tavares de Farias" e de orientação do pesquisador "Manoel Eusebio de Linha". (RESPONDIDO ADEQUADAMENTE)

4- O pesquisador retificou e informa que não haverá retenção de amostras para armazenamento em banco na Plataforma Brasil. (RESPONDIDO ADEQUADAMENTE)

5-Na seção destinada à metodologia proposta, os centros de coleta já estão listados na lista de centros coparticipantes da pesquisa. (RESPONDIDO ADEQUADAMENTE)

6-Ressalta-se que foram apresentadas todas as anuências e a concordância de participação no estudo dos centros de pesquisa onde serão realizadas as coletadas de dados com os neonatos. (RESPONDIDO ADEQUADAMENTE)

7- O orçamento financeiro foi apresentado adequadamente detalhado. (Norma Operacional CNS nº 001 de 2013, item 3.3.e). (RESPONDIDO ADEQUADAMENTE)

8-O termo de assentimento é a "anuência do participante da pesquisa, criança, adolescente ou legalmente incapaz, livre de vícios (simulação, fraude ou erro), dependência, subordinação ou intimidação, estando de acordo foi anexado o TCLE . (RESPONDIDO ADEQUADAMENTE)

9- "TCLE. Foi reformulado tendo como referência o capítulo IV da Resolução CNS 466/2012: em linguagem clara, acessível e conforme as normas gramaticais de português, descrevendo claramente a justificativa, os objetivos, os procedimentos, os desconfortos e riscos possíveis, os benefícios esperados, os métodos alternativos existentes, a forma de acompanhamento e assistência bem como seus responsáveis, a garantia de sigilo, as formas de ressarcimento de despesas decorrentes da participação na pesquisa, as formas de indenização diante de eventuais danos decorrentes da pesquisa. (RESPONDIDO ADEQUADAMENTE)

10- Os protocolos de pesquisa contem demonstrativos da existência de INFRAESTRUTURA NECESSÁRIA E APTA AO DESENVOLVIMENTO DA PESQUISA.(RESPONDIDO ADEQUADAMENTE)

Considerações Finais a critério do CEP:

A comissão de ética considera o Projeto APROVADO após respostas, com adequações abaixo solicitadas:

1-Área temática de "Equipamentos e dispositivos terapêuticos, novos ou não registrados no País", tendo em vista que todos os equipamentos e dispositivos terapêuticos utilizados no estudo já estão registrados no Brasil. (RESPONDIDO ADEQUADAMENTE)

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar
Bairro: Encruzilhada **CEP:** 52.030-010
UF: PE **Município:** RECIFE
Telefone: (81)3182-7738 **Fax:** (81)3182-7738 **E-mail:** cep.cisam@upe.br

**CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.**



Continuação do Parecer: 2.477.448

2- Termos de apresentação obrigatória: 1. Na "folharosto.pdf", o campo Patrocinador Principal Já está preenchido, conforme Norma Operacional CNS 001/2013 item 3.3.a): "todos os campos devem ser preenchidos, datados e assinados, com identificação dos signatários".. (RESPONDIDO ADEQUADAMENTE)

3-"Pesquisador Responsável" Projeto de pós-graduação de autoria do pesquisador "Thyago Maia Tavares de Farias" e de orientação do pesquisador "Manoel Eusebio de Linha". (RESPONDIDO ADEQUADAMENTE)

4- O pesquisador retificou e informa que não haverá retenção de amostras para armazenamento em banco na Plataforma Brasil. (RESPONDIDO ADEQUADAMENTE)

5-Na seção destinada à metodologia proposta, os centros de coleta já estão listados na lista de centros coparticipantes da pesquisa. (RESPONDIDO ADEQUADAMENTE)

6-Ressalta-se que foram apresentadas todas as anuências e a concordância de participação no estudo dos centros de pesquisa onde serão realizadas as coletadas de dados com os neonatos. (RESPONDIDO ADEQUADAMENTE)

7- O orçamento financeiro foi apresentado adequadamente detalhado. (Norma Operacional CNS nº 001 de 2013, item 3.3.e). (RESPONDIDO ADEQUADAMENTE)

8-O termo de assentimento é a "anuência do participante da pesquisa, criança, adolescente ou legalmente incapaz, livre de vícios (simulação, fraude ou erro), dependência, subordinação ou intimidação, estando de acordo foi anexado o TCLE . (RESPONDIDO ADEQUADAMENTE)

9- "TCLE. Foi reformulado tendo como referência o capítulo IV da Resolução CNS 466/2012: em linguagem clara, acessível e conforme as normas gramaticais de português, descrevendo claramente a justificativa, os objetivos, os procedimentos, os desconfortos e riscos possíveis, os benefícios esperados, os métodos alternativos existentes, a forma de acompanhamento e assistência bem como seus responsáveis, a garantia de sigilo, as formas de ressarcimento de despesas decorrentes da participação na pesquisa, as formas de indenização diante de eventuais danos decorrentes da pesquisa. (RESPONDIDO ADEQUADAMENTE)

10- Os protocolos de pesquisa contem demonstrativos da existência de INFRAESTRUTURA NECESSÁRIA E APTA AO DESENVOLVIMENTO DA PESQUISA.(RESPONDIDO ADEQUADAMENTE)

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar

Bairro: Encruzilhada

CEP: 52.030-010

UF: PE

Município: RECIFE

Telefone: (81)3182-7738

Fax: (81)3182-7738

E-mail: cep.cisam@upe.br

**CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.**



Continuação do Parecer: 2.477.448

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Projeto Detalhado / Brochura Investigador	Brochurainvestigador.pdf	10/01/2018 18:49:29	Sandra Trindade Low	Aceito
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_P ROJETO_885143.pdf	26/12/2017 16:10:23		Aceito
Folha de Rosto	folharostoAtualizada.pdf	26/12/2017 16:04:20	THYAGO MAIA TAVARES DE	Aceito
Projeto Detalhado / Brochura Investigador	BrochuraPesquisador.pdf	20/12/2017 22:24:59	THYAGO MAIA TAVARES DE FARIAS	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_CORRIGIDO.docx	20/12/2017 19:36:39	THYAGO MAIA TAVARES DE FARIAS	Aceito
Outros	carta_anuencia_ICV.pdf	20/12/2017 19:30:42	THYAGO MAIA TAVARES DE	Aceito
Declaração de concordância	concordancia.pdf	20/12/2017 10:46:24	Sandra Trindade Low	Aceito
Solicitação Assinada pelo Pesquisador Responsável	solicitacao.pdf	11/09/2017 12:56:39	Sandra da Silva Mattos	Aceito
Outros	CARTA_ANUENCIA_CIRCOR.PDF	08/09/2017 10:57:06	THYAGO MAIA TAVARES DE	Aceito
Outros	Aspectos_Eticos_Pesquisa.pdf	10/07/2017 11:09:01	THYAGO MAIA TAVARES DE	Aceito
Outros	carta_anuencia_cisam.pdf	14/06/2017 08:51:06	THYAGO MAIA TAVARES DE	Aceito
Outros	termo_confidencialidade.PNG	24/05/2017 10:13:19	THYAGO MAIA TAVARES DE	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar

Bairro: Encruzilhada

CEP: 52.030-010

UF: PE

Município: RECIFE

Telefone: (81)3182-7738

Fax: (81)3182-7738

E-mail: cep.cisam@upe.br

CENTRO INTEGRADO DE
SAÚDE AMAURY DE
MEDEIROS - CISAM/UPE.



Continuação do Parecer: 2.477.448

RECIFE, 29 de Janeiro de 2018

Assinado por:
Sandra Trindade Low
(Coordenador)

Endereço: Rua Visconde de Mamaguape, s/nº 1º andar

Bairro: Encruzilhada

CEP: 52.030-010

UF: PE

Município: RECIFE

Telefone: (81)3182-7738

Fax: (81)3182-7738

E-mail: cep.cisam@upe.br

ANEXO C – CARTA DE ANUÊNCIA - CIRCOR



CIRCOR
RCP
REDE DE CARDIOLOGIA PEDIÁTRICA
PERNAMBUCO - PARAÍBA

CARTA DE ANUÊNCIA PARA AUTORIZAÇÃO DE PESQUISA

Autorizamos institucionalmente a realização da pesquisa intitulada **“CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIAS ARTIFICIAIS”**, a ser realizado sob a orientação da **Profa. Dra. Sandra da Silva Mattos**, médica cardiologista pediátrica, CRM 6734 do Círculo do Coração de Pernambuco (CirCor), dentro do escopo da Rede de Cardiologia Pediátrica Pernambuco-Paraíba, sendo a coleta dos dados realizada em Maternidades da Rede Pública dos Estados supracitados, parceiras do Círculo do Coração, desde que expressamente obtida a anuência das direções destes Centros participantes dentro das normas estabelecidas por cada Centro e das normas gerais da Comissão Nacional de Ética em Pesquisa - CONEP. Ao mesmo tempo, autorizamos que o nome desta instituição possa constar no relatório final bem como em futuras publicações na forma de artigo científico.

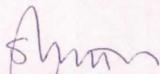
Ressaltamos que os dados coletados deverão ser mantidos em absoluto sigilo de acordo com a Resolução do Conselho Nacional de Saúde (CNS/MS) 466/12 que trata da Pesquisa envolvendo Seres Humanos. Salientamos ainda, que tais dados devem ser utilizados tão somente para realização deste estudo.

A pesquisa do deverá ser realizada em Instituições parceiras do Círculo do Coração, após a aprovação do projeto por um comitê de ética em pesquisa com seres humanos reconhecidos pela CONEP/CNS/MS, comprovada mediante a apresentação do parecer aprovado.

Ressaltamos que os dados coletados deverão ser mantidos em absoluto sigilo de acordo com a resolução do Conselho Nacional de Saúde (CNS/MS) 466/12 que trata da Pesquisa envolvendo Seres Humanos. Salientamos ainda, que tais dados devem ser utilizados tão somente para a realização deste estudo.

Recife, 08 de setembro de 2017.


Dr. Felipe Alves Mourato
Diretor-Científico - CirCor
CRM: 20843 - PE


Prof. Dra. Sandra da Silva Mattos
Diretora-Presidente - CirCor
CRM: 6734 - PE

ANEXO D – CARTA DE ANUÊNCIA - ICV



PREFEITURA MUNICIPAL DE JOÃO PESSOA
INSTITUTO CÂNDIDA VARGAS



CARTA DE ANUÊNCIA PARA AUTORIZAÇÃO DE PESQUISA

Autorizamos institucionalmente a realização da pesquisa intitulada “CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIS ARTIFICIAIS”, a ser realizado no INSTITUTO CÂNDIDA VARGAS, por THYAGO MAIA TAVARES DE FARIAS, no setor UTI Neonatal, sob orientação do PROF(a). MANOEL EUSEBIO DE LIMA, cujo objetivo é: desenvolver um sistema computacional preditivo para a caracterização da persistência do canal arterial em imagens térmicas de recém-nascidos a partir do uso de uma rede neural artificial (RNA), necessitando, portanto, ter acesso aos dados a serem colhidos na instituição. Ao mesmo tempo, autorizamos que o nome desta instituição possa constar no relatório final bem como em futuras publicações na forma de artigo científico.

Ressaltamos que os dados coletados deverão ser mantidos em absoluto sigilo de acordo com a Resolução do Conselho Nacional de Saúde (CNS/MS) 466/12 que trata da Pesquisa envolvendo Seres Humanos. Salientamos ainda, que tais dados devem ser utilizados tão somente para realização deste estudo.

A pesquisa deverá ser realizada nesta instituição após a aprovação do projeto por um comitê de ética em pesquisa com seres humanos reconhecidos pela CONEP/CNS/MS, comprovada mediante a apresentação do parecer aprovado.

Ressaltamos que os dados coletados deverão ser mantidos em absoluto sigilo de acordo com a resolução do Conselho Nacional de Saúde (CNS/MS) 466/12 que trata da Pesquisa envolvendo Seres Humanos. Salientamos ainda, que tais dados devem ser utilizados tão somente para a realização deste estudo.

INSTITUTO CÂNDIDA VARGAS
PREFEITURA MUNICIPAL DE JOÃO PESSOA
JULIANA SOARES
Coordenação de Neonatologia
CRM: 5872

João Pessoa, 25 de outubro 2017

Coordenação de Neonatologia

Coordenação do Centro de Estudos ICV

ANEXO E – CARTA DE ANUÊNCIA - CISAM



CARTA DE ANUÊNCIA PARA AUTORIZAÇÃO DE PESQUISA

Autorizamos institucionalmente a realização da pesquisa intitulada "CARACTERIZAÇÃO DA PERSISTÊNCIA DO CANAL ARTERIAL EM IMAGENS TÉRMICAS DE RECÉM-NASCIDOS A PARTIR DO USO DE REDES NEURAIS ARTIFICIAIS", a ser realizado no CENTRO INTEGRADO DE SAÚDE AMAURY DE MEDEIROS CISAM/ UPE, por THYAGO MAIA TAVARES DE FARIAS, no setor _____, sob orientação do PROF(a). MANOEL EUSEBIO DE LIMA, cujo objetivo é: desenvolver um sistema computacional preditivo para a caracterização da persistência do canal arterial em imagens térmicas de recém-nascidos a partir do uso de uma rede neural artificial (RNA), necessitando, portanto, ter acesso aos dados a serem colhidos na instituição. Ao mesmo tempo, autorizamos que o nome desta instituição possa constar no relatório final bem como em futuras publicações na forma de artigo científico.

Ressaltamos que os dados coletados deverão ser mantidos em absoluto sigilo de acordo com a Resolução do Conselho Nacional de Saúde (CNS/MS) 466/12 que trata da Pesquisa envolvendo Seres Humanos. Salientamos ainda, que tais dados devem ser utilizados tão somente para realização deste estudo.

A pesquisa deverá ser realizada nesta instituição após a aprovação do projeto por um comitê de ética em pesquisa com seres humanos reconhecidos pela CONEP/CNS/MS, comprovada mediante a apresentação do parecer aprovado.

Ressaltamos que os dados coletados deverão ser mantidos em absoluto sigilo de acordo com a resolução do Conselho Nacional de Saúde (CNS/MS) 466/12 que trata da Pesquisa envolvendo Seres Humanos. Salientamos ainda, que tais dados devem ser utilizados tão somente para a realização deste estudo.

Recife, 06 de Junh, de 17.

Eliane Cavalcanti dos Santos

GERENTE DO SETOR
NOME COMPLETO E CARIMBO

Eliane Cavalcanti dos Santos
Gerência Médica da Neonatologia
CISAM/UPE
UPE CRM: 6373/ Mat. 65455

UBATA

DIRETOR EXECUTIVO
NOME COMPLETO E CARIMBO

CISAM-PE
Prof. Olímpio Barbosa de Moraes Filho
Gestor Executivo
CRM-PE 8539 - Mat. 7025-4

Rua Visconde de Mamanguape s/n – Encruzilhada
Estado: Pernambuco Cidade: Recife
CEP: 52030010
E.mail cep.cisam@upe.br
Fone: 3182-7738