

UNIVERSIDADE FEDERAL DO PAMPA

DHYONATAN SANTOS DE FREITAS

**DIAGNÓSTICO AUTOMÁTICO DE
CERATOCONJUNTIVITE INFECCIOSA
BOVINA POR MEIO DE IMAGENS
TERMOGRÁFICAS E REDES NEURAIS
CONVOLUCIONAIS**

**Bagé
2019**

DHYONATAN SANTOS DE FREITAS

**DIAGNÓSTICO AUTOMÁTICO DE
CERATOCONJUNTIVITE INFECCIOSA
BOVINA POR MEIO DE IMAGENS
TERMOGRÁFICAS E REDES NEURAIS
CONVOLUCIONAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada como requisito parcial para a obtenção do título de Mestre em Computação Aplicada.

Orientador: Sandro da Silva Camargo
Coorientador: Fernando Flores Cardoso

**Bagé
2019**

Ficha catalográfica elaborada automaticamente com os dados fornecidos
pelo(a) autor(a) através do Módulo de Biblioteca do
Sistema GURI (Gestão Unificada de Recursos Institucionais) .

F866d Freitas, Dhyonatan Santos de
Diagnóstico automático de Ceratoconjuntivite Infecciosa
Bovina por meio de Imagens Termográficas e Redes Neurais
Convolucionais / Dhyonatan Santos de Freitas.
89 p.

Dissertação(Mestrado)-- Universidade Federal do Pampa,
MESTRADO EM COMPUTAÇÃO APLICADA, 2019.

"Orientação: Sandro da Silva Camargo".

1. Diagnóstico por imagem. 2. Inteligência artificial. 3.
Deep learning. 4. Doença ocular. 5. Reconhecimento de padrões.
I. Título.

DHYONATAN SANTOS DE FREITAS

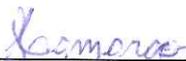
**DIAGNÓSTICO AUTOMÁTICO DE
CERATOCONJUNTIVITE INFECCIOSA
BOVINA POR MEIO DE IMAGENS
TERMOGRÁFICAS E REDES NEURAIAS
CONVOLUCIONAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada como requisito parcial para a obtenção do título de Mestre em Computação Aplicada.

Área de concentração: Tecnologias para a Produção Agropecuária

Dissertação defendida e aprovada em: 20 de dezembro de 2019.

Banca examinadora:



Prof. Dr. Sandro da Silva Camargo
Orientador



Prof.ª Dr.ª Ana Paula Lüdtke Ferreira
Universidade Federal do Pampa



Dr.ª Emanuelle Baldo Gaspar
Embrapa Pecuária Sul



Prof. Dr. Felipe Pivetta Carpes
Universidade Federal do Pampa

AGRADECIMENTO

Agradeço ao Prof. Dr. Sandro da Silva Camargo, pela orientação, ensinamentos e estímulos durante o desenvolvimento desta pesquisa.

Ao Prof. Dr. Fernando Flores Cardoso, pela co-orientação, ensinamentos e generosidade em compartilhar conhecimentos.

À M^a. Helena Brocardo Comin, ao Dr. Robert Domingues e a Dr^a. Emanuelle Baldo Gaspar, pela disponibilização das imagens termográficas, esclarecimentos e auxílio na condução deste trabalho.

Ao Programa de Pós-Graduação em Computação Aplicada e à Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA Pecuária Sul.

À Banca examinadora pela predisposição e o tempo dedicado na avaliação deste trabalho.

Por fim, agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior e a Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul pela bolsa de mestrado.

RESUMO

A Ceratoconjuntivite Infecciosa Bovina (CIB) é considerada a doença ocular de maior importância na criação de bovinos, causando perdas no rebanho e prejuízos ao produtor. Por se tratar de uma doença infectocontagiosa é necessário que as formas de diagnóstico sejam aprimoradas. Atualmente, o diagnóstico para CIB é realizado por meio da avaliação dos sinais clínicos por um especialista e confirmados por exames laboratoriais, o que geralmente é uma tarefa custosa. Neste trabalho, é avaliada a utilização da termografia infravermelha para aquisição de imagens da região ocular bovina de animais saudáveis e experimentalmente infectados pela CIB. A base de imagens disponível foi previamente classificada por um especialista e, posteriormente, utilizada no processo de treinamento e validação de um conjunto de arquiteturas distintas de redes neurais convolucionais (RNC), as quais foram avaliadas utilizando validação cruzada. Os melhores resultados indicam que as RNC são capazes de identificar os sinais clínicos da CIB em imagens termográficas com acurácia próxima a 94%.

Palavras-chave: Diagnóstico por imagem. Inteligência artificial. Deep learning. Doença ocular. Reconhecimento de padrões.

ABSTRACT

Infectious bovine keratoconjunctivitis (IBK) is considered the most important ocular disease in cattle breeding, causing losses in the herd and damage to the producer. Because of being an infectious disease it is necessary to improve diagnostic forms. Currently, the diagnosis for IBK is made by evaluating clinical signs by a specialist and confirmed by laboratory tests, which is usually a costly task. In this work, the use of infrared thermography is evaluated for the acquisition of images of the bovine ocular region of healthy and experimentally infected animals by IBK. The available image base was previously classified by a specialist and subsequently used in the training and validation process of a set of distinct architectures of convolutional neural networks (CNN), which were evaluated using cross-validation. The best results indicate that CNN are able to identify clinical signs in thermographic images with accuracy close to 94%.

Keywords: Image diagnostics. Artificial intelligence. Deep learning. Ocular disease. Pattern recognition.

LISTA DE FIGURAS

Figura 1	Neurônio biológico.	24
Figura 2	Neurônio artificial.....	25
Figura 3	Exemplos gráficos de diferentes tipos de funções de ativação para processar as informações em neurônios artificiais.....	25
Figura 4	Arquitetura de uma RNA do tipo MLP.....	26
Figura 5	Arquitetura de uma rede neural convolucional.....	29
Figura 6	Processo de convolução utilizado em RNC.....	30
Figura 7	Conectividade global e esparsa das redes MLP e RNC.....	31
Figura 8	Exemplo do campo receptivo local das RNC.....	31
Figura 9	Exemplo de uma operação de <i>pooling</i>	33
Figura 10	Problema de <i>overfitting</i> durante o treinamento de uma RNC.....	34
Figura 11	Resultado do uso de técnicas de regularização durante o treinamento de uma RNC.....	35
Figura 12	Estrutura de uma camada totalmente conectada de uma RNC.....	36
Figura 13	Exemplo de um <i>ensemble</i>	38
Figura 14	Evolução dos sinais clínicos em um bezerro afetado pela CIB.....	41
Figura 15	Escores para identificação da CIB.....	42
Figura 16	Registro termográfico de um bezerro.....	44
Figura 17	Fluxograma das fases da pesquisa.....	53
Figura 18	Imagem térmica da região ocular bovina.....	55
Figura 19	Exemplo de planilha com as informações das avaliações realizadas pelos especialistas.....	56
Figura 20	Imagem termográfica com análise de temperatura e imagem termográfica com a análise removida.....	59
Figura 21	Processo de aumento de dados a partir de uma imagem utilizando a biblioteca Keras.....	60
Figura 22	Fluxograma do processo de desenvolvimento e validação de um modelo de RNC.....	60
Figura 23	Arquitetura dos modelos de RNC desenvolvidas para o primeiro experimento.....	62
Figura 24	Resultados da etapa de treinamento dos modelos de RNC do primeiro experimento.....	64
Figura 25	Arquitetura dos modelos de RNC desenvolvidos para o segundo experimento.....	67
Figura 26	Resultados da etapa de treinamento dos modelos de RNC do segundo experimento.....	68
Figura 27	Comparativo da performance dos modelos de RNC durante a etapa de treinamento entre os experimentos realizados.....	74

LISTA DE TABELAS

Tabela 1	Matriz de confusão de uma hipótese.	22
Tabela 2	Resultados encontrados durante o primeiro levantamento bibliográfico.....	47
Tabela 3	Resultados encontrados durante o segundo levantamento bibliográfico	48
Tabela 4	Classificação dos escores de acordo com o sinal clínico apresentado pelo animal no momento da avaliação.....	56
Tabela 5	Base de dados do primeiro experimento gerada após o processo de aumento de dados.....	62
Tabela 6	Resultados obtidos pelos modelos de RNC na etapa de validação do primeiro experimento.....	65
Tabela 7	Base de imagens do segundo experimento gerada a partir do processo de aumento de dados.....	66
Tabela 8	Resultados obtidos pelos modelos de RNC na etapa de validação do segundo experimento.	69
Tabela 9	Combinação dos modelos utilizando a técnica ensemble.....	70
Tabela 10	Resultados obtidos pelos ensembles.....	72

LISTA DE ABREVIATURAS E SIGLAS

API	<i>Application Programming Interface</i>
CIB	Ceratoconjuntivite Infecciosa Bovina
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
IA	Inteligência Artificial
MLP	<i>Multilayer Perceptron</i>
PIB	Produto Interno Bruto
RNA	Rede Neural Artificial
RNC	Rede Neural Convolucional
TIC	Tecnologias da Informação e da Comunicação
TIV	Termografia Infravermelha

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Justificativa	13
1.2 Objetivos	13
1.3 Organização do trabalho	14
2 REVISÃO DA BIBLIOGRAFIA	15
2.1 Agropecuária de Precisão.....	15
2.2 Inteligência Artificial	16
2.2.1 Aprendizado de Máquina.....	17
2.2.2 Classificação.....	19
2.2.2.1 Avaliação da aprendizagem.....	20
2.2.3 Redes Neurais Artificiais	23
2.2.3.1 Redes Neurais Convolucionais.....	28
2.2.4 Combinação de classificadores.....	38
2.3 Ceratoconjuntivite Infecciosa Bovina	39
2.4 Diagnóstico por Imagem.....	43
2.4.1 Termografia Infravermelha.....	43
2.5 Trabalhos Relacionados.....	46
3 METODOLOGIA	51
3.1 Caracterização da Pesquisa	51
3.2 Fases da Pesquisa	52
3.3 Material.....	55
3.3.1 Base de imagens.....	55
3.3.2 Ferramentas.....	57
4 ABORDAGEM PROPOSTA	58
4.1 Implementação	58
4.1.1 Pré-processamento dos dados	58
4.1.2 Desenvolvimento dos modelos de Redes Neurais Convolucionais	60
4.2 Experimentos.....	61
4.3 Discussão dos resultados.....	73
5 CONCLUSÕES	77
5.1 Contribuições.....	78
5.2 Trabalhos futuros	78
REFERÊNCIAS	79

1 INTRODUÇÃO

A criação de bovinos é uma das principais atividades do agronegócio nacional e está inserida no mercado internacional da carne como importante setor competitivo. Em 2018, a atividade agropecuária no Brasil representou cerca de 5,5% do PIB (Produto Interno Bruto) brasileiro e teve participação considerável na geração de empregos (CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA, 2018).

Apesar da posição favorável no mercado, melhorias nos aspectos gerenciais, zootécnicos e econômicos se fazem necessários para garantir a competitividade nos mercados internacionais e permanência como empreendimento economicamente atraente para os produtores nacionais (EUCLIDES FILHO; EUCLIDES, 2010). Do ponto de vista dos processos zootécnicos, principalmente aqueles que garantem o bem-estar animal e a qualidade sanitária, percebe-se um grande esforço para integrar novas tecnologias que possam colaborar ao incremento da produtividade e redução de custos nas fazendas. Nesse sentido, faz-se presente a necessidade do desenvolvimento de ferramentas que auxiliem no diagnóstico precoce, bem como na prevenção de novos casos de doenças, dentre elas, a ceratoconjuntivite infecciosa bovina (CIB).

A CIB é a doença ocular com maior incidência em rebanhos bovinos do mundo todo, causando prejuízos significativos aos animais e, conseqüentemente, aos produtores (BAPTISTA, 1979; SLATTER *et al.*, 1982; MCCONNEL; SHUM; HOUSE, 2007). Com o avanço da infecção, os indivíduos têm a visão comprometida, e isso acarreta em diminuição do ganho de peso, redução da produção de leite, custos elevados com o tratamento e desvalorização de mercado devido a desfiguração física do olho afetado (POSTMA; CARFAGNINI; MINATEL, 2008).

A bactéria gram-negativa *Moraxella bovis* é um dos principais agentes etiológicos da CIB (FAGLIN *et al.*, 2016). A transmissão desta bactéria ocorre por meio de contato direto, secreções respiratórias ou conjuntivas do animal infectado e também via insetos vetores (KOPECKY; PUGH; MCDONALD, 1986), podendo levar rapidamente a disseminação da infecção entre todo o rebanho, caso nenhuma atividade preventiva seja iniciada. Além disso, bovinos de todas as raças e idades podem ser infectados pela CIB, mas a maioria dos casos ocorre em animais jovens (com 2 a 12 meses de idade) e da raça Hereford ou gado de cruzamento Hereford (ANGELOS, 2015).

Os estágios iniciais da CIB são caracterizados por lacrimejamento excessivo e fotofobia com blefarospasmo. Posteriormente, exsudatos conjuntivais e opacidade

corneana podem ocorrer, progredindo para ulceração e edema da córnea (ALEXANDER, 2010). Embora a ulceração da córnea possa curar-se de forma natural, sem intervenção terapêutica, em casos mais graves, a ruptura da córnea resulta em perda completa e permanente da visão, causando desconforto acentuado nos animais (SCHNEE *et al.*, 2015). Assim, tratando-se de uma doença infectocontagiosa, percebe-se que é essencial para a saúde do rebanho que os primeiros animais que apresentem sinais clínicos da CIB sejam diagnosticados de forma precoce, ou seja, na fase inicial da doença.

O diagnóstico inicial da CIB é clínico. Já o diagnóstico confirmatório pode ser realizado por meio de cultura de cepa hemolítica, isolada a partir da secreção do olho afetado ou das narinas. Adicionalmente, teste de sensibilidade a antibióticos, podem auxiliar na escolha terapêutica. Diversos trabalhos na literatura têm utilizado o diagnóstico clínico para identificação de surtos de CIB (COSTA *et al.*, 2008; CARMO *et al.*, 2011; COMIN *et al.*, 2016). No entanto, esse método não é o mais eficiente, pois depende da subjetividade e experiência do especialista para um diagnóstico mais acurado. Além disso, em determinadas regiões não há disponibilidade imediata de um especialista, o que acarreta em atraso do tratamento e a possibilidade da infecção se alastrar no rebanho.

Tecnologias inovadoras e biotecnologias contribuem significativamente para o avanço em pesquisa animal, atuando principalmente na identificação de doenças e promovendo seu bem-estar. Métodos não destrutivos nem invasivos podem ser úteis para obtenção de dados confiáveis sem interferir diretamente com os animais, evitando reações de estresse. Segundo Rekant *et al.* (2016), frente a doenças inflamatórias, a termografia infravermelha torna-se um método adequado para coleta de dados, possibilitando detectar alterações locais e sistêmicas de temperatura, expressas na superfície da pele, com a vantagem, em muitos casos, de identificá-las ainda no início da doença, mesmo antes do aparecimento dos primeiros sinais clínicos. No entanto, a interpretação dos dados contidos em uma imagem termográfica é uma tarefa complexa, exigindo do especialista conhecimento anatômico do animal examinado e experiência nesse tipo análise, pois a imagem analisada pode conter áreas com variação de temperatura determinantes para o diagnóstico da doença, que são difíceis de detectar a olho nu.

Nesse sentido, percebe-se crescente interesse no emprego de técnicas de aprendizado de máquina (do inglês, *machine learning*), para a construção de ferramentas que auxiliem na avaliação clínica. Segundo Cihan *et al.* (2017), na medicina, especialmente no diagnóstico de doenças assistidas por computador e exploração de

fatores de risco e suas relações com doenças, resultados promissores foram alcançados utilizando essas técnicas. Em relação à medicina veterinária, técnicas de aprendizado de máquina podem fornecer novas fronteiras para resolver problemas que são conhecidos por serem persistentes no campo (CIHAN *et al.*, 2017). Dentre as subáreas do aprendizado de máquina, entre as mais promissoras, certamente está o aprendizado profundo (do inglês, *deep learning*), que, segundo LeCun, Bengio e Hinton (2015), está fazendo grandes avanços na resolução de problemas que resistiram por anos aos melhores esforços empreendidos pela comunidade científica.

1.1 Justificativa

Sendo a CIB uma doença infectocontagiosa, o tempo de reação contra o surto é determinante para o controle da infecção e atenuação dos prejuízos ao produtor, porém a disponibilidade de um profissional especializado para realizar o diagnóstico muitas vezes é uma dificuldade enfrentada por produtores de determinadas regiões. Carmo *et al.* (2011) relatam que muitas vezes, por falta de experiência ou desconhecimento dos sinais clínicos da CIB, produtores procuram por um especialista quando parte do rebanho já está contaminado, tornando o tratamento mais longo e custoso.

Por isso, o desenvolvimento de uma ferramenta computacional que, utilizando a termografia infravermelha como método de obtenção de dados, seja capaz de auxiliar no diagnóstico preliminar da CIB de forma automática é desejável. Desta forma, por meio desta solução é possível identificar, de forma ágil, os sintomas da CIB, podendo atenuar o tempo de reação clínica e tornar o tratamento mais efetivo, além de minimizar os custos para o produtor.

1.2 Objetivos

I. Objetivo geral

Desenvolver um método computacional capaz de identificar sintomas da CIB em imagens termográficas da região ocular bovina utilizando redes neurais convolucionais é o principal objetivo deste trabalho.

II. Objetivos específicos

Os objetivos específicos deste trabalho são:

1. Construir arquiteturas distintas de redes neurais convolucionais para a interpretação das imagens termográficas;
2. Treinar e validar esses modelos junto a base de dados disponível;
3. Avaliar o desempenho dos modelos em classificar corretamente novas amostras.

1.3 Organização do trabalho

O restante deste trabalho está estruturado da seguinte forma: no capítulo 2 é apresentada uma revisão bibliográfica sobre os conceitos utilizados nesta pesquisa; no capítulo 3 é discutido a caracterização e as fases desta pesquisa; no capítulo 4 é apresentada a abordagem proposta para o desenvolvimento deste trabalho, os testes realizados e a discussão dos resultados; e por fim, no capítulo 5 são apresentadas as considerações sobre o trabalho desenvolvido, as principais contribuições e uma perspectiva de trabalhos futuros.

2 REVISÃO DA BIBLIOGRAFIA

Este capítulo tem como objetivo apresentar uma revisão teórica sobre os conceitos utilizados neste trabalho, colaborando para uma melhor compreensão do conteúdo técnico. Na seção 2.1 é descrita a importância da agropecuária de precisão para monitoramento individualizado dos animais e diagnóstico precoce de enfermidades. Na seção 2.2 são apresentados os conceitos que envolvem os modelos de inteligência artificial. Na seção 2.3 são descritos os principais conceitos sobre a CIB e o seu impacto na produtividade e bem-estar animal. Na seção 2.4 é apresentada a importância do diagnóstico por imagem como forma de obtenção de dados. Por fim, na seção 2.5 são discutidos os trabalhos relacionados.

2.1 Agropecuária de Precisão

Agropecuária de precisão é o termo utilizado para definir o modelo atual de gestão sobre os processos produtivos que ocorrem nas fazendas (MOLIN; AMARAL; COLAÇO, 2015). Esse conceito engloba o uso de novas tecnologias, equipamentos modernos e postura gerencial do produtor frente as suas tomadas de decisões, as quais podem se tornar mais assertivas, conduzindo ao incremento da produtividade do estabelecimento rural.

No contexto dos sistemas de produção e gerenciamento de produção animal, a precisão consiste na observação de diferentes parâmetros dos animais e também das condições ambientais, que pode ser realizada de forma automatizada por meio do uso de tecnologias da informação e da comunicação (TIC). TIC consiste em um conjunto de recursos tecnológicos utilizados de forma integrada para atingir um objetivo comum (MOLIN; AMARAL; COLAÇO, 2015). O desenvolvimento de novos hardwares e softwares voltados ao agronegócio tem evoluído nos últimos anos, o que acaba contribuindo para o controle operacional nas fazendas. Como um exemplo disso podemos citar o monitoramento individualizado dos animais.

Segundo Bambini *et al.* (2013), no monitoramento individualizado dos animais, observa-se informações específicas de cada indivíduo de modo que traduza a sua situação atual dentro do planejamento desenvolvido pelo produtor. Este processo pode ser de forma automatizada ou manual. Assim, é possível observar fatores determinantes que podem auxiliar o produtor nas suas tomadas de decisões, como o controle gerencial sobre cada

indivíduo, acompanhamento da produtividade, comparações com o restante do rebanho e o mais importante, identificar fatores que ajudam no diagnóstico precoce de enfermidades.

Doenças que afetam diretamente o rebanho são os fatores que têm maior impacto produtivo e, conseqüentemente, econômico para uma propriedade rural. Sua manifestação interrompe o desenvolvimento produtivo do animal, além de ter como consequência elevados custos com o tratamento. Neste contexto, observa-se que a agropecuária de precisão tem como objetivo auxiliar na identificação desses problemas por meio do monitoramento individualizado dos animais utilizando novas tecnologias, contribuindo para o tempo de recuperação e a saúde dos animais, minimizando custos para a propriedade rural.

2.2 Inteligência Artificial

Em problemas de agropecuária de precisão, uma abordagem que tem sido cada vez mais utilizada é a inteligência artificial (IA), com o objetivo de desenvolver novas tecnologias capazes de reconhecer padrões sobre os dados.

A IA pode ser definida como um ramo da ciência da computação que tem como objetivo estudar e criar sistemas que possam manifestar um comportamento inteligente capaz de realizar tarefas complexas com um nível de competência que é equivalente ou superior ao de um especialista humano (LUGER, 2004).

Segundo Haykin (2001) um sistema ou máquina embarcado com inteligência artificial tem como objetivo principal realizar três tarefas: i) armazenar conhecimento; ii) aplicar o conhecimento armazenado para resolver problemas; e iii) adquirir novo conhecimento por meio da experiência.

Além de ser capaz de realizar as tarefas citadas, um sistema embarcado com IA deve possuir três componentes fundamentais: a representação, utilizada para representar o conhecimento genérico sobre um domínio do problema que se deseja resolver; o raciocínio, que é a habilidade de resolver este problema; e a aprendizagem, que é um processo de mudança de comportamento obtido por meio da experiência construída por fatores emocionais, neurológicos, relacionais e ambientais (SAGE, 1990).

Como pode-se perceber, um sistema baseado em IA necessita de um aprendizado prévio antes de realizar as tarefas incumbidas a ela. Para isso, existe uma subárea da IA chamada aprendizado de máquina, a qual será detalhada a seguir.

2.2.1 Aprendizado de Máquina

O aprendizado de máquina tem como finalidade desenvolver técnicas para adquirir conhecimento de forma automática em um sistema baseado em IA. O desenvolvimento de tais técnicas tem como objetivo aprender e realizar tarefas que sejam comparáveis, ou até mesmo superiores, a de um especialista na área em questão (PESSIN, 2013).

O aprendizado de máquina pode ser visto também como o processo de mudança de estrutura, baseado em entradas ou em respostas a informações externas, de maneira que o desempenho futuro de um algoritmo em alguma tarefa melhore (NILSSON, 1996). Segundo Mitchell (1999), para se dizer que uma máquina aprende ela deve, a partir de uma experiência E , com respeito a uma classe de tarefas T e medida de performance P , melhorar sua performance na tarefa T , medida por P , com essa experiência E .

Os métodos de aprendizado de máquina indutivos são classificados em três tipos: i) aprendizado supervisionado, no qual um conjunto de dados rotulados é fornecido ao algoritmo para que ele aprenda como esses rótulos foram atribuídos aos dados e, a partir disso, use esse conhecimento para classificar novos dados; ii) aprendizado não supervisionado, no qual não são fornecidos rótulos para o conjunto de dados, portanto o que se deseja é agrupar os dados de acordo com sua similaridade; e iii) aprendizado semi-supervisionado, no qual também se tem um conjunto de exemplos fornecidos, mas este conjunto é limitado, portanto em uma das abordagens deste tipo de paradigma é a realimentação do conjunto de treinamento com dados classificados pelo próprio algoritmo. A forma e a presença (ou ausência) de supervisão são aspectos primordiais para caracterizar cada uma das três diferentes abordagens (MITCHELL, 1999).

Na subseção seguinte, o aprendizado supervisionado será descrito com mais detalhes, pois este é o método de aprendizagem que será utilizado nos experimentos deste trabalho.

I. Aprendizado supervisionado

Esta técnica de aprendizado de máquina é dita supervisionada pelo fato de necessitar de um supervisor externo, o qual é responsável por estimular as entradas da rede e observar a saída calculada pela mesma, comparando-a com a saída desejada. Como a resposta da rede é determinada pelos valores atuais do seu conjunto de pesos sinápticos, estes são ajustados de forma a aproximar a saída da rede da saída desejada (BRAGA; FERREIRA; LUDERMIR, 2007).

De modo geral, para cada entrada, a rede tem sua saída corrente comparada com a saída desejada pelo supervisor, que fornece informações sobre a direção do ajuste dos pesos, permeando a minimização dessa diferença. Utilizando como exemplo o reconhecimento de uma imagem que apresenta a região ocular de um bovino infectado pela CIB ou de um bovino sadio, neste caso, cada uma das imagens apresentadas a rede é acompanhada de um rótulo. Assim, o conjunto de dados e rótulos são utilizados para realizar o aprendizado. Esse conhecimento é utilizado posteriormente para reconhecer novas instâncias, no qual o sistema deve ser capaz de diferenciar as duas classes de forma automática.

Os objetos que compõem o problema podem ser representados como pares (x, y) , no qual $x \in X$ é um vetor de valores que representa a instância dos objetos a serem classificados. O rótulo, dado por $y \in Y$, representa o conceito associado à instância e assume-se que existe uma função $F : X \rightarrow Y$, denominada função-conceito, que relaciona a instância x_i ao seu rótulo $F(x_i) = y_i$. Um conjunto de treinamento D é um conjunto que possui exemplos rotulados de forma que $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$.

Segundo Russell e Norvig (2010), o objetivo ideal é induzir a função-conceito F a partir do conjunto de treinamento D . Entretanto, esse objetivo é em geral inalcançável, pois as amostras são tipicamente insuficientes para caracterizar perfeitamente a função-conceito. Assim, o objetivo prático é encontrar, com base nos exemplos de treinamento D , uma boa aproximação ρ tal que $\rho \approx F$. Nesse caso o mapeamento $\rho : X \rightarrow Y$ é uma hipótese ou um modelo sobre F .

A premissa fundamental do aprendizado indutivo sustenta que qualquer modelo ou hipótese que aproxime bem a função-conceito para um conjunto de treinamento representativo também será capaz de aproximar bem a função-conceito para exemplos não observados (MITCHELL, 1999). Porém, o espaço de hipóteses sobre F é potencialmente infinito e pode conter inúmeros modelos que aparentem ser boas aproximações de F nas amostras, mas não generalizem bem para exemplos novos. É necessário que o indutor estabeleça critérios para restringir o processo de busca a um espaço determinado de hipóteses e estabeleça critérios de preferência que lhe permitam escolher uma hipótese adequada nesse espaço, em detrimento de outras hipóteses candidatas (HAUSSLER, 1988). Esse conjunto de critérios configura o viés do indutor.

2.2.2 Classificação

Em sistemas baseados em inteligência artificial e aprendizado de máquina, o objetivo da classificação é examinar um objeto ou instância e decidir, com respeito a um conjunto discreto de classes ou rótulos conhecidos, a qual classe ele pertence (RICH; KNIGHT, 1991). Decidir se uma imagem representa um olho infectado ou um olho sadio, por exemplo, é um problema de classificação. Um algoritmo que realiza essa decisão é denominado classificador.

Estes algoritmos consistem em variáveis alvo ou de saída, conhecidas também como variáveis dependentes, que são previstas por um grupo de variáveis predecessoras, as variáveis independentes. Usando este grupo de variáveis, é gerado uma função que tem como objetivo mapear entradas a fim de obter, em outras análises, as saídas desejadas. Existe uma infinidade de algoritmos de classificação utilizados em aprendizado de máquina. Algumas das principais e mais conhecidas abordagens são árvores de decisão, classificadores condicionais (por exemplo, Naïve Bayes) e redes neurais artificiais.

Como pode ser visto, existem várias abordagens com o mesmo propósito (gerar algoritmos classificadores), contudo, a finalidade do problema tem um papel fundamental na escolha da abordagem mais adequada. É importante conhecer bem a finalidade e o contexto do problema que deve ser processado pela máquina, com detalhes específicos, pois eles ajudam a selecionar a melhor técnica para tratar os dados (MOHRI; ROSTAMIZADEH; TALWALKAR, 2018). Outro aspecto relevante é a quantidade de dados que será utilizada para alimentar o algoritmo classificador. Redes neurais, por exemplo, geralmente precisam de conjuntos de dados com muitas amostras para ter um treinamento eficiente (SERMANET *et al.*, 2013).

Assim, torna-se necessário conhecer bem e se ater ao tamanho do conjunto de dados para estabelecer qual método seguir, pois cada um tem uma forma distinta de lidar com a quantidade de dados. Além disso, existem outros dois aspectos que deve-se levar em consideração no momento de escolher a abordagem que será utilizada: a complexidade do problema e o tempo. A complexidade do problema exige que seja realizada uma avaliação a respeito da capacidade computacional necessária para a execução do algoritmo. A base de dados também influencia neste aspecto. Bases de dados grandes exigem maior poder computacional que bases de dados menores. E, por fim, o tempo de resposta da solução deve ser levado em conta. Existem problemas que vão requerer decisões em tempo real, outros, no entanto, com um intervalo aceitável. Isso

deve ser pensado na hora de escolher a abordagem de classificação que resolva o caso da melhor forma.

A confirmação da melhor abordagem de classificação para um determinado problema é concluída quando é avaliado o processo de aprendizagem do algoritmo adotado. Para isso, existem diversas técnicas de avaliação de aprendizagem que devem ser conduzidas juntamente com o experimento.

2.2.2.1 Avaliação da aprendizagem

O objetivo fundamental de um sistema baseado em aprendizado de máquina é generalizar além das instâncias de dados usadas na etapa de treinamento. Assim, é desejável avaliar o modelo para estimar a qualidade da sua generalização frente a novas instâncias, distintas das quais o modelo utilizou em seu treinamento. Para isso, são utilizadas algumas técnicas que permitem avaliar os modelos em uso, principalmente aqueles que adotam o aprendizado supervisionado. A seguir serão detalhados dois métodos utilizados para avaliação da aprendizagem dos modelos, a divisão da base de dados e as métricas de avaliação.

I. Divisão da base de dados

Segundo Mohri, Rostamizadeh e Talwalkar (2018), a divisão da base de dados é uma abordagem que tem como objetivo separar os dados disponíveis em dois subconjuntos principais: dados de treinamento e dados de avaliação. O processo de criação de modelos de classificação envolve a criação dos modelos e a avaliação da qualidade de generalização. Estas partes devem envolver conjuntos disjuntos de dados, por isso é necessária a divisão da base de dados.

Dados de treinamento são aqueles cuja resposta é conhecida, ou seja, que já possuem uma classe ou rótulo predefinido. Esses dados, por possuírem essa identificação, são utilizados para a tarefa de aprendizagem do modelo. Dados de avaliação são aqueles que também possuem uma classe ou rótulo predefinido, sendo utilizados para avaliar o desempenho de aprendizagem do modelo. Assim, o sistema avalia o desempenho preditivo comparando as previsões no conjunto de dados de avaliação com valores verdadeiros por meio de métricas de avaliação. Geralmente, essa etapa é decisiva para selecionar o modelo com a maior taxa de acerto no subconjunto de avaliação para, posteriormente, realizar previsões mais assertivas em instâncias futuras. Essa divisão é necessária visto que avaliar o modelo com os mesmos dados usados no treinamento não é

útil, pois isso acaba recompensando os modelos que conseguem “memorizar” os dados de treinamento, em vez de fazer a generalização a partir deles (MOHRI; ROSTAMIZADEH; TALWALKAR, 2018).

Sistemas de aprendizado de máquina que utilizam como forma de avaliação a divisão da base de dados em dados de treinamento e dados de avaliação, estão realizando uma validação cruzada. A validação cruzada é uma técnica para avaliar a capacidade de generalização de um modelo, a partir do particionamento do conjunto de dados (KOHAVI *et al.*, 1995). Esta técnica é amplamente empregada em problemas onde o objetivo é a predição de novas amostras. Para isso, existem algumas formas de realizar o particionamento dos dados, sendo as três mais utilizadas: o método *holdout*; o método *k-fold*; e o método *leave-one-out*. Segundo Kohavi *et al.* (1995), os três métodos podem ser definidos da seguinte forma:

- Método *holdout*: consiste em dividir, de forma aleatória, o conjunto total de amostras em dois subconjuntos mutuamente exclusivos, um para treinamento e outro para avaliação. O conjunto de amostras pode ser separado em quantidades iguais, porém usualmente considera-se uma proporção de 70% das amostras para treinamento e 30% restante para avaliação. Após o particionamento, o treinamento do modelo é realizado e, posteriormente, é realizada a avaliação do modelo e o erro de predição calculado. Esta abordagem é indicada quando está disponível uma grande quantidade de amostras. Caso o conjunto total de amostras seja pequeno, o erro calculado na predição pode sofrer muita variação.
- Método *k-fold*: consiste em dividir o conjunto total de amostras em k subconjuntos mutuamente exclusivos de tamanhos similares e, a partir disto, um subconjunto é utilizado para avaliação enquanto os $k - 1$ restantes são utilizados para treinamento. Este processo é realizado k vezes alternando de forma circular o subconjunto de avaliação. Ao final das k iterações calcula-se a acurácia sobre os erros encontrados em cada subconjunto, obtendo uma medida sobre a capacidade de generalização do modelo.
- Método *leave-one-out*: é um caso específico do *k-fold*, porém o k é igual ao número total de amostras. Nesta abordagem é realizado um cálculo de erro para cada amostra. Apesar de apresentar uma investigação completa sobre a variação do modelo em relação as amostras utilizadas, este método possui um alto custo computacional, sendo indicado para situações onde poucas amostras estão disponíveis.

II. Métricas de avaliação

Sistemas baseados em aprendizado de máquina necessitam de uma avaliação do seu desempenho para verificar sua eficiência em relação a tarefa de aprendizagem e para isso algumas métricas são utilizadas. Segundo Sokolova, Japkowicz e Szpakowicz (2006), medidas que avaliam a qualidade de uma tarefa de classificação são construídas a partir de uma matriz de confusão, que contabiliza exemplos reconhecidos corretamente e incorretamente para cada classe. Geralmente, em classificações binárias essas matrizes são estruturas compostas por quatro categorias de resultados: verdadeiros positivos (VP); falsos positivos (FP); verdadeiros negativos (VN); falsos negativos (FN). O modelo de matriz de confusão para uma hipótese pode ser visto na tabela 1.

Tabela 1 – Matriz de confusão de uma hipótese.

		Classe Esperada	
		Positivo	Negativo
Classe Prevista	Positivo	VP	FP
	Negativo	FN	VN

Fonte: Adaptada de Sokolova, Japkowicz e Szpakowicz (2006).

Como pode ser visto na tabela 1, a saída de um classificador é contabilizada como VP quando a classe prevista e a classe esperada são igualmente positivas; FP quando a classe prevista é positiva, mas a classe esperada é negativa; VN quando a classe prevista e classe esperada são igualmente negativas; e FN quando a classe prevista é negativa e a classe esperada é positiva.

Segundo Sokolova, Japkowicz e Szpakowicz (2006), as métricas mais utilizadas para avaliar algoritmos de aprendizado de máquina têm sido a taxa de acurácia e a taxa de erro, as quais são definidas pelas Equações 1 e 2, respectivamente. Porém, afirmam também que a avaliação utilizando apenas essas métricas é frágil, pois as mesmas não atendem plenamente as necessidades de problemas de aprendizagem nos quais as classes são igualmente importantes.

$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN} \quad (1)$$

$$Erro = 1 - Acurácia \quad (2)$$

Por outro lado, duas medidas que estimam separadamente o desempenho de um classificador em diferentes classes são sensibilidade e especificidade. Essas

medidas geralmente são utilizadas em aplicações de aprendizado de máquina e visão computacional para resolver problemas médicos, biomédicos e em estudos de outras áreas que envolvam dados visuais (imagens) (DAVIS; GOADRICH, 2006). A sensibilidade explica a capacidade do sistema em prever corretamente a condição para casos que realmente a possui e a especificidade explica a capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a possui (ZHU *et al.*, 2010). A sensibilidade e a especificidade são definidas pelas Equações 3 e 4.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (4)$$

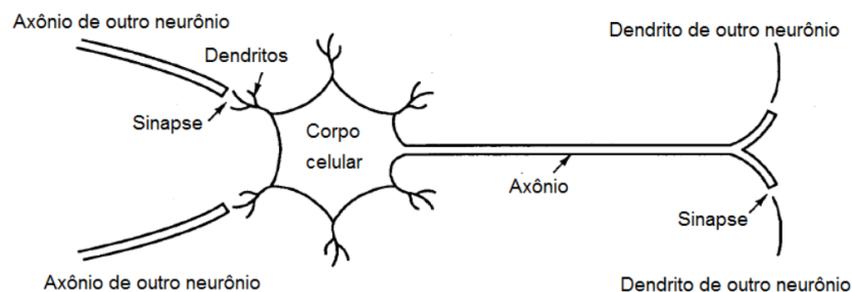
2.2.3 Redes Neurais Artificiais

Uma rede neural artificial (RNA) é um método de classificação poderoso inspirado no conceito de neurônios biológicos (MITCHELL, 1999; HAYKIN *et al.*, 2009), que possui a capacidade de aprender por meio de exemplos e generalizar a informação por meio de um conjunto de unidades de processamento, caracterizadas como unidades de neurônios artificiais (SILVA; SPATTI; FLAUZINO, 2010).

RNA podem receber uma coleção de padrões de entrada com a categoria a qual cada padrão particular pertence. Em seguida, pode-se apresentar um novo padrão ainda desconhecido à rede e, a tarefa dela é classificar este novo padrão corretamente. A vantagem de usar uma rede neural para realizar tarefas de classificação de padrões é que ela pode construir fronteiras de decisões não lineares entre as diferentes classes e oferecer um método prático para resolver problemas complexos (KOVÁCS, 2002).

Os neurônios artificiais são constituídos por elementos de uma maneira análoga a das funções mais elementares dos neurônios biológicos. Desta forma, a estrutura individual de cada neurônio, os tipos de suas conexões e o comportamento do conjunto dos neurônios naturais formam a base para o estudo de RNA (BRAGA; CARVALHO; LUDERMIR, 2000). Um neurônio biológico é uma unidade fundamental do sistema nervoso, tendo como principal função a condução de impulsos elétricos. A figura 1 apresenta a composição de um neurônio biológico e suas respectivas partes.

Figura 1 – Neurônio biológico.



Fonte: Fausett *et al.* (1994).

Para compreender melhor seu funcionamento, Silva, Spatti e Flauzino (2010) sugerem dividi-lo em três partes: dendritos, corpo celular e axônio.

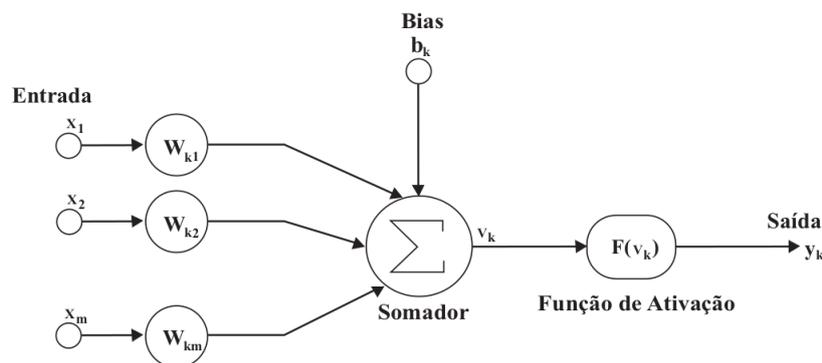
1. **Dendritos:** são vários prolongamentos que associados formam a árvore dendrital. Sua função é captar os estímulos de outros neurônios, por meio de sinais em forma de impulsos elétricos, e os conduzirem até o corpo celular.
2. **Corpo celular:** onde as informações recebidas por meio dos dendritos são processadas e novos impulsos são gerados. Esses impulsos são transmitidos a outros neurônios, por meio do axônio.
3. **Axônio:** é constituído por um único prolongamento, e o ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro neurônio é denominada sinapse. Portanto, por meio das sinapses, ocorre a conexão que viabiliza a transferência de impulsos elétricos de um neurônio a outro.

Nas RNA, assim como no sistema nervoso, o neurônio artificial é a unidade fundamental para o processamento da informação. A figura 2 apresenta o modelo de um neurônio artificial.

No neurônio artificial, os valores são recebidos pelas entradas (x_1, x_2, \dots, x_m) , a partir disso são ponderados pela ação dos respectivos pesos sinápticos $(w_{k1}, w_{k2}, \dots, w_{km})$ e combinados pelo somador V_k . Em seguida, a saída gerada pelo somador é aplicada a uma função de ativação $F(V_k)$, que restringe a amplitude do sinal de saída ao condicionador de ativação do sinal à ultrapassagem de um determinado limiar pelo valor da soma ponderada das entradas. A saída y_k , gerada pela função de ativação, é a resposta do neurônio para as entradas que lhes foram apresentadas. De forma complementar, o *bias* b_k pode ser utilizado para aumentar ou diminuir a entrada da função de ativação (OLIVEIRA, 2005).

Como descrito em Oliveira (2005), a saída de uma RNA depende de uma função

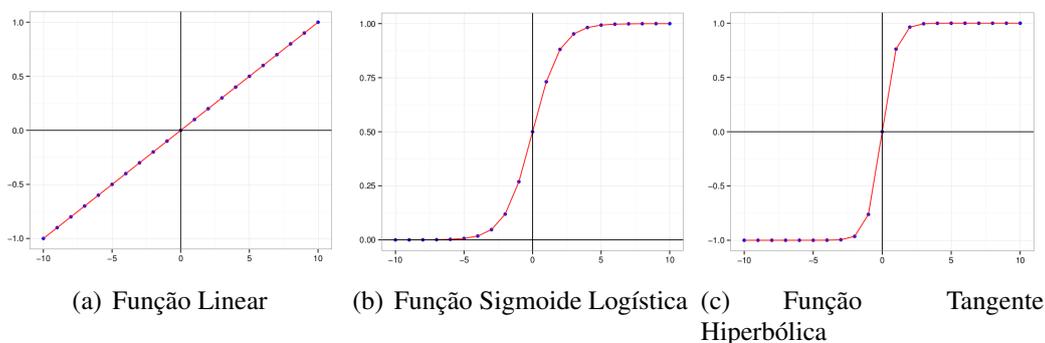
Figura 2 – Neurônio artificial



Fonte: Oliveira (2005).

de ativação, a qual recebe os dados do somador, realiza o processamento e gera a saída do neurônio. Contudo, há diferentes tipos de funções de ativação, sendo as mais utilizadas a função linear, sigmoide e tangente hiperbólica. A figura 3 apresenta, de forma gráfica, as funções de ativação linear, sigmoide logística e tangente hiperbólica.

Figura 3 – Exemplos gráficos de diferentes tipos de funções de ativação para processar as informações em neurônios artificiais.



Fonte: Adaptada de Oliveira (2005).

A função linear, representada pela figura 4(a), pode ser restringida para gerar valores entre $[-1, 1]$. Já a função sigmoide logística, representada pela figura 4(b), possui valores em uma faixa de $[0, 1]$. Por fim, a função tangente hiperbólica, representada pela figura 4(c), possui valores entre $[-1, 1]$.

Atualmente, uma simples função de ativação denominada ReLu vem sendo utilizada com sucesso em várias aplicações envolvendo RNA. Testes conduzidos por Krizhevsky, Sutskever e Hinton (2012) reportaram uma convergência 6 vezes mais rápida das RNA utilizando a função ReLu quando comparada à convergência das RNA com função de ativação tangente hiperbólica. A função ReLu será detalhada na subseção

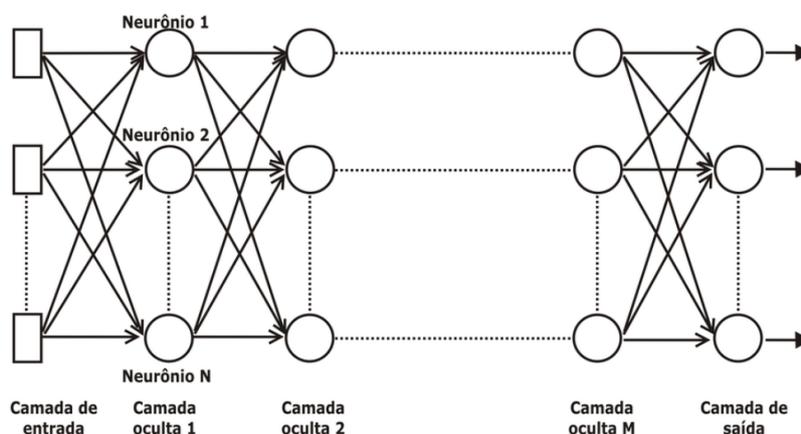
seguinte.

I. Arquiteturas de uma Rede Neural Artificial

Segundo Silva, Spatti e Flauzino (2010), a forma como os neurônios estão organizados ou dispostos, uns em relação aos outros, define a arquitetura de uma RNA. Definir a arquitetura de uma RNA é uma tarefa fundamental, pelo fato da sua organização depender do problema a ser tratado pela rede. Outro fator que também está ligado à arquitetura da rede é o tipo de algoritmo utilizado para o seu treinamento. Dentre os vários tipos de arquiteturas existentes, as principais são as redes do tipo *feedforward* de camada simples e as redes *feedforward* de camadas múltiplas. A arquitetura de camadas múltiplas, amplamente conhecida como *Multilayer Perceptron* (MLP), é uma das mais utilizadas (SILVA; SPATTI; FLAUZINO, 2010).

As redes MLP são formadas por grupos de neurônios organizados em forma de camadas. A figura 4 apresenta a estrutura de uma rede MLP. Na primeira camada estão as entradas, unidades sensoriais que não possuem poder de processamento, seguida pela camada oculta (que pode possuir uma ou várias camadas), formada por grupos de nós computacionais (*perceptrons*), e, por fim, uma camada de saída, também formada por nós computacionais. O sinal recebido pela entrada se propaga por todas as camadas da rede (PRADO, 2014).

Figura 4 – Arquitetura de uma RNA do tipo MLP.



Fonte: Prado (2014).

Geralmente, redes MLP são arquiteturas totalmente conectadas, uma vez que todos os neurônios de uma camada estão ligados a todos os neurônios da camada seguinte. Caso alguma conexão entre dois neurônios (ou mais) esteja ausente, essa rede passa a ser denominada parcialmente conectada. A arquitetura apresentada na figura 4 é um exemplo

de MLP totalmente conectada.

Em uma rede MLP, cada neurônio realiza uma função específica. A função implementada por um neurônio de uma dada camada é uma combinação das funções realizadas pelos neurônios da camada anterior que estão conectados a ele. Com isso, a complexidade do processamento aumenta à medida em que o processamento avança nas camadas da rede. Segundo Faceli *et al.* (2011), a combinação das funções desempenhadas por cada neurônio da rede define a função associada à RNA como um todo. Para que uma rede MLP seja capaz de solucionar um determinado problema, é necessário realizar seu treinamento de aprendizagem.

II. Aprendizagem de uma Rede Neural Artificial

O aprendizado supervisionado é o mais comum em RNA do tipo MLP. Desta forma, cada entrada submetida à rede gera uma saída calculada, que é comparada à resposta desejada, para que os pesos possam ser ajustados e o erro seja minimizado (RUSSELL; NORVIG, 2010). O principal algoritmo utilizado para o treinamento de RNA é o *Backpropagation*.

O algoritmo *Backpropagation* consiste em realizar iterações em duas fases, uma fase para frente, conhecida como propagação, e outra fase para trás, conhecida como retro-propagação. Na fase de propagação, cada amostra de entrada é apresentada à rede. A amostra é primeiramente recebida por cada um dos neurônios da primeira camada oculta, onde são ponderados pelos pesos associados as conexões de entrada correspondentes ao neurônio e, em seguida, o valor total recebido é aplicado à função de ativação e a saída produzida pela função é utilizada como entrada para os neurônios da próxima camada (GOODFELLOW; BENGIO; COURVILLE, 2016).

Esse processo é repetido até os neurônios da camada de saída. Os valores gerados pelos neurônios da camada de saída são comparados com a saída desejada, já no processo de classificação. O cálculo da diferença entre esses valores indica o erro cometido pela rede. O valor do erro de cada neurônio da camada de saída é então utilizado na fase de retro-propagação para ajustar os pesos iniciais (FACELI *et al.*, 2011). Assim, a rede tem a capacidade de aumentar sua taxa de assertividade a cada vez que os pesos são ajustados.

i. Aprendizagem profunda

Aprendizagem profunda ou "*Deep Learning*", como é amplamente conhecida, é o termo usado para denotar o problema de treinar redes neurais artificiais que realizam o aprendizado de características de maneira hierárquica, onde as características nos níveis

mais altos da hierarquia sejam formadas pela combinação de características de mais baixo nível (GOODFELLOW; BENGIO; COURVILLE, 2016; ARAÚJO *et al.*, 2017; PONTI; COSTA, 2018).

Segundo Serre *et al.* (2007), o processo de utilizar múltiplos níveis de abstração é particularmente similar ao funcionamento do sistema visual dos primatas. Neste caso, o processamento pode ser dividido em dois estágios: i) detecção de bordas; e ii) detecção de formas primitivas, onde gradualmente é identificado formatos visuais mais complexos. Esse processo se repete por meio das regiões onde estão os neurônios das camadas intermediárias, os quais repassam seus resultados para a região onde estão os neurônios da camada final. Na camada final, é onde ocorre a detecção de características com um nível mais alto de abstração, como por exemplo faces ou objetos específicos (BENGIO; COURVILLE; VINCENT, 2013).

O aprendizado de características em múltiplos níveis de abstração permite um sistema aprender complexas funções de mapeamento dos dados de entrada para saída, de maneira independente, ou seja, é uma forma de automatizar a identificação de características. Assim, a própria rede acaba selecionando características que sejam mais representativas para solucionar o problema proposto.

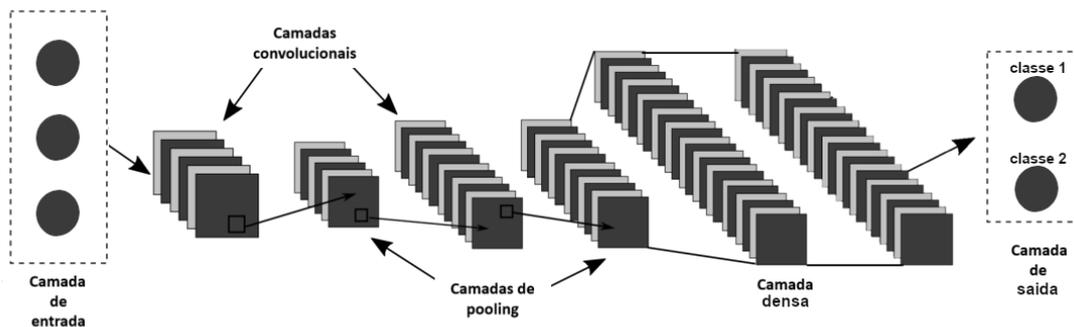
Um tipo de RNA que utiliza o aprendizado profundo como método de aprendizagem são as redes neurais convolucionais.

2.2.3.1 *Redes Neurais Convolucionais*

Redes neurais convolucionais (RNC) são um tipo de RNA, baseada em aprendizagem profunda, especializada para o processamento de dados de entrada que possuem um formato de matriz, usualmente utilizadas para o processamento de informações visuais, em particular imagens digitais (KRIZHEVSKY; SUTSKEVER; HINTON, 2012; LECUN; BENGIO; HINTON, 2015; GOODFELLOW; BENGIO; COURVILLE, 2016; PONTI; COSTA, 2018).

De modo geral, as RNC são caracterizadas pela sua composição, onde é basicamente composta por camadas convolutivas, que processam as entradas considerando campos receptivos locais. Desta forma, as RNC são uma espécie de extrator de características automático que antecede uma RNA do tipo *feedforward* de camadas múltiplas para, no fim, servir como um classificador de resultados em classes distintas. A arquitetura de uma RNC é apresentada na figura 5.

Figura 5 – Arquitetura de uma rede neural convolucional.



Fonte: Araújo *et al.* (2017).

A título de simplificação do modelo apresentado na figura 5, é composto por apenas duas camadas de convolução e duas camadas de *pooling*. Entretanto, a maioria dos modelos atuais, são compostas de diversas destas camadas. O resultado gerado a partir da camada de convolução é denominado mapas de características e os mesmos são utilizados como entrada para a próxima camada, que é a de *pooling*. Já os resultados gerados a partir da camada de *pooling* é utilizado como entrada para a camada totalmente conectada. Esta camada é responsável em gerar as saídas da rede, ou seja, o resultado da classificação. Segundo Ponti e Costa (2018), as camadas de uma RNC são caracterizadas da seguinte forma:

i. Camada de entrada

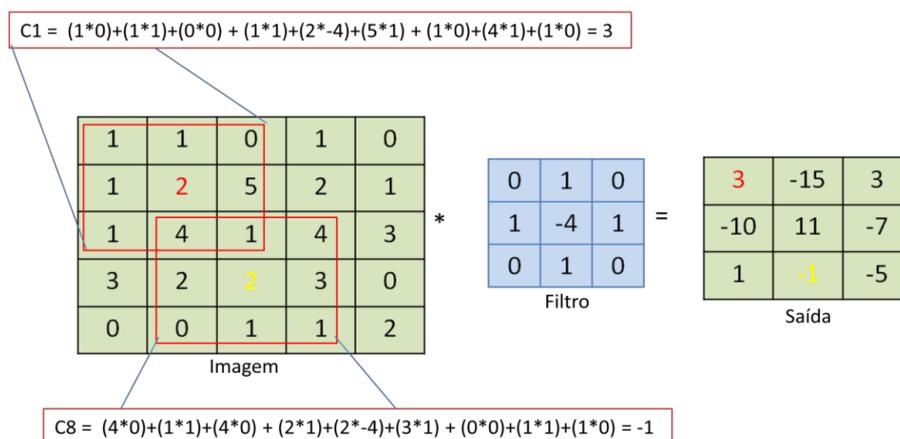
A camada de entrada é responsável por receber os padrões que serão apresentados para a RNC processar, seja na fase de treinamento, seja na fase de avaliação de aprendizagem.

ii. Camada convolucional

Na camada convolucional cada neurônio é utilizado como um filtro aplicado a um subconjunto ou uma pequena região do conjunto de entrada, onde as pequenas regiões coletivamente cobrem o conjunto de entrada como um todo. Esse filtro é constituído por uma matriz de pesos. Assim, cada neurônio irá processar partes do conjunto de entrada e produzir uma transformação desse conjunto por meio de uma combinação linear. Cada representação gerada pelos neurônios da camada convolucional é denominada campo receptivo local e o resultado é conhecido como mapa de características, os quais são utilizados como entrada para a próxima camada da rede.

Um mapa de características é obtido efetuando a convolução de uma matriz de entrada, que em aplicações de visão computacional pode ser uma imagem, por um filtro linear. O processo de convolução utilizado em uma RNC é apresentado na figura 6.

Figura 6 – Processo de convolução utilizado em RNC.



Fonte: Faria (2018).

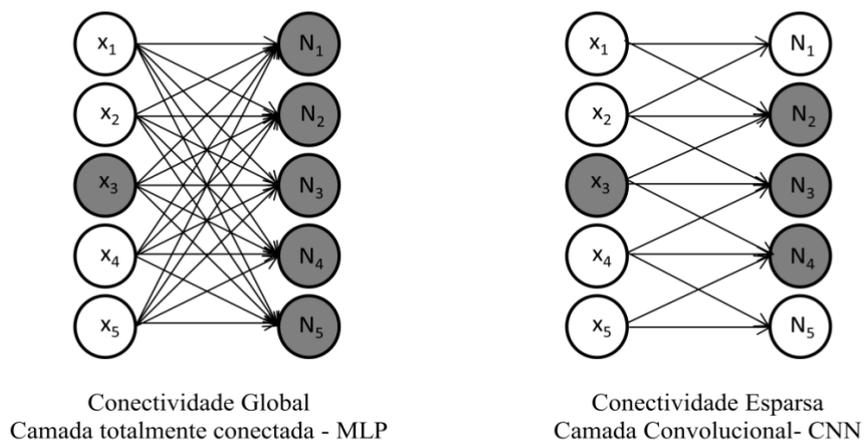
Na figura 6 o processo de convolução é realizado em uma imagem, a qual foi utilizada como o conjunto de entrada neste exemplo. Neste processo, para cada representação que é deslocada sobre a imagem de entrada, o produto entre cada elemento do filtro (também conhecido como *kernel* de convolução) e o elemento de entrada que ele sobrepõe é calculado e os resultados são somados para obter a saída correspondente aquela localização analisada. O resultado final deste procedimento é denominado mapa de características.

De acordo com Faria (2018), as RNC apresentam características que contrastam com paradigmas que fazem parte dos modelos de arquiteturas rasas, como as redes MLP por exemplo. São elas: conectividade esparsa, campos receptivos locais e compartilhamento de parâmetro.

- **Conectividade esparsa:** este tipo de conectividade acontece devido ao fato de que o filtro (*kernel*) que é utilizado no processo de convolução apresenta dimensões muito menores do que a matriz de entrada. Isto permite uma correlação espacial local por meio da aplicação de um padrão de conectividade local entre neurônios de camadas adjacentes. Nas arquiteturas de redes MLP, cada neurônio da camada de saída interage com cada neurônio da camada de entrada por meio de um processo de multiplicação de matrizes gerando uma conectividade global entre os parâmetros.

Na figura 7 é possível verificar os dois tipos de conectividades (global e esparsa) para os dois tipos de arquiteturas (MLP e RNC).

Figura 7 – Conectividade global e esparsa das redes MLP e RNC.

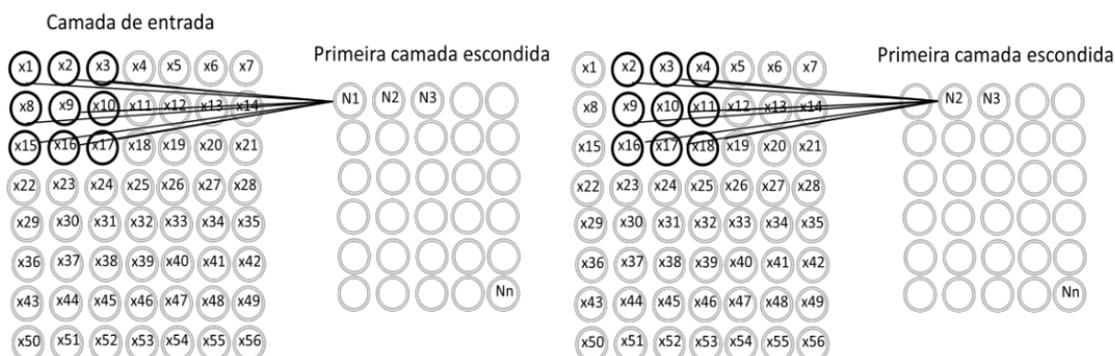


Fonte: Goodfellow *et al.* (2016).

Na figura 7, analisando apenas a entrada x_3 , é possível verificar que quando o modelo faz uso da multiplicação de matrizes (conectividade global) todas as unidades de saída são afetadas. Isto não ocorre quando o modelo faz uso da camada convolutiva, neste caso utilizando um *kernel* de tamanho 3×3 por exemplo, apenas três unidades da camada de saída são afetadas pela entrada x_3 .

- **Campos receptivos locais:** cada região na matriz de entrada que representa o tamanho do filtro utilizado vai corresponder a um novo neurônio na camada escondida. Este procedimento está representado na figura 8.

Figura 8 – Exemplo do campo receptivo local das RNC.



Fonte: Nielsen (2015).

Na figura 8 é possível verificar que os neurônios de entrada x_1 a x_{17} , utilizando um filtro de convolução de tamanho 3×3 , afetam o neurônio de saída N_1 . Esta região destacada é que recebe o nome de campo receptivo local do neurônio de saída N_1 . O mesmo acontece para os demais neurônios de saída.

- **Compartilhamento de parâmetros:** os mesmos filtros são aplicados em diferentes locais da matriz de entrada. Isto faz com que os padrões que ocorrem com frequência na matriz de entrada e que estejam localizados em qualquer parte da entrada possam ser aprendidos (NIELSEN, 2015).

Segundo Goodfellow *et al.* (2016), o uso dessas características permite as RNC armazenarem menos parâmetros, o que reduz os requisitos de memória do modelo e melhora a sua eficiência estatística. Além disso, a geração dos resultados obtidos requer menos operações, o que possibilita uma grande melhoria na eficiência destes modelos.

Os resultados obtidos ao efetuar o processo de convolução em uma matriz de entrada juntamente com a adição de um termo de *bias* são utilizados como entrada para uma função de ativação não linear. A função de ativação que tem se destacado para uso em modelos de RNC é a ReLu (JARRETT *et al.*, 2009; GLOROT; BENGIO, 2010; NAIR; HINTON, 2010; KRIZHEVSKY; SUTSKEVER; HINTON, 2012). A função ReLu é descrita pela Equação 5, onde z representa o valor de entrada de um neurônio. A saída esperada de uma ReLu é o valor máximo entre 0 e a entrada.

$$f(z) = \max(0, z) \quad (5)$$

Por fim, cabe ressaltar dois hiperparâmetros muito importantes em relação aos filtros utilizados nas camadas convolucionais, o *wide* ou *narrow convolution* e o *stride* (PONTI; COSTA, 2018). O primeiro deles define a forma como aplicar o filtro, ou seja, dada uma matriz de dados, como aplicar o filtro aos elementos que não possuem vizinhos (elementos na borda da matriz). Uma abordagem comumente utilizada é a utilização do *padding* (preenchimento) que visa expandir a matriz de entrada. Em casos onde se faz uso do *padding* com valor zero este hiperparâmetro é conhecido por *wide convolution*. No caso contrário, onde não há utilização do *padding*, o hiperparâmetro é conhecido como *narrow convolution*. *Stride* (ou passo) é outro hiperparâmetro a ser definido e é responsável por determinar qual o tamanho do deslocamento do filtro a cada passo. Geralmente em aplicações envolvendo reconhecimento de imagens é comum o uso de

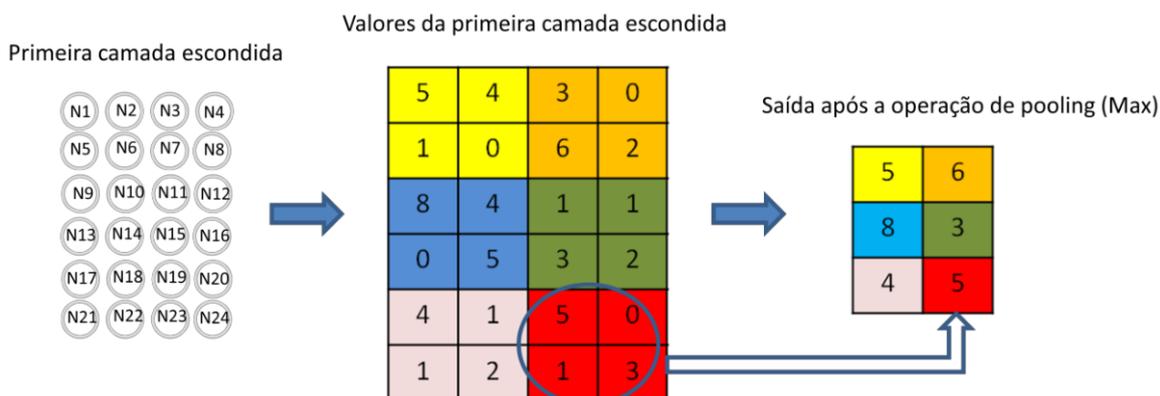
stride igual a 1, ou seja, o filtro é deslocado pela imagem um pixel por vez.

iii. Camada de *pooling*

A camada de *pooling* é usualmente utilizada imediatamente depois de uma camada convolucional e é responsável por tentar encontrar a informação mais importante e significativa obtida por uma camada convolutiva. Segundo Goodfellow *et al.* (2016), as camadas de *pooling* substituem a saída das camadas convolucionais em uma determinada região por uma estatística resumida das saídas mais próximas, o que pode gerar uma redução no número de neurônios da camada anterior. O operador de *max* é a função de *pooling* que reporta o valor máximo de uma determinada região, esse operador é geralmente adotado como padrão. Outras funções também muito utilizadas são a média, a norma L2 ou a média ponderada da região local analisada (PONTI; COSTA, 2018).

Uma propriedade importante do *pooling* é o fato do mesmo fornecer uma matriz de saída de tamanho fixo. Em aplicações envolvendo reconhecimento de imagens, o *pooling* fornece invariância a translação e rotação, ou seja, indiferente da operação realizada na imagem, o operador de *max* escolherá sempre o mesmo valor. A figura 9 apresenta o operador *max* para uma matriz de saída de tamanho 4×6 com uma janela de tamanho 2×2 . Este operador será adotado neste trabalho para compor a arquitetura dos modelos de RNC desenvolvidos.

Figura 9 – Exemplo de uma operação de *pooling*.



Fonte: Faria (2018).

Na figura 9 é possível visualizar que a saída da camada convolucional é composta de 4×6 neurônios e que após o processamento da camada de *pooling* restou apenas uma saída de 2×3 neurônios. Uma redução significativa, onde somente as melhores características ficam armazenadas. Além disso, com a redução do número

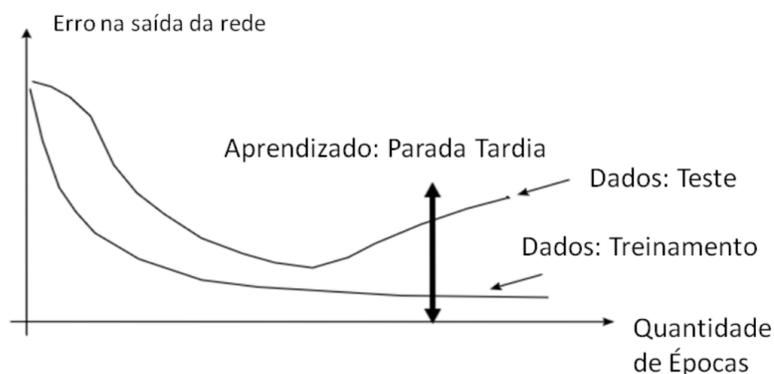
de características, há também uma redução no número de parâmetros necessários nas camadas posteriores e o custo computacional é atenuado (PONTI; COSTA, 2018).

iv. *Dropout*

RNC são complexas pelo ponto de vista operacional, isto é, as aplicações que fazem uso deste tipo de arquitetura podem chegar a apresentar milhares de camadas de processamento aumentando substancialmente a quantidade de parâmetros da rede (PONTI; COSTA, 2018). Conseqüentemente, esta maior complexidade da RNC pode apresentar um problema conhecido como sobre-ajuste (*overfitting*), ou seja, quando o modelo se ajusta muito aos dados apresentados durante o processo de treinamento e conseqüentemente não generaliza bem a dados desconhecidos, o que não é desejável.

Na figura 10, pode ser visualizada a ocorrência do *overfitting* no treinamento de uma RNC por exemplo. É possível constatar que o erro nos dados de treinamento continua diminuindo, entretanto, o erro do conjunto de teste começou a aumentar. Isso acontece porque o critério de parada do algoritmo ocorre de forma tardia.

Figura 10 – Problema de *overfitting* durante o treinamento de uma RNC.



Fonte: Faria (2018).

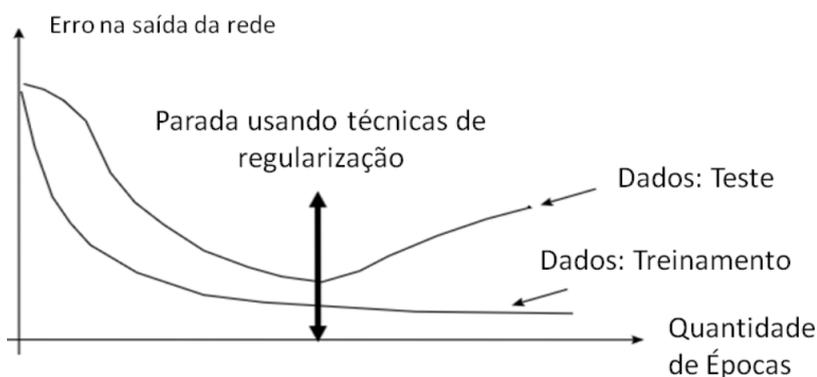
Segundo Goodfellow *et al.* (2016), o problema de *overfitting* pode ser resolvido por meio de diferentes técnicas de regularização. Estas técnicas são responsáveis em realizar uma modificação no algoritmo de aprendizagem a fim de reduzir o erro de generalização, mas não necessariamente o erro do treinamento.

Uma das técnicas de regularização que vem sendo utilizada com sucesso em aplicações envolvendo RNC é conhecida como *dropout* (HINTON *et al.*, 2012). A técnica de *dropout* visa definir estocasticamente zeros a saída de alguns neurônios de uma determinada camada com probabilidade de $p = 0.5$. O restante dos pesos dos neurônios não modificados são treinados pelo algoritmo *backpropagation*. O procedimento é

repetido para cada exemplo em cada época de treinamento.

A figura 11 apresenta o resultado do uso de uma técnica de regularização (como o *dropout*) durante a fase de treinamento de uma RNC. Observando a respectiva imagem, é possível constatar que o treinamento é encerrado em um ponto ótimo de generalização, ou seja, antes que o erro no conjunto de teste aumentasse.

Figura 11 – Resultado do uso de técnicas de regularização durante o treinamento de uma RNC.



Fonte: Faria (2018).

Hinton *et al.* (2012) afirmaram que a técnica de *dropout* pode reduzir as coadaptações complexas de neurônios, uma vez que os neurônios da camada associada desativados não podem influenciar os demais neurônios. Consequentemente os neurônios aprendem características mais robustas aumentando assim a eficiência na generalização do modelo. Os autores afirmaram também que a técnica além de ser eficiente para reduzir o erro no conjunto de testes (generalização), é computacionalmente eficiente no treinamento de um grande número de redes difergrande número de redes diferentes em um tempo razoável.

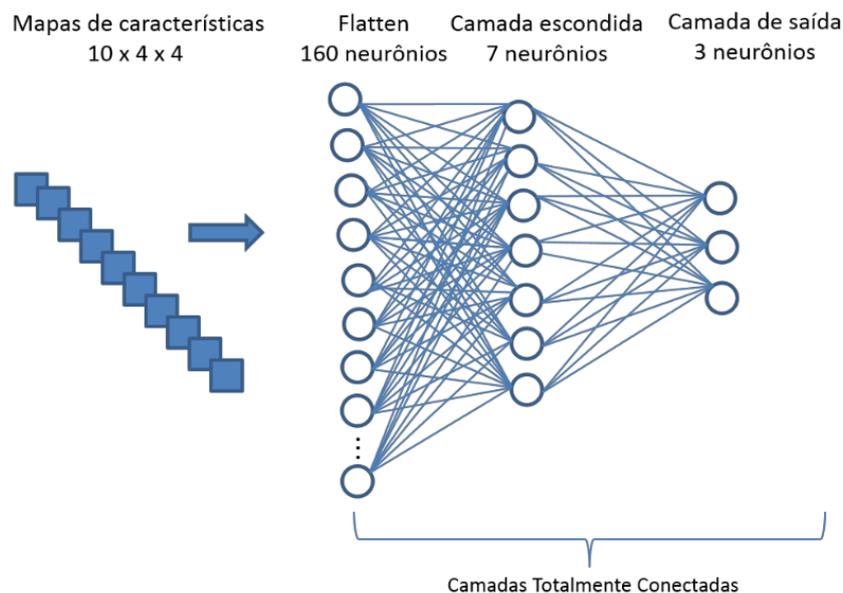
v. Camada totalmente conectada (densa):

As RNC apresentam uma ou mais camadas totalmente conectadas. O objetivo desta camada é usar as características de mais alto nível, geradas a partir das camadas anteriores (camadas convolucionais e *pooling*), para fazer a classificação dos dados de entrada em várias classes baseada em um conjunto de treinamento (PONTI; COSTA, 2018).

Essa camada possui a característica de ser completamente conectada, uma vez que, cada neurônio da camada anterior é conectado a cada um dos neurônios da próxima camada, neste caso a primeira camada totalmente conectada. A mesma é composta

também de uma última camada, denominada camada de saída, onde cada neurônio representa uma determinada classe do modelo, sendo assim, o número de neurônios da camada de saída é correspondente a quantidade de classes presentes no modelo. A figura 12 apresenta um exemplo de estrutura de uma camada totalmente conectada.

Figura 12 – Estrutura de uma camada totalmente conectada de uma RNC.



Fonte: Faria (2018).

Na figura 12 é possível observar dez mapas de características de tamanho 4×4 (resultados dos processamentos das camadas anteriores - convolucional ou *pooling*), no qual cada elemento da matriz de saída é conectado a um determinado neurônio de entrada. Estes resultados são colocados de forma linear formando a primeira camada totalmente conectada (camada *flatten* composta por 160 neurônios). Em seguida, estas entradas vão alimentar a segunda camada totalmente conectada (camada escondida composta por 7 neurônios). No final da cadeia de processamento da camada totalmente conectada pode ser visualizada a camada de saída (composta por 3 neurônios) que correspondem as classes do modelo.

Segundo Goodfellow *et al.* (2016) a função de ativação amplamente utilizada na camada de saída de uma camada totalmente conectada é a função sigmoide, descrita na Equação 6 e visualizada na figura 4(b), a qual será adotada nos modelos de RNC desenvolvidos neste trabalho. A sigmoide limita a saída a um intervalo entre 0 e 1,

tornando essa função útil na previsão de probabilidades.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

vi. Camada de saída:

Ao final do processamento da RNC, a camada de saída é responsável por receber os estímulos das camadas intermediárias e construir o padrão que será a resposta final.

I. Arquitetura e parâmetros de uma Rede Neural Convolutacional

A arquitetura de uma RNC é constituída pela camada de entrada juntamente com a combinação de blocos de camadas convolucionais seguidas de funções de ativação que geram mapas de características. Esses mapas de características são processados pelas camadas de *pooling*. Por fim, um conjunto de camadas completamente conectadas, também acompanhadas por funções de ativação, são responsáveis por gerar o resultado final.

A configuração de uma RNC passa pela definição de três principais hiperparâmetros:

1. Número de camadas convolucionais;
2. Número de camadas de *pooling*;
3. Número de camadas totalmente conectadas.

Uma RNC pode ter uma arquitetura simples, com poucos parâmetros de entrada. Porém, se a arquitetura é expandida, o número de parâmetros a serem aprendidos cresce consideravelmente e a complexidade da rede também.

A definição dos hiperparâmetros para o desenvolvimento do melhor modelo é um processo exploratório que observa a complexidade dos dados de avaliação. Nesse sentido, Ponti e Costa (2018) recomendam criar vários modelos de treinamento distintos, onde para cada novo modelo os hiperparâmetros devem ser variados. Por vezes, o modelo que melhor se ajusta aos dados não é aquele que possui a configuração mais complexa, contudo o contrário também pode ser verdade.

O número de camadas convolucionais e o número de camadas de *pooling* são responsáveis pela extração de características do modelo, portanto a quantidade e tamanho dos filtros convolucionais são importantes hiperparâmetros a serem explorados na construção dos modelos. Da mesma maneira, o número de camadas totalmente conectadas também é fundamental para a classificação dos mapas de características

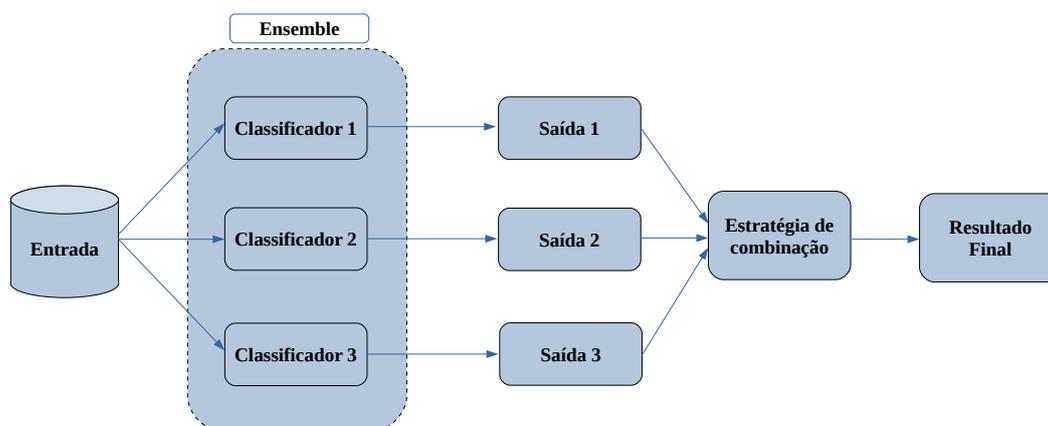
gerados pelas camadas anteriores e uma variação delas também é desejada na composição de modelos com arquiteturas distintas.

2.2.4 Combinação de classificadores

Até o momento foi visto como construir um modelo embarcado com inteligência artificial capaz de aprender com base em exemplos e generalizar esse aprendizado para novas amostras. Por vezes, a decisão baseada em apenas um classificador pode ser equivocada, principalmente quando estamos desenvolvendo uma ferramenta para diagnóstico médico. Uma alternativa que tem sido utilizada para atenuar esse problema é a utilização de um *ensemble*.

Um *ensemble* é uma combinação de classificadores por meio de uma estratégia pré-estabelecida que usualmente visa garantir um aumento de generalização em problemas de classificação (DIETTERICH, 2000). A decisão final de apenas um classificador pode ser considerada fraca ou até mesmo inadequada, enquanto a decisão de vários classificadores torna o método mais robusto e com decisões mais seguras. Um exemplo de *ensemble* pode ser visto na figura 13. Neste exemplo, o conjunto de entrada é apresentado para três classificadores com arquiteturas ou métodos distintos. Cada um dos classificadores gera uma saída, as quais são combinadas por meio de uma estratégia e a saída final é gerada.

Figura 13 – Exemplo de um *ensemble*.



Fonte: Autor (2019).

A combinação das saídas pode ser gerada a partir de várias técnicas, sendo a combinação linear, a combinação não linear e a combinação estatística as mais utilizadas

(KUNCHEVA, 2014). Na combinação linear, a partir da saída dos classificadores, utiliza-se a soma, média e mediana para calcular o resultado final; na combinação não linear o voto majoritário é um exemplo bastante utilizado; e na combinação estatística utilizam-se de probabilidades ou combinações estatísticas.

Em casos que estrutura de um *ensemble* é composta por uma quantidade par de classificadores, uma estratégia de desempate se faz necessária para evitar que a decisão final seja afetada. Isso ocorre nos casos que a combinação das saídas dos classificadores seja igualmente dividida entre as classes. Neste trabalho a estratégia adotada envolve a escolha das saídas dos classificadores que, após somadas, tenham a maior distância do ponto de indecisão, que neste caso é 0.5.

Os benefícios do uso de um *ensemble* iniciam pelo fato de que um conjunto de classificadores geralmente obtém um desempenho melhor do que os classificadores individuais (DIETTERICH, 2000). Por exemplo, suponha que um conjunto de classificadores binários $\{c1, c2, c3, c4, c5\}$ sejam testados na classificação de uma imagem termográfica da região ocular bovina, o qual devem retornar como resultado se há sinais da doença na imagem ou não. Quando as saídas dos classificadores $\{c3, c5\}$ estiverem em desacordo com as saídas dos classificadores $\{c1, c2, c4\}$, utilizando a votação majoritária como técnica de combinação, a maioria dos acertos prevalecem e portanto as saídas dos classificadores $\{c1, c2, c4\}$ serão consideradas como saída final. Dessa forma, percebe-se que o método de classificação pode tornar-se mais robusto na predição das amostras do conjunto de dados.

Neste trabalho é pretendido explorar a combinação dos melhores modelos de RNC em *ensembles* distintos. Desta forma, espera-se que a capacidade de predição do método proposto seja potencializada.

2.3 Ceratoconjuntivite Infeciosa Bovina

A ceratoconjuntivite infecciosa bovina (CIB) é considerada a doença ocular de maior relevância na criação de bovinos, sendo responsável por perdas econômicas e produtivas consideráveis em rebanhos de todo o mundo. A CIB é uma doença contagiosa causada por uma bactéria do gênero *Moraxella*, sendo seu agente primário *Moraxella bovis* (ALEXANDER, 2010; POSTMA; CARFAGNINI; MINATEL, 2008).

A CIB pode apresentar curso agudo, subagudo ou crônico, atingindo apenas um ou ambos os olhos do animal (PUNCH *et al.*, 1985). Embora não seja uma doença

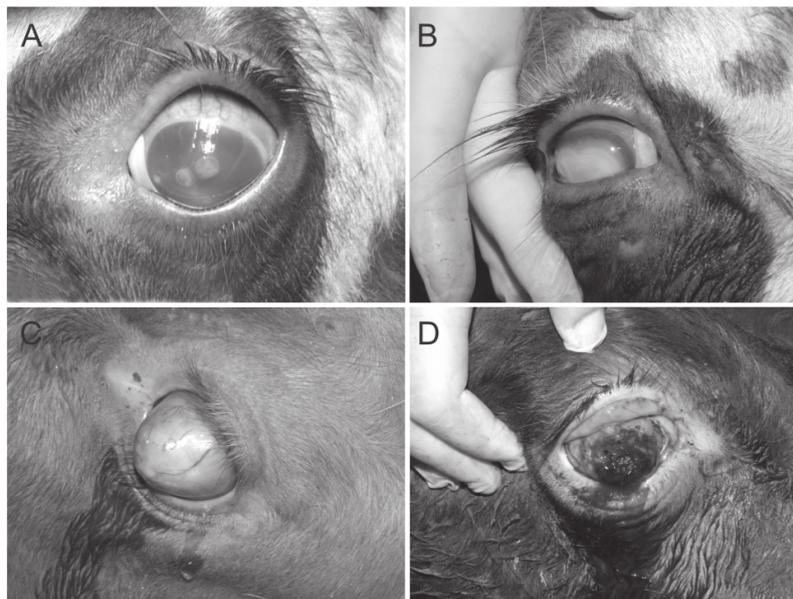
geralmente fatal, tem altas taxas de morbidade, principalmente em animais jovens (até 2 anos), chegando a afetar cerca de 80% do rebanho após 3 a 4 semanas do início do surto (POSTMA; CARFAGNINI; MINATEL, 2008), ocasionando diminuição do ganho de peso e da produção de leite dos animais infectados, além de elevados custos com o tratamento. A caracterização da CIB pode ser feita por meio de seus sinais clínicos na avaliação dos animais a campo ou em confinamento.

I. Sinais clínicos da Ceratoconjuntivite Infecciosa Bovina

Os animais acometidos apresentam manifestações clínicas que iniciam com lacrimejamento, fotofobia, edema e opacidade de córnea. Os animais não tratados ou que não apresentam cura espontânea neste estágio, frequentemente evoluem para ulceração de córnea, podendo desenvolver cegueira temporária e diferentes graus de cicatrização após a recuperação. A ruptura da córnea, em casos severos, resulta em cegueira completa e permanente (CHANDLER; BAPTISTA; TURFREY, 1979; POSTMA; CARFAGNINI; MINATEL, 2008; ALEXANDER, 2010). Animais seriamente comprometidos podem apresentar dor intensa, perda de apetite e perda de peso (BAPTISTA, 1979).

Carmo *et al.* (2011) registraram, em um surto de CIB, a evolução da doença em vinte bezerros na região central do Rio Grande do Sul. Os sinais clínicos observados nesse surto caracterizavam a doença desde o seu estágio inicial, com lacrimejamento e formação de focos milimétricos brancos e opacos no centro da córnea, até os estágios mais avançados, caracterizados por ceratocone, ruptura e cegueira. A figura 14 apresenta a evolução dos sinais clínicos da CIB em um bezerro.

Figura 14 – Evolução dos sinais clínicos em um bezerro afetado pela CIB.



Fonte: Carmo *et al.* (2011).

Observando a figura 14, Carmo *et al.* (2011) identificaram os seguintes aspectos:

- figura 14(A): dois pequenos focos opacos, com úlceras rasas ao centro, são observados na porção central da córnea e há hiperemia da conjuntiva bulbar;
- figura 14(B): a opacidade atinge quase toda a superfície da córnea e é circundada por um halo vermelho de hiperemia;
- figura 14(C): conificação da córnea causada pela CIB;
- figura 14(D): ulceração completa da córnea.

II. Diagnóstico da Ceratoconjuntivite Infecciosa Bovina

As lesões características da CIB, que se originam da área central da córnea e progridem de forma centrífuga, facilitam o diagnóstico pelo especialista. Porém, o diagnóstico conclusivo depende do isolamento e identificação de *Moraxella bovis* em laboratório por meio da coleta do exsudato conjuntival de animais em fase inicial da doença (ANGELOS *et al.*, 2007).

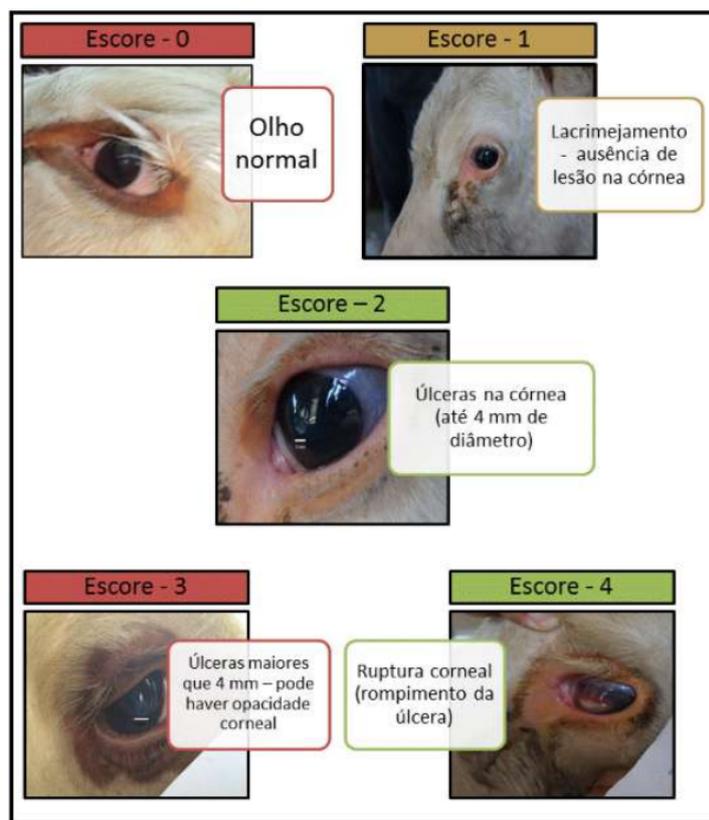
As amostras devem ser coletadas e semeadas em placas de ágar sangue o mais rápido possível, preferencialmente no campo, e posteriormente, mantidas e incubadas a 35°C por 48-72 horas. Se não for possível, a amostra deverá ser colocada em água destilada estéril para prevenir dessecação e processadas dentro de 2 horas. Pode-se utilizar a refrigeração de amostras por, no máximo, 24 horas antes de serem semeadas. Pode-se

também realizar a coleta com *swab* e adição de soro equino ou ainda com meio de Stuart por até 72 horas (QUINN *et al.*, 2005).

Contudo, apesar de ser conclusivo, o diagnóstico laboratorial é demorado e custoso. Assim, a forma mais comum e rápida de diagnosticar a CIB é por meio da avaliação do especialista a campo, analisando os sinais clínicos apresentados pelos animais, podendo ou não, atribuir escores de identificação dos estágios da doença.

Comin *et al.* (2016) descrevem em sua metodologia uma forma de identificar os animais doentes e os saudáveis pertencentes ao mesmo lote, e propõem um sistema simplificado de escores para a avaliação de um surto de CIB, o qual é baseado no guia de coleta de dados de ceratoconjuntivite bovina infecciosa (GASPAR *et al.*, 2016). A figura 15 apresenta os escores para identificação dos estágios da CIB. Desta forma, o especialista pode utilizar o método de escores para catalogar informações dos bovinos em um rebanho, atribuindo o estágio que a doença se encontra em cada olho do animal.

Figura 15 – Escores para identificação da CIB



Fonte: Comin *et al.* (2016).

Além disso, por se tratar de uma doença altamente contagiosa, a identificação de animais doentes no início do surto pode ser preponderante para o isolamento e tratamento,

evitando a disseminação da doença no rebanho.

Alguns casos de CIB apresentam resolução espontânea. Entretanto, na maioria dos animais acometidos, se não for estabelecido um tratamento eficaz, há a ocorrência de graves danos à córnea, podendo acarretar em cegueira irreversível (POSTMA; CARFAGNINI; MINATEL, 2008). Animais que se recuperam da infecção, estando esta em um estágio avançado, podem apresentar cicatrizes permanentes na córnea e até perda da visão do olho afetado (O'CONNOR *et al.*, 2006).

Atualmente, as duas principais estratégias de prevenção da doença em rebanhos são dirigidas para o controle de *Musca autumnalis*, principal vetor e para a imunização de animais suscetíveis por meio de vacinação (TURNES, 2003).

2.4 Diagnóstico por Imagem

Técnicas de diagnóstico por imagem são importantes no tratamento de animais, auxiliando na determinação de diversas patologias, tratamentos e prognósticos (HAN; HURD, 2007). Segundo Thrall (2014), as técnicas mais utilizados são: radiologia, ultrassonografia, ecocardiografia, endoscopia e tomografia computadorizada.

A escolha da técnica a ser utilizada depende da análise clínica do médico veterinário e, muitas vezes, é necessário mais de um exame para se chegar a um diagnóstico preciso. Um método de exame complementar emergente e com bons resultados na medicina veterinária é a termografia infravermelha (LAHIRI *et al.*, 2012).

2.4.1 Termografia Infravermelha

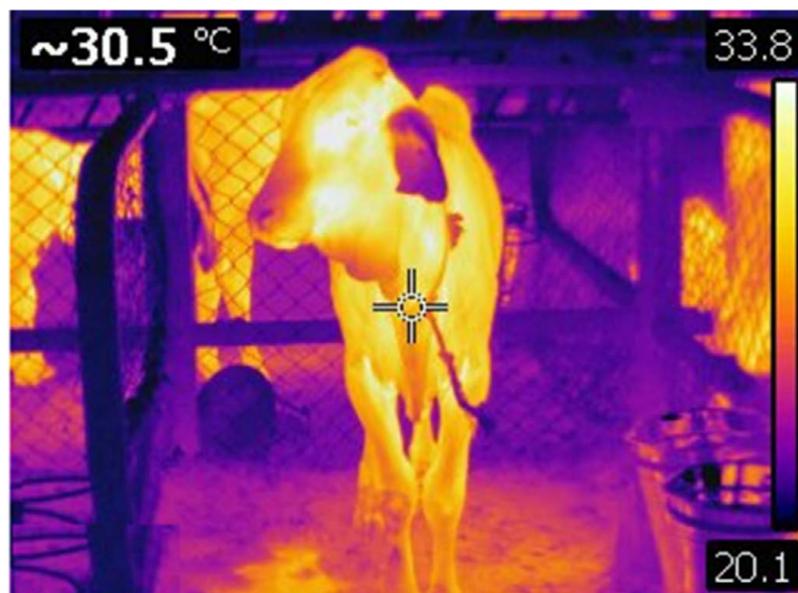
A termografia infravermelha (TIV) é um método não invasivo e indireto que possui aplicações na medicina veterinária, produção animal e também nas pesquisas científicas. A utilização de métodos invasivos para a coleta de dados podem produzir falsos resultados por desencadarem respostas ansiogênicas (STEWART *et al.*, 2008; ALVES *et al.*, 2016), assim a TIV aparece como uma alternativa promissora.

O princípio da termografia infravermelha é fundamentado nas bases de que todos os corpos formados de matéria, ou massa, que possuam temperatura acima de zero emitem radiação infravermelha que pode ser mensurada e correlacionada com a temperatura corporal (KNÍŽKOVÁ *et al.*, 2007). A radiação é uma forma de perda de calor por raios

infravermelhos, envolvendo a transferência de calor de um objeto para outro sem contato físico. A emissividade da pele é um fator importante na determinação da sua temperatura e, por meio da avaliação da temperatura superficial, é possível avaliar o estado físico e saudável dos seres vivos (CHIU *et al.*, 2005; BOUZIDA; BENDADA; MALDAGUE, 2009).

As câmeras térmicas captam a radiação infravermelha emitida pela superfície, convertem-na em sinais radiométricos e criam uma imagem térmica que representa a distribuição de temperatura superficial do corpo (INCROPERA; DEWITT; BERGMAN, 2000). No termograma, cada cor expressa a faixa de temperatura específica, relacionada a uma escala definida, por exemplo graus celsius (LUDWIG *et al.*, 2010). Os dados obtidos por digitalização são processados por computador, proporcionando análise detalhada da temperatura por meio da mensuração e análise da temperatura absoluta, máxima, média e mínima da região de interesse. A figura 16 apresenta um registro termográfico de um bezerro, onde é possível notar que as narinas e orelhas são extremidades mais frias e entorno dos olhos e região posterior da boca como regiões mais quentes.

Figura 16 – Registro termográfico de um bezerro.



Fonte: Leão *et al.* (2015).

A TIV tem ganhado cada vez mais importância por ser uma técnica não invasiva e segura tanto para o animal quanto para o aplicador, que é capaz de detectar mudanças de temperatura corporal de forma eficiente (REKANT *et al.*, 2016). Uma das vantagens dessa técnica reside no fato de não haver necessidade de se conter o animal, ou de usar

sedativos, nem do contato físico direto, já que o termograma é capturado à distância, gerando menor alteração fisiológica e maior confiabilidade dos dados gerados (GODYŃ; HERBUT; WALCZAK, 2013).

I. Termografia Infravermelha como método de auxílio nos diagnósticos

A termografia é uma técnica de registro gráfico em que são detectados padrões térmicos gerados pela emissão infravermelha de calor da superfície corporal (INFERNUSO *et al.*, 2010). Assim, é possível detectar locais na pele que demonstram anormalidades de temperatura, principalmente em áreas vascularizadas, denominadas de pontos quentes (do inglês, *hot spots*), que podem ser observados em casos de inflamação aguda. Em contrapartida, os pontos frios (do inglês, *cold spots*), podem ser observados em regiões que apresentem necrose (BAILEY; MARR; ELLIOTT, 2004).

Segundo Simon *et al.* (2006), um dos sinais cardiais da inflamação é o calor. Com a utilização do exame termográfico é possível observar os indícios do processo inflamatório antes mesmo que os sinais clínicos apareçam no paciente. O calor da superfície corporal é baseado na circulação local e, portanto, variações na temperatura podem indicar processos de ruptura da homeostase (VIANNA; CARRIVE, 2005). Assim, a TIV, torna-se uma ferramenta capaz de evidenciar alterações da perfusão sanguínea, tais como inflamações, tumores, fibroses, neuropatias ou isquemias. Permite o diagnóstico de problemas relacionados a tendões, ligamentos, articulações, músculos e ossos, desde que os últimos sejam cobertos por fina musculatura (BRIOSCHI; MACEDO; MACEDO, 2003).

Na medicina veterinária, o exame termográfico é empregado desde 1970, sendo que inicialmente só era utilizado como forma de detecção de lesões inflamatórias em equinos de corrida (ÇETİNKAYA; DEMİRUTKU, 2012). Entretanto, nos últimos anos, com os avanços alcançados no aprimoramento do aparelho de termografia, e consequentemente redução dos custos dos equipamentos, o seu uso encontra-se em expansão (ROBERTO; SOUZA, 2014). Embora seja uma tecnologia emergente, apresenta alguns benefícios em sua utilização. Lahiri *et al.* (2012) ressaltam que este procedimento não é indicado para a realização de um diagnóstico definitivo, e sim como um método de exame complementar utilizado para auxiliar o diagnóstico clínico e a tomada de decisão.

Desta forma, observa-se que a TIV tem sido utilizada na medicina veterinária como complemento importante de outras modalidades de diagnóstico por imagem,

como a tomografia computadorizada. Contudo, em alguns casos, a TIV demonstra-se mais eficiente ao detectar, de forma precoce, doenças em seus estágios iniciais, o que muitas vezes não é alcançado com a utilização de outras técnicas (TURNER; PANSCH; WILSON, 2001; ROBERTO; SOUZA, 2014). Na seção seguinte, são apresentados alguns trabalhos que utilizaram a TIV como forma de diagnóstico de doenças na medicina veterinária.

2.5 Trabalhos Relacionados

Nesta seção são discutidos alguns trabalhos importantes para o entendimento do que tem sido pesquisado em termos da utilização da termografia infravermelha e redes neurais convolucionais para o diagnóstico de alterações sistêmicas e como a integração dessas tecnologias podem colaborar para um avanço neste aspecto.

A metodologia adotada no processo de busca dos trabalhos iniciou por uma pesquisa nas bases de dados do *Congreso Argentino de AgroInformática* (CAI), Congresso Brasileiro de Agroinformática (SBIAgro), *IEEE Digital Library*, Biblioteca Digital Brasileira de Teses e Dissertações (BDTD), *Science Direct* e no repositório de Acesso Livre à Informação Científica da Embrapa (ALICE). A fim de buscar trabalhos correspondentes ao estado da arte, o período escolhido foi entre os anos de 2016 e 2019.

Além disso, este trabalho visa verificar a potencialidade de redes neurais convolucionais em detectar sinais clínicos da CIB utilizando como dados de entrada imagens termográficas da região ocular bovina. Desta forma, justifica-se o uso das *strings* de busca “redes neurais convolucionais ceratoconjuntivite” e “imagens termográficas ceratoconjuntivite”, além de suas correspondentes em inglês “*convolutional neural networks keratoconjunctivitis*” e “*thermographic images keratoconjunctivitis*”, durante a busca nas bases de dados. Nas buscas realizadas em anais de eventos, foi utilizada a ferramenta de localizar e os termos das *strings* de busca foram utilizados separadamente. Já nas bases com ferramenta de busca automatizadas foram utilizadas as *strings*. Os resultados encontrados estão detalhados na tabela 2.

Tabela 2 – Resultados encontrados durante o primeiro levantamento bibliográfico

<i>String</i> de busca	Bases de dados						Trabalhos selecionados
	CAI	SBIAgro	IEEE	BDTD	Science Direct	ALICE	
redes neurais convolucionais ceratoconjuntivite	2	6	0	41	0	15	0
<i>convolutional neural networks keratoconjunctivitis</i>	3	1	21	42	191	22	0
imagens termográficas ceratoconjuntivite	1	0	0	55	0	33	1
<i>thermographic images keratoconjunctivitis</i>	6	0	113	41	75	22	0

Fonte: Autor (2019).

Após a consolidação das buscas, foi realizada a leitura do título dos trabalhos encontrados. Esse procedimento teve como finalidade identificar os objetivos de cada um. Os trabalhos que não estavam relacionados com os objetivos deste, foram excluídos da lista de seleção. Após isso, foi realizada a leitura do resumo, a fim de identificar os objetivos e resultados dos trabalhos restantes. Ao final deste processo, os trabalhos selecionados foram armazenados e uma leitura detalhada foi realizada.

De maneira geral, não foram encontrados trabalhos na revisão da literatura que tenham utilizado especificamente em sua metodologia redes neurais convolucionais para o reconhecimento da ceratoconjuntivite infecciosa bovina (CIB) utilizando imagens termográficas, o qual é o tema base deste trabalho. Tampouco, trabalhos que utilizaram redes neurais convolucionais para diagnóstico por imagem de outras doenças em bovinos.

Contudo, presumindo-se que redes neurais convolucionais, pelo sucesso que demonstram atualmente na identificação de padrões em imagens, poderiam ser aplicadas ao reconhecimento dos sinais clínicos da CIB utilizando imagens termográficas da região ocular bovina, foi realizado um novo levantamento bibliográfico nas mesmas bases de dados. O objetivo desta nova pesquisa foi verificar o potencial das RNC no reconhecimento de padrões em imagens termográficas. As novas *strings* de busca foram: “redes neurais convolucionais imagem térmica”, “*convolutional neural networks thermal image*”, “*deep learning thermal image*”, “diagnóstico imagem redes neurais”, “*diagnostic imaging neural networks*”, “reconhecimento padrões imagem térmica” e “*pattern recognition thermal image*”. Os resultados encontrados estão detalhados na tabela 3.

Tabela 3 – Resultados encontrados durante o segundo levantamento bibliográfico

<i>String de busca</i>	Bases de dados						Trabalhos selecionados
	CAI	SBIAgro	IEEE	BDTD	Science Direct	ALICE	
redes neurais convolucionais imagem térmica <i>convolutional neural networks</i> <i>thermal image</i>	2	6	0	80	0	17	1
<i>deep learning thermal image</i>	2	3	65	181	2832	22	5
diagnóstico imagem redes neurais <i>diagnostic imaging</i> <i>neural networks</i>	4	9	0	15	0	16	1
reconhecimento padrões imagem térmica <i>pattern recognition</i> <i>thermal image</i>	3	10	578	3	9608	11	10
	2	6	0	13	2	1	1
	2	6	82	2	8816	24	6

Fonte: Autor (2019).

Os trabalhos selecionados nesta busca, estão relacionados as duas principais subáreas deste trabalho, as quais têm um papel fundamental na construção da metodologia proposta: i) redes neurais convolucionais para reconhecimento de padrões em imagens termográficas; ii) termografia infravermelha para detecção de doenças.

Redes neurais convolucionais são uma ferramenta poderosa que podem aprender automaticamente recursos efetivos a partir de dados brutos. Imagens termográficas fornecem uma gama de informações relevantes sobre um determinado objeto, as quais podem ser extraídas e interpretadas por tais métodos computacionais.

De acordo com a literatura atual, a união dessas técnicas tem sido utilizada para reconhecimento de padrões e automatização de processos. Wu, Peng e Chen (2016) utilizaram RNC no desenvolvimento de um sistema capaz de realizar o reconhecimento facial utilizando imagens térmicas. Os resultados alcançados obtiveram uma taxa de acerto superior a metodologias tradicionais, as quais foram aplicadas a mesma base de imagens. Da mesma forma, Janssens *et al.* (2018) utilizaram RNC para investigar sua aplicação no reconhecimento de imagens térmicas para detectar automaticamente falhas de máquina e previsão do nível de óleo em uma planta industrial. Os resultados indicam que a metodologia empregada consegue identificar corretamente falhas no sistema com até 95% de precisão, sem exigir qualquer conhecimento detalhado sobre a física subjacente e, assim, ter o potencial de simplificar o monitoramento de condições usando dados complexos de sensores.

As RNC constituem uma técnica recente para processamento de imagens e

análise de dados, com resultados promissores. Com isso, essa abordagem tem sido amplamente utilizada em diversas áreas do conhecimento na resolução ou automação de atividades, bem como na agricultura e pecuária. Na agricultura, há trabalhos nos quais os autores propõem sistemas para diagnosticar doenças em plantas a partir da análise de imagens das folhas (SLADOJEVIC *et al.*, 2016; MOHANTY; HUGHES; SALATHÉ, 2016; MAHLEIN, 2016); sistemas de irrigação inteligentes baseados na análise de imagens térmicas (ROOPAEI; RAD; CHOO, 2017); classificação da cobertura do solo e identificação de culturas baseados em imagens aéreas (RUSSWURM; KÖRNER, 2017; REBETEZ *et al.*, 2016); classificação e fenotipagem de plantas usando imagens estáticas individuais das plantas (NAMIN *et al.*, 2018). Na pecuária, o uso de RNC tem sido utilizado na análise de imagens para a estimativa da condição corporal de bovinos (ALVAREZ *et al.*, 2018; BRAGAMONTE *et al.*, 2018); no desenvolvimento de sistemas de rastreamento de gado baseado em análise de imagens térmicas (KIM; CHO; LEE, 2017; GARDENIER; UNDERWOOD; CLARK, 2018); na análise de imagens para identificação de espécies ou animais individuais com base em suas características (KUMAR *et al.*, 2018).

De acordo com a literatura atual, a utilização da termografia infravermelha na medicina veterinária tem sido aplicada principalmente como ferramenta de apoio ao diagnóstico e prevenção de doenças, por meio da obtenção de dados físicos dos animais de forma não invasiva (LEÃO *et al.*, 2015). A interpretação desses dados pode ser feita por meio de um sistema tecnológico específico ou simplesmente pela análise empírica de um especialista. Dentre os trabalhos encontrados, percebe-se que a termografia infravermelha tem sido utilizada mais vezes para detecção precoce de doenças infecciosas (SCHAEFER *et al.*, 2004; RAINWATER-LOVETT *et al.*, 2009); detecção de doenças respiratórias em bovinos (SCHAEFER *et al.*, 2007; SCHAEFER *et al.*, 2012); detecção da mastite bovina (COLAK *et al.*, 2008; HOVINEN *et al.*, 2008; POLAT *et al.*, 2010; REZENDE *et al.*, 2017); avaliação de comportamento e bem estar animal, incluindo análise da temperatura ocular (KOTRBA *et al.*, 2007; STEWART *et al.*, 2008; STEWART *et al.*, 2010).

Em relação ao uso da termografia infravermelha como forma de coleta de dados com a finalidade de diagnosticar a ceratoconjuntivite infecciosa bovina, foi encontrado na literatura, especificamente, um trabalho que sugere essa abordagem. Lopes *et al.* (2018) propõem avaliar a utilização de imagens termográficas como forma de visualizar a variação da temperatura ocular durante o desenvolvimento da CIB em bovinos da raça Hereford. Neste estudo, os animais foram infectados e avaliados de forma experimental

em cinco momentos. No dia 0, os animais foram avaliados em seu estado natural, ou seja, antes da infecção pela bactéria da CIB. A partir da infecção, foi coletada a temperatura ocular no dias 2,3,6 e 8, por meio das imagens termográficas. Os resultados deste experimento indicam que a temperatura ocular aumenta com a infecção, retornando aos níveis basais após tratamento.

Diante do exposto, é possível identificar, que a utilização de RNC na resolução de problemas que demandam de conhecimento prévio, principalmente aqueles que envolvem análise de imagens, possui resultados promissores. Da mesma maneira, a utilização de imagens termográficas para obtenção de dados mostrou-se ser uma forma eficiente para a identificação precoce de doenças na medicina veterinária. Além disso, trabalhos em outras áreas do conhecimento demonstraram, com sucesso, a capacidade de união dessas técnicas para a resolução de problemas de reconhecimento de padrões e automação de processos. Desta forma, estima-se que a utilização de RNC na análise de imagens termográficas para o diagnóstico da CIB é uma tarefa viável e com ampla capacidade de sucesso, observada a literatura atual.

3 METODOLOGIA

Este capítulo visa apresentar a metodologia adotada na elaboração deste trabalho. Na seção 3.1 é apresentada a caracterização da pesquisa e seu enquadramento. Em seguida, as fases da pesquisa são apresentadas e discutidas na seção 3.2. Por fim, a base de imagens disponível e as ferramentas que serão utilizadas na etapa de implementação são apresentadas na seção 3.3.

3.1 Caracterização da Pesquisa

Segundo Pereira *et al.* (2018), a pesquisa científica pode ser classificada tanto da parte teórica quanto da parte prática. No que diz respeito à parte teórica, podemos classificá-la quanto à natureza, aos objetivos e a abordagem do problema. Já do ponto de vista prático, podemos classificá-la quanto aos procedimentos técnicos utilizados durante seu ciclo de vida (FONSECA, 2002).

Neste contexto, a caracterização desta pesquisa está fundamentada da seguinte forma, como descreve Pereira *et al.* (2018):

I. Da parte teórica:

- Quanto sua natureza, está classificada na modalidade de pesquisa aplicada. Assim, este trabalho tem como objetivo gerar conhecimento de aplicação prática para um problema específico, envolvendo interesses locais.
- Quanto aos objetivos, visto que não há relatos na literatura atual sobre o desenvolvimento de ferramentas computacionais para a detecção da ceratoconjuntivite infecciosa bovina, busca-se de forma exploratória gerar dados e informações sobre o tema de interesse, possibilitando pesquisas futuras.
- Quanto à abordagem do problema, busca-se de forma quantitativa analisar os dados gerados, utilizando técnicas estatísticas para extrair informações que possam gerar conclusões acerca do problema em questão.

II. Da parte prática:

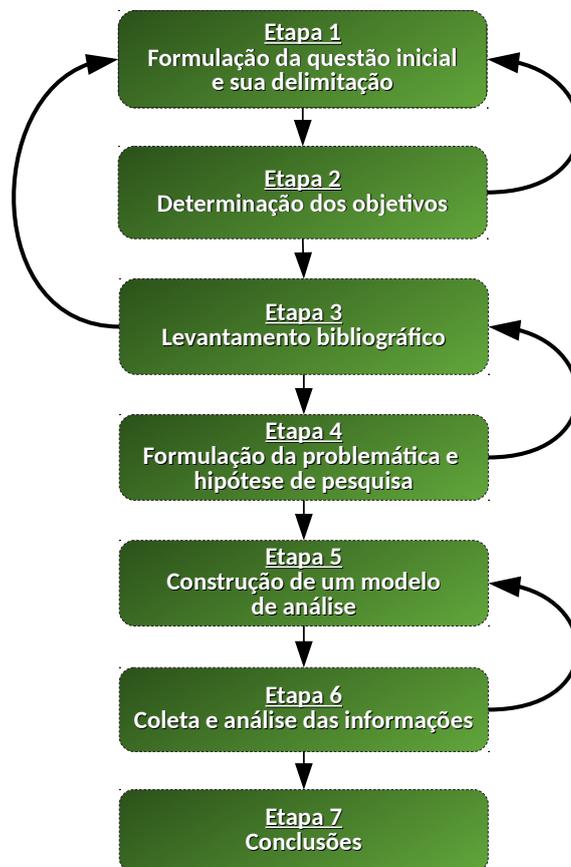
- No que diz respeito aos procedimentos técnicos, este trabalho é fundamentado na modalidade de pesquisa experimental. A pesquisa experimental ocorre

quando há a delimitação de um objeto de estudo, a seleção das variáveis que seriam capazes de influenciá-lo e a definição das formas de controle e de observação que a variável produz no objeto (PEREIRA *et al.*, 2018). Neste caso, temos como objeto de estudo as imagens termográficas da região ocular bovina, na qual deseja-se, por meio das redes neurais convolucionais, identificar os sintomas da ceratoconjuntivite infecciosa bovina. Após os experimentos, deseja-se analisar, comparar e tirar conclusões sobre os resultados obtidos.

3.2 Fases da Pesquisa

Segundo Cervo e Científica (2002), a pesquisa científica é composta por sete fases principais, sendo elas: i) a formulação da questão inicial ou escolha do tema, além da sua delimitação; ii) determinação dos objetivos; iii) formulação da problemática e hipótese de pesquisa; iv) levantamento bibliográfico; v) construção de um modelo de análise; vi) coleta e análise das informações; e vii) conclusões. A Figura 17 apresenta um fluxograma com as fases da pesquisa.

Figura 17 – Fluxograma das fases da pesquisa.



Fonte: Autor (2019).

O processo de desenvolvimento deste trabalho está embasado nas etapas apresentadas na Figura 17. Desta forma, este trabalho foi conduzido da seguinte forma:

- **Etapa 1 – Formulação da questão inicial e sua delimitação**

Inicialmente foi estabelecida a seguinte questão inicial: **“É possível desenvolver uma ferramenta computacional capaz de auxiliar o médico veterinário no diagnóstico da ceratoconjuntivite infecciosa bovina, utilizando imagens termográficas como dados de entrada?”**

- **Etapa 2 – Determinação dos objetivos**

Nesta etapa, foram definidos os objetivos gerais e específicos, os quais foram descritos no capítulo 1.

- **Etapa 3 – Levantamento bibliográfico**

A partir da etapa 2, foi realizado um levantamento bibliográfico objetivando,

primeiramente, observar se já haviam sido desenvolvidas pesquisas semelhantes por outros autores. A metodologia utilizada e os resultados desta etapa foram apresentados na seção 2.5, do capítulo 2. De modo geral, não foram encontrados trabalhos semelhantes nas bases de dados consultadas.

- **Etapa 4 – Formulação da problemática e hipótese de pesquisa**

Nesta etapa, a hipótese de pesquisa foi formulada, na qual presume-se que redes neurais convolucionais, pelo sucesso que demonstram atualmente na identificação de padrões em imagens, podem ser aplicadas ao reconhecimento dos sinais clínicos da CIB utilizando imagens termográficas da região ocular bovina. Desta forma, foi realizado um novo levantamento bibliográfico, nas mesmas bases de dados (Etapa 3), com o objetivo de verificar o potencial das RNC no reconhecimento de padrões em imagens termográficas. A metodologia adotada e os resultados encontrados estão descritos na seção 2.5, do capítulo 2. Os trabalhos encontrados indicam que a união dessas técnicas tem tido sucesso em outras áreas do conhecimento, potencializando a hipótese definida.

- **Etapa 5 – Construção de um modelo de análise**

Nesta etapa, foi realizada a construção de um conjunto de modelos de redes neurais convolucionais para verificar sua capacidade em reconhecer os sintomas da CIB em imagens termográficas da região ocular bovina. Esses modelos foram testados na base de imagens disponível e seus resultados computados.

- **Etapa 6 – Coleta e análise das informações**

A partir da análise dos resultados obtidos, foi possível verificar o potencial da hipótese de pesquisa e a satisfação dos objetivos almejados.

- **Etapa 7 – Conclusões**

Por fim, nesta etapa foram observadas as conclusões obtidas, as limitações encontradas, as principais contribuições e o planejamento de novos experimentos e avanços.

3.3 Material

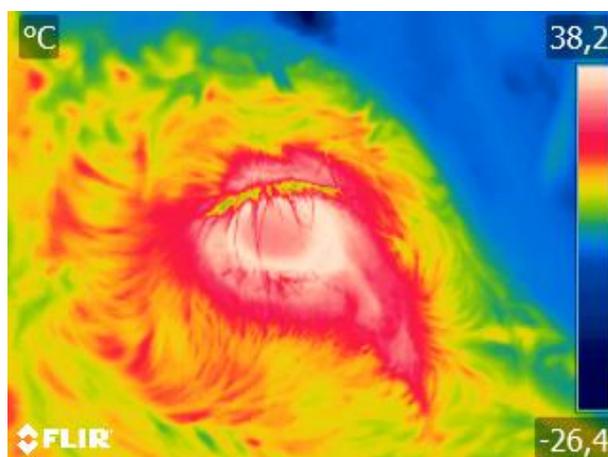
Nesta seção, a base de imagens disponível e as ferramentas que serão utilizadas na fase de implementação são apresentadas e detalhadas.

3.3.1 Base de imagens

A base de imagens disponível foi obtida pela Embrapa Pecuária Sul na qual os pesquisadores observaram o desenvolvimento da CIB em 11 animais da raça Hereford. Os registros termográficos foram realizados em cinco dias (dia 0, 2, 4, 6 e 8 pós infecção), sendo que no dia zero os animais foram observados sadios e nos dias seguintes já com a manifestação da doença em um dos olhos, que foi experimentalmente infectado ¹. Essa base é composta por 111 imagens termográficas da região ocular bovina, compactadas no formato JPEG, com dimensões de 320×240 pixels e três canais do espaço de cores RGB. As imagens foram produzidas utilizando uma câmera térmica da marca FLIR® modelo T300. Posteriormente, foram adicionadas 75 imagens termográficas da região ocular bovina, as quais são oriundas de uma visita técnica realizada pelos especialistas da Embrapa Pecuária Sul. Desta forma, a base de dados atual conta com 186 imagens termográficas da região ocular bovina.

A Figura 18 mostra uma imagem térmica da região ocular bovina que compõe a base de imagens.

Figura 18 – Imagem térmica da região ocular bovina.



Fonte: Autor (2019).

¹Procedimento aprovado pela CEUA/CPPSul nº 10/2016.)

As avaliações do progresso da doença foram realizadas por especialistas na modalidade de escores (de 0 a 4), conforme o Guia de Coleta de Dados de Ceratoconjuntivite Bovina Infecciosa (CBI) (GASPAR *et al.*, 2016). A tabela 4 mostra a classificação de cada escore de acordo com os sinais clínicos do animal no momento da avaliação.

Tabela 4 – Classificação dos escores de acordo com o sinal clínico apresentado pelo animal no momento da avaliação.

Escore	Sinal Clínico
0	Nenhum sinal clínico
1	Lacrimejamento (ausência de lesão na córnea)
2	Úlceras na córnea (até 4mm de diâmetro)
3	Úlceras na córnea maiores que 4mm (pode haver opacidade da córnea)
4	Ruptura corneal (rompimento da úlcera)

Fonte: Adaptada de Gaspar *et al.* (2016).

Após as avaliações dos especialistas, as informações foram armazenadas em uma planilha eletrônica, contendo a identificação do animal, o escore atribuído e o identificador da imagem para cada olho do animal. A Figura 19 apresenta um exemplo da planilha na qual as informações foram armazenadas. Neste exemplo, OD significa olho direito e OE olho esquerdo.

Figura 19 – Exemplo de planilha com as informações das avaliações realizadas pelos especialistas.

Avaliação Experimental				
Dia da avaliação	Escore CIB		ID Imagem Termográfica	
	OD	OE	OD	OE
0	0	0	32091	32090
	0	0	32093	32094

2	2	0	32096	32095
	3	0	32097	32098

4	3	0	32100	32999
	2	0	32101	32102

6	2	0	32106	32105
	2	0	32103	32104

8	3	0	32108	32107
	3	0	32109	32110

Fonte: Autor (2019).

3.3.2 Ferramentas

Para a construção dos métodos foram utilizadas as bibliotecas de código aberto para aprendizado de máquina *Tensorflow* (versão 1.5) e *Keras* (versão 2.2.4), ambas utilizadas na linguagem de programação Python. A escolha dessas ferramentas foi baseada em sua popularidade e eficiência quando comparado a outras estruturas de aprendizado profundo com distribuição em código aberto (RAMPASEK; GOLDENBERG, 2016; KOVALEV; KALINOVSKY; KOVALEV, 2016).

Tensorflow é uma ferramenta implementada pela Google[®] para construir e executar algoritmos de aprendizado de máquina. Essa ferramenta possibilita o uso de aceleração gráfica de processamento. Por esse entre outros motivos, *Tensorflow* é altamente aplicado em tarefas de *Deep Learning* (ABADI *et al.*, 2015). A implementação do *Tensorflow* possui uma API de alto nível que permite uma construção mais simples de modelos, abstraindo vários conceitos por trás do funcionamento da ferramenta.

Keras é um API, que significa um conjunto de rotinas e padrões de programação de alto nível especializada em redes neurais. Ele utiliza um *framework* de *Deep Learning* como base, podendo ser *Tensorflow*, *Theano* ou *CNTK*. Ele possibilita a rápida construção e utilização de redes neurais com funções e comandos simples que abstraem uma grande parte do funcionamento da *framework* base (CHOLLET *et al.*, 2015). O processo de treinar e inferir um modelo utilizando *Keras* consiste na utilização da API para a construção, aquisição e pré-processamento dos dados de entrada, treinamento do modelo e testes de validação. Por fim, esse modelo pode ser utilizado também para avaliar novas amostras do problema.

O computador utilizado na construção e validação dos métodos foi uma máquina com processador Intel[®] Xeon[®] Octa Core de 2.10Ghz, com 8Gb de memória RAM e portando uma GPU NVIDIA[®] Tesla C1060. O sistema operacional utilizado é o Linux Ubuntu na versão 18.04 LTS 64 bits.

4 ABORDAGEM PROPOSTA

Neste capítulo é apresentada a abordagem proposta para atingir os objetivos deste trabalho. Inicialmente, os procedimentos realizados para a preparação da base de imagens e a construção dos modelos de RNC são apresentados na seção 4.1. Em seguida, os testes realizados e os resultados obtidos são apresentados e discutidos nas seções 4.2 e 4.3, respectivamente.

4.1 Implementação

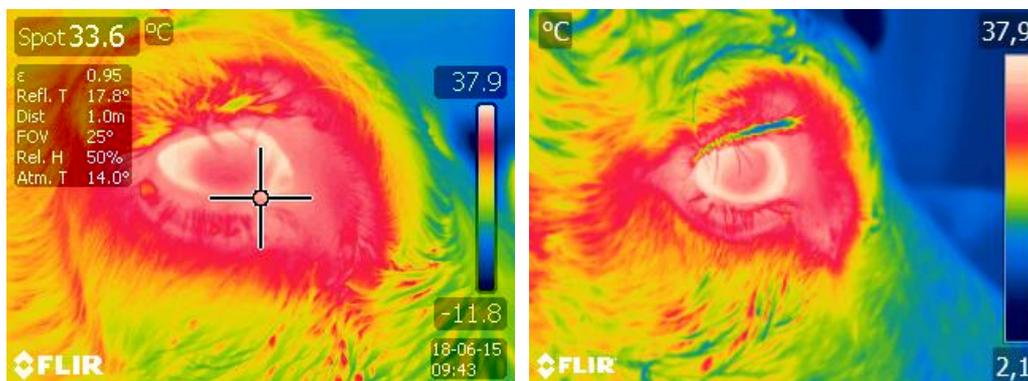
A implementação foi dividida em duas fases principais: i) pré-processamento, no qual é apresentada a manipulação dos dados disponíveis e a preparação destes para a etapa de treinamento e validação dos modelos; e ii) desenvolvimento dos modelos de RNC, no qual é apresentado o processo de desenvolvimento e validação dos mesmos.

4.1.1 Pré-processamento dos dados

Inicialmente, com base nas informações contidas na planilha de avaliação dos especialistas, as imagens foram separadas em duas classes. A primeira classe contém as imagens identificadas com presença dos sinais clínicos da CIB, classificadas pelos escores de 1, 2, 3 e 4. A segunda classe contém as imagens identificadas com ausência dos sinais clínicos da CIB, classificadas com o escore 0. Desta forma, a primeira classe (imagens de olhos infectados) dispõe de 75 imagens originais, já a segunda classe (olhos não infectados) dispõe de 111 imagens originais.

Como as imagens são oriundas de análises realizadas pela Embrapa, a maioria continha dados de temperatura em seu conteúdo. Com isso, o segundo passo do pré-processamento foi remover essas análises de temperaturas, as quais não são interessantes para este trabalho, podendo atrapalhar a extração de características pelas RNCs. Assim, utilizando o próprio software disponibilizado pela fabricante da câmera, o FLIR Tools[®], essas análises de temperaturas foram removidas das imagens originais. A figura 21(a) apresenta uma imagem termográfica da região ocular bovina com a análise de temperatura e a figura 21(b) apresenta outra imagem termográfica da região ocular bovina com a análise de temperatura removida.

Figura 20 – Imagem termográfica com análise de temperatura e imagem termográfica com a análise removida.



(a) Imagem com análise de temperatura

(b) Imagem com análise de temperatura removida

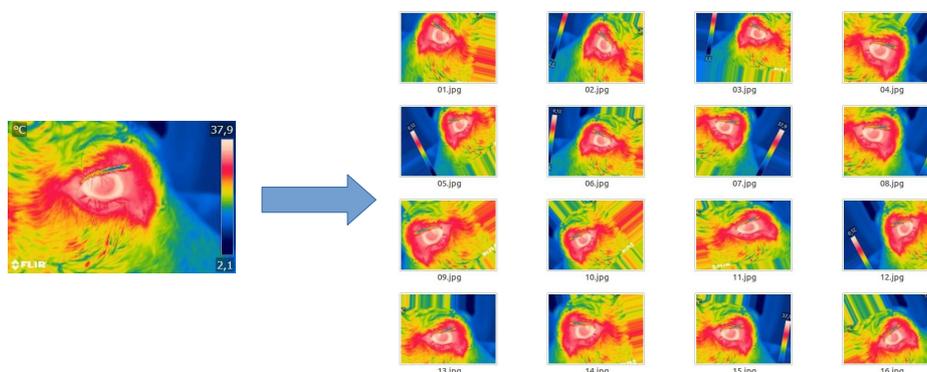
Fonte: Autor (2019).

Redes neurais convolucionais são amplamente utilizadas para reconhecimento de padrões em imagens digitais, porém necessitam de grandes volumes de dados para efetuar um treinamento eficiente e, posteriormente, classificar novas amostras de forma acurada (HAYKIN, 2007; GOODFELLOW *et al.*, 2016). Como a base de imagens disponível possui poucas amostras para cada classe, é desejável que a partir dessas imagens se construa um conjunto maior de amostras.

Assim, a próxima etapa na preparação dos dados é aplicar uma técnica conhecida como aumento de dados (do inglês, *data augmentation*), a qual tem sido utilizada em diversos trabalhos de reconhecimento de imagens utilizando aprendizagem profunda (PEREZ; WANG, 2017; HAN; LIU; FAN, 2018). Neste processo é utilizada a biblioteca Keras, a qual possui uma função destinada para isso (GULLI; PAL, 2017).

O processo de aumento de dados consiste em, a partir de uma imagem original, gerar outras imagens aplicando técnicas morfológicas sem perder as principais características da imagem original. Usualmente são utilizadas rotações e deslocamentos na imagem principal, gerando novas imagens, ou seja, neste processo por exemplo, a imagem original após a aplicação de uma rotação de 10° em sentido horário é considerada uma nova imagem. A figura 21, mostra um exemplo do processo do aumento de dados utilizando a biblioteca *Keras*, onde a partir de uma imagem são geradas 16 novas imagens.

Figura 21 – Processo de aumento de dados a partir de uma imagem utilizando a biblioteca Keras.

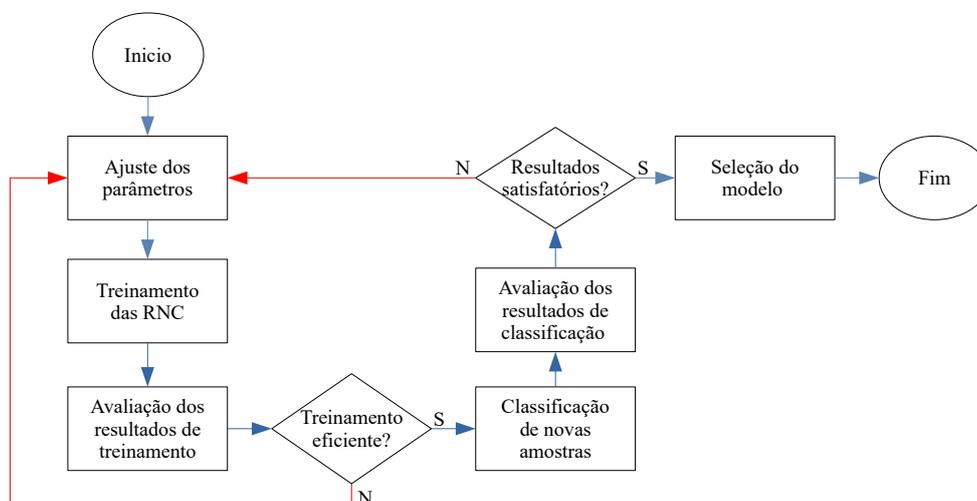


Fonte: Autor (2019).

4.1.2 Desenvolvimento dos modelos de Redes Neurais Convolucionais

Segundo Ponti e Costa (2018), o processo de desenvolvimento de uma rede neural convolucional para a interpretação e solução de novos problemas é um desafio, principalmente no que tange a busca pela arquitetura com melhor capacidade de abstração e generalização dos dados. Por vezes, é necessário testar várias configurações, ajustando os parâmetros de entrada, para obter um modelo adequado. A figura 22 exemplifica, por meio de um fluxograma, o processo de desenvolvimento e validação de uma modelo de RNC.

Figura 22 – Fluxograma do processo de desenvolvimento e validação de um modelo de RNC.



Fonte: Autor (2019).

Nesse sentido, buscou-se neste trabalho desenvolver diversos modelos de RNC, variando seus parâmetros de entrada, com o objetivo de construir arquiteturas distintas entre si. Posteriormente, essas arquiteturas foram treinadas e avaliadas em relação a capacidade de identificar os sintomas da CIB em imagens termográficas da região ocular bovina. Neste processo foi utilizada a linguagem de programação Python e as bibliotecas Keras e Tensorflow, as quais são detalhadas na seção 3.3, do capítulo 3.

4.2 Experimentos

No decorrer desta pesquisa, três experimentos foram realizados. No experimento inicial a metodologia proposta foi executada e os resultados avaliados. A partir da análise desses resultados, alterações na metodologia inicial foram realizadas, buscando o aperfeiçoamento do método proposto, o que deu origem ao segundo experimento. O terceiro experimento teve como objetivo potencializar os resultados do experimento anterior. As arquiteturas desenvolvidas, justificativas dos parâmetros de entrada e os resultados obtidos em cada um dos experimentos são vistos a seguir.

I. Primeiro experimento

O objetivo principal deste experimento foi diagnosticar os sintomas da CIB em imagens termográficas da região ocular bovina usando modelos de RNC, independentemente do escore que a doença apresente. Para isso, neste experimento foram utilizadas todas as imagens disponíveis, as quais foram separadas em duas classes principais: i) classe de olhos infectados (75 imagens); e ii) classe de olhos sadios (111 imagens). Em seguida, utilizando o processo de aumento de dados, uma nova base de imagens foi gerada, a qual possui um total de 4938 imagens termográficas da região ocular bovina, divididas em três agrupamentos utilizando a técnica da validação cruzada por meio do método *holdout*. A base de imagens gerada a partir do processo de aumento de dados e sua divisão são apresentadas na tabela 5.

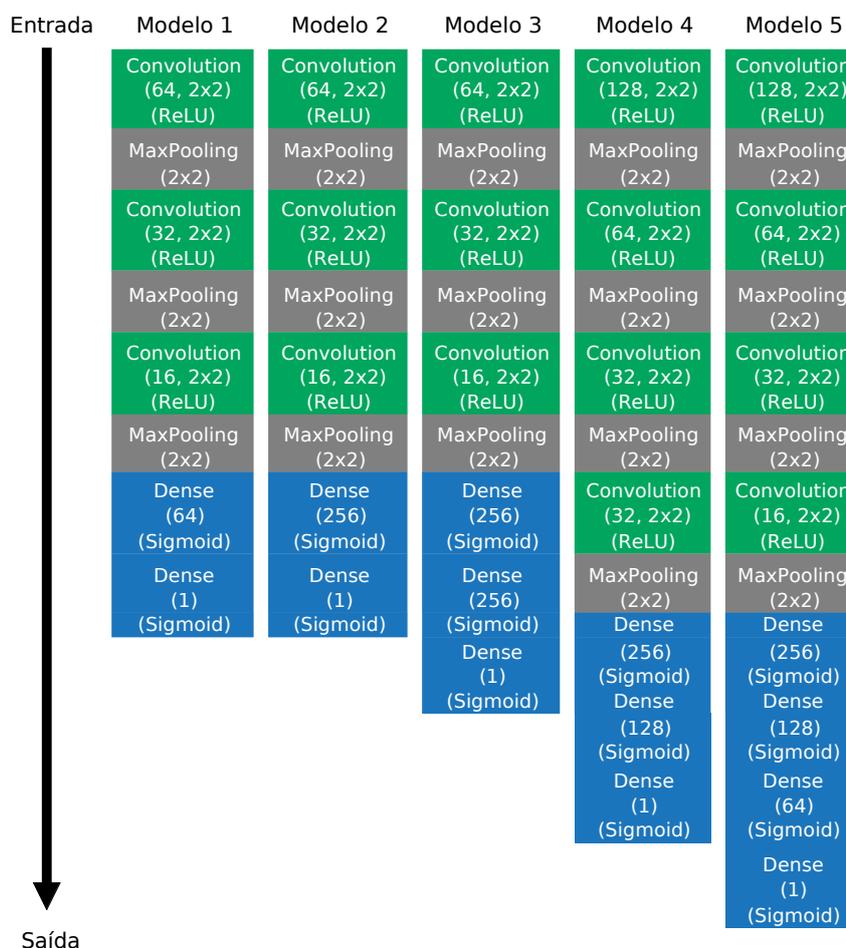
Neste experimento foram desenvolvidos cinco modelos distintos de RNC a fim de avaliar a capacidade de cada um deles em identificar os sintomas da CIB em imagens termográficas da região ocular bovina. A arquitetura de cada um dos modelos de RNC desenvolvidos é apresentada na figura 23.

Tabela 5 – Base de dados do primeiro experimento gerada após o processo de aumento de dados.

Agrupamento	Antes do processo de aumento de dados		Após o processo de aumento de dados	
	Imagens de olhos infectados	Imagens de olhos saudios	Imagens de olhos infectados	Imagens de olhos saudios
Treinamento	48	72	1750	1750
Teste	15	22	484	494
Validação	12	17	230	230
Total de imagens	75	111	2464	2474

Fonte: Autor (2019).

Figura 23 – Arquitetura dos modelos de RNC desenvolvidas para o primeiro experimento.



Fonte: Autor (2019).

Neste caso, os parâmetros de entrada entre a etapa de convolução e a etapa densa foram variados na tentativa de obter o modelo que melhor se adapte ao problema. A

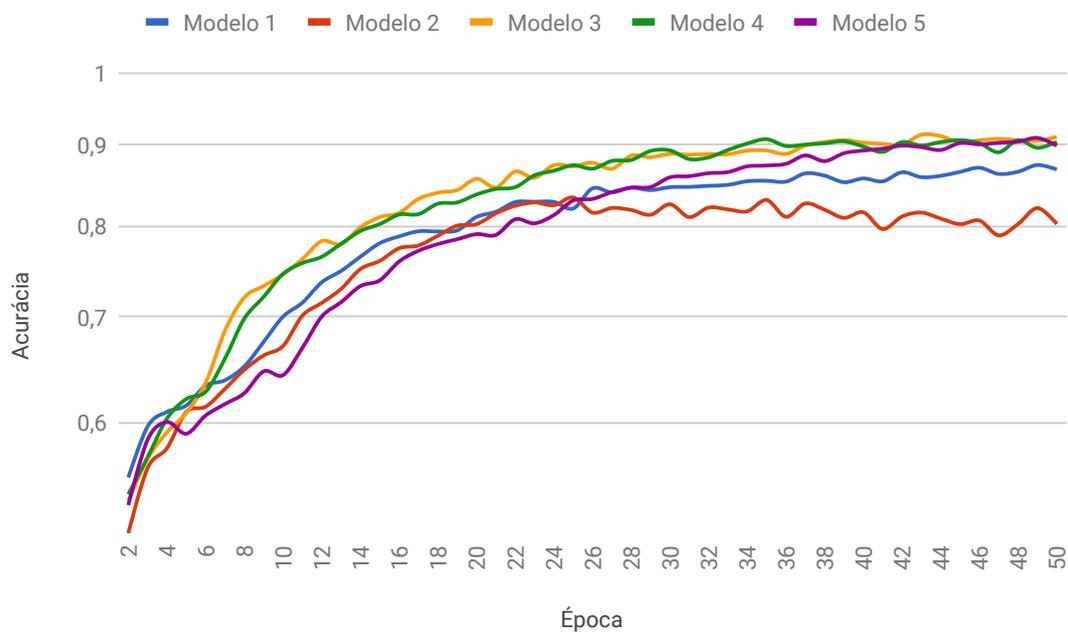
variação dos parâmetros observou a profundidade e complexidade da RNC. O Modelo 1 apresenta a RNC com a arquitetura mais simples com apenas três camadas convolutivas e uma camada densa, enquanto o Modelo 5 apresenta a arquitetura mais profunda com quatro camadas convolutivas e três camadas densas. Além disso, optou-se por utilizar *kernel* de convolução com tamanho 2×2 em todos os modelos. A utilização de *kernels* pequenos torna a extração de características mais refinada, uma vez que a cada passo do processo convolucional um novo pixel é gerado a partir de uma janela de pixels menor.

No treinamento dos modelos, de acordo com a tabela 5, o conjunto de imagens utilizado na etapa de treinamento é composto por dois agrupamentos, o primeiro contendo imagens de treino e o segundo contendo imagens de teste. O conjunto de treino é utilizado pela RNC para avaliar o desempenho do modelo durante seu treinamento, sendo a acurácia (Equação 1) utilizada como métrica de avaliação. O conjunto de teste é utilizado pela RNC para avaliar o desempenho do modelo quando novas amostras são apresentadas, neste momento a taxa de erro (Equação 2) é utilizada como métrica de avaliação. Em geral, a acurácia verifica a precisão do modelo enquanto que a taxa de erro penaliza o modelo quando este comete um erro no processamento de novas amostras. Nesta etapa, o melhor modelo será aquele que obtiver a maior taxa de acurácia juntamente com a menor taxa de erro, considerando uma escala de 0 a 1.

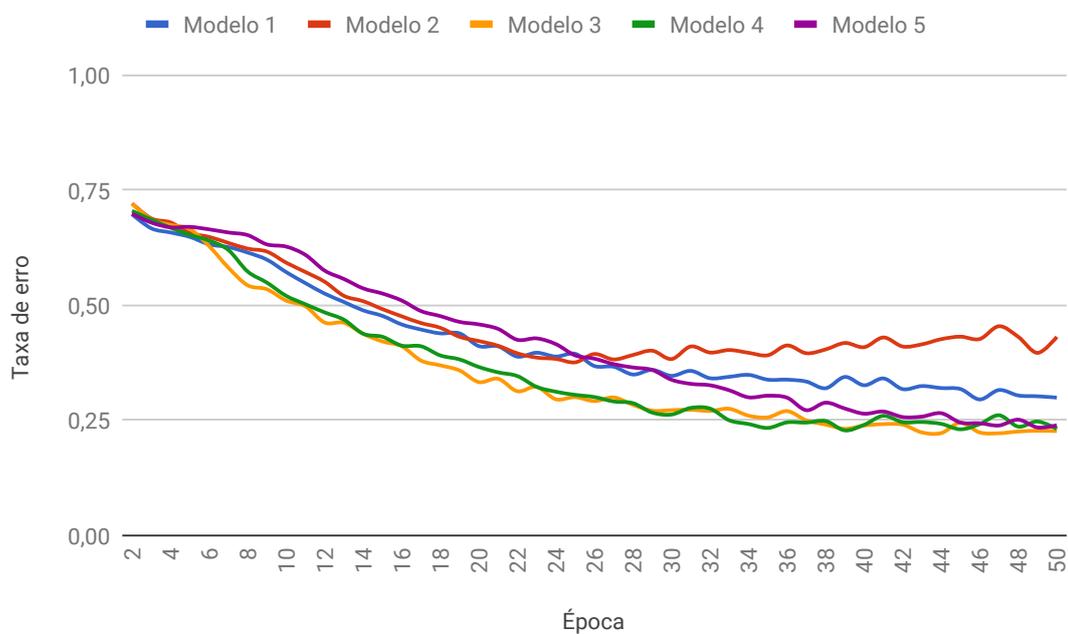
Em seguida, os modelos de RNC desenvolvidos foram submetidos a uma rotina de treinamento de 50 épocas cada. O número de épocas é determinado como uma condição de parada para o algoritmo de treinamento. Esse número pode ser variado, porém, foi mantida a mesma condição para todos os modelos para fins de comparação. Além disso, percebeu-se durante a etapa de treinamento que a curva de aprendizagem se mantém estável após percorridas 40 épocas de treinamento, após isso a variação de aprendizagem é muito pequena e o risco de ocorrer *overfitting* é acentuado. O conceito de *overfitting* foi descrito na subseção 2.2.3.1 do capítulo 2.

Os resultados da acurácia e taxa de erro obtidos por cada modelo na etapa de treinamento são apresentados na figura 24(a) e na figura 24(b), respectivamente.

Figura 24 – Resultados da etapa de treinamento dos modelos de RNC do primeiro experimento.



(a) Acurácia



(b) Taxa de erro

Fonte: Autor (2019).

Em relação ao desempenho dos modelos durante a etapa de treinamento, o qual é avaliado por meio da acurácia, os modelos 3, 4 e 5 obtiveram os melhores resultados, conforme pode ser visto na figura 24(a), indicando que arquiteturas mais profundas tem vantagem em relação a arquiteturas mais simples. O modelo 2 foi o que obteve o pior resultado nesta etapa, apresentando problemas de generalização a partir da época de número 23, quando sua taxa de erro começa a aumentar (figura 24(b)).

Após a etapa de treinamento é necessário avaliar os modelos desenvolvidos em relação a sua capacidade de generalização. Para isso, foi utilizada uma parte do conjunto de imagens totalmente desconhecidas pelos modelos de RNC, exclusivamente destinadas a esta etapa, como pode ser visto na tabela 5.

Os cinco modelos de RNC foram submetidos a análise da base de imagens citada e os resultados computados em uma matriz de confusão (tabela 1) onde os valores de VP, FP, FN e VN foram obtidos para cada predição. A partir desses valores é possível validar os modelos calculando as métricas de avaliação da acurácia, taxa de erro, sensibilidade e especificidade. A descrição das métricas de avaliação utilizadas pode ser vista com mais detalhes na subseção 2.2.2.1, item II, do capítulo 2.

Os resultados obtidos por cada modelo de RNC na etapa de validação deste experimento são apresentados na tabela 6.

Tabela 6 – Resultados obtidos pelos modelos de RNC na etapa de validação do primeiro experimento.

Métricas	Modelos de RNCs				
	1	2	3	4	5
VP	161	204	141	144	170
FP	89	113	68	25	34
VN	141	117	162	205	196
FN	69	26	89	86	60
Acurácia	0,6565	0,6978	0,6587	0,7587	0,7957
Taxa de erro	0,3435	0,3022	0,3413	0,2413	0,2043
Sensibilidade	0,7000	0,8870	0,6130	0,6261	0,7391
Especificidade	0,6130	0,5087	0,7043	0,8913	0,8522

Fonte: Autor (2019).

Os resultados apresentados na fase de treinamento indicam o comportamento dos modelos em relação a sua capacidade de aprendizado, mas não garantem os mesmos resultados em predições futuras. Durante a validação dos modelos, isto é, quando novas amostras são apresentadas a rede, percebe-se que o modelo 2 obteve acurácia superior ao modelo 3. Nesta etapa, o modelo 5 tem destaque por três motivos: maior acurácia; menor

taxa de erro; e equilíbrio na capacidade de prever valores de VP e VN. Desta forma, o modelo 5 é considerado o mais apto a compor uma ferramenta de diagnóstico automático para os sintomas da CIB.

II. Segundo experimento

Neste experimento, o objetivo principal é a identificação precoce da CIB. Para isso, com base nas informações contidas na planilha de avaliação dos especialistas, foram selecionadas apenas as imagens classificadas com os escores 0 e 1, as quais foram separadas em duas classes. A primeira classe contém 33 imagens identificadas com escore 1 e a segunda classe contém 111 imagens com escore 0. A ideia principal deste experimento é explorar a capacidade dos modelos de RNC em detectar sinais da CIB em imagens termográficas da região ocular bovina antes mesmo dos sinais clínicos aparecerem, por isso os escores 2, 3 e 4 foram removidos.

As classes descritas foram divididas em três agrupamentos: treinamento, teste e validação. Essa divisão foi baseada na técnica da validação cruzada utilizando o método *holdout*, o qual garante a exclusividade dos dados que serão empregados na avaliação dos modelos. Em seguida, foi aplicada a técnica de aumento de dados nos agrupamentos de treino e teste. A nova base de dados gerada a partir do processo de aumento de dados é apresentada na 7.

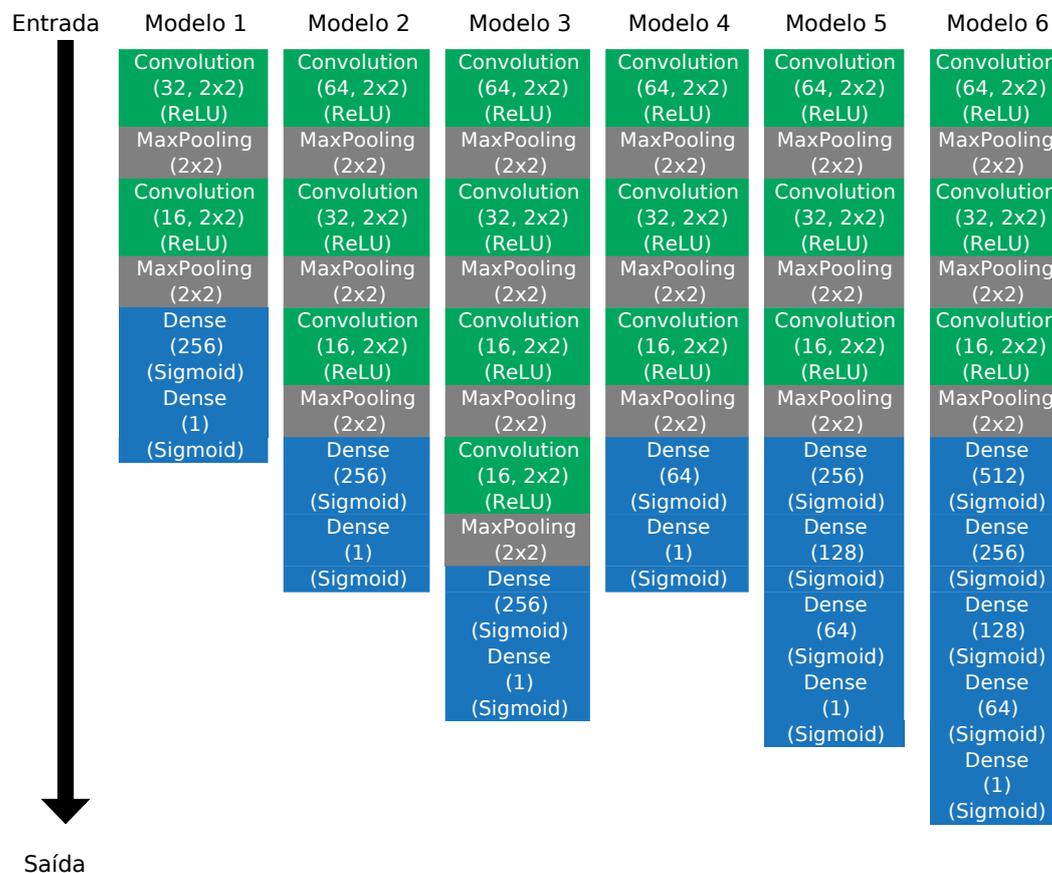
Tabela 7 – Base de imagens do segundo experimento gerada a partir do processo de aumento de dados.

Agrupamento	Antes do processo de aumento de dados		Após o processo de aumento de dados	
	Imagens de olhos infectados	Imagens de olhos sadios	Imagens de olhos infectados	Imagens de olhos sadios
Treinamento	19	65	938	949
Teste	7	23	322	327
Validação	7	23	7	23
Total de imagens	33	111	1260	1276

Fonte: Autor (2019).

Nesse experimento, foram desenvolvidos seis modelos de RNC com arquiteturas distintas a fim de avaliar sua capacidade de identificar os sintomas iniciais da CIB em imagens termográficas da região ocular bovina. A figura 25 apresenta a arquitetura de cada um dos modelos de RNC desenvolvidos.

Figura 25 – Arquitetura dos modelos de RNC desenvolvidos para o segundo experimento.



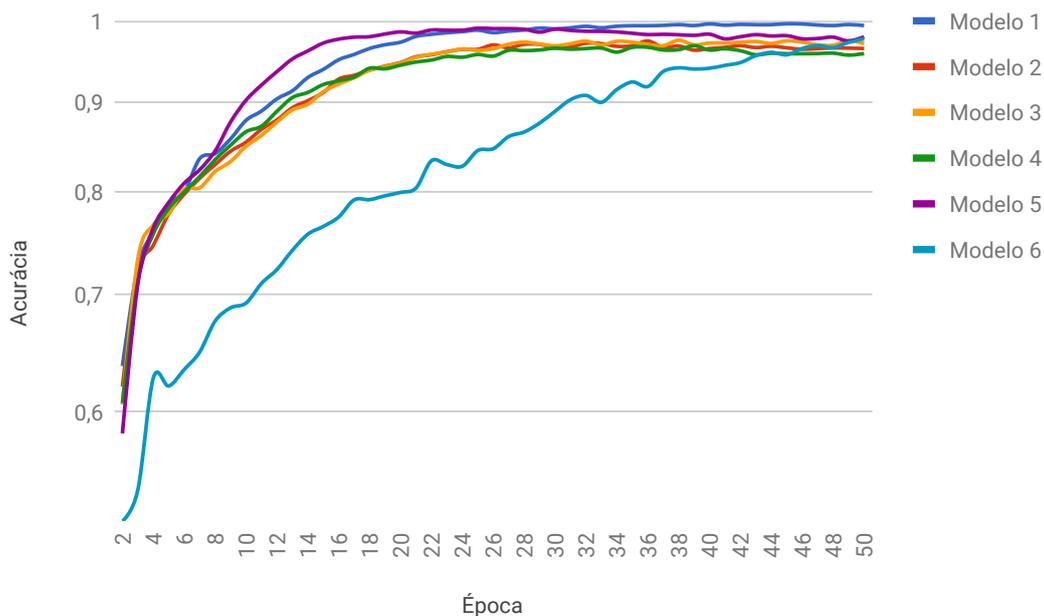
Fonte: Autor (2019).

A variação dos hiperparâmetros observaram a composição de dois tipos de arquiteturas: a primeira com maior número de camadas convolutivas e um número fixo de camadas totalmente conectadas, como pode ser visto nos modelos 1, 2 e 3; a segunda com um número fixo de camadas convolutivas e uma variação crescente de camadas totalmente conectadas, como é visto nos modelos 4, 5 e 6. Essa proposta foi elaborada com o intuito de observar se modelos com maior capacidade de extração de características e menor capacidade de classificação teriam vantagem em relação a modelos com maior capacidade de classificação. Além disso, neste experimento também optou-se por utilizar *kernel* de convolução com tamanho 2×2 em todos os modelos, tendo em vista que *kernels* de convolução com tamanhos maiores (3×3 , 5×5 e 7×7) foram testados e obtiveram resultados inferiores.

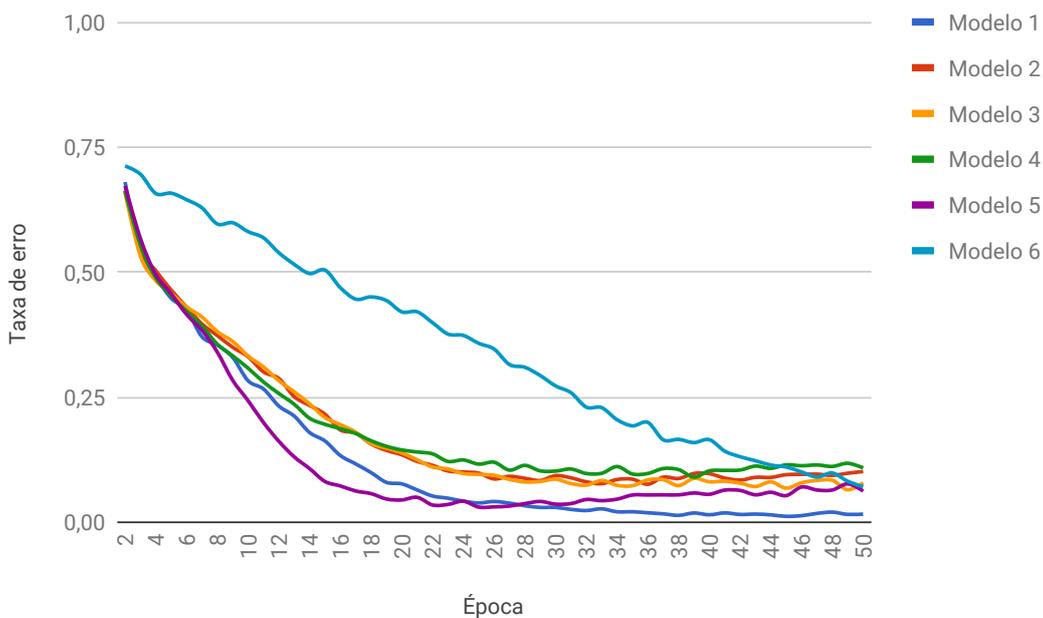
Durante a fase de treinamento, os modelos foram submetidos a uma rotina de treinamento de 50 épocas cada. Esse número de épocas foi determinado como uma

condição de parada para o algoritmo de treinamento, tendo em vista a possibilidade de ocorrer *overfitting*. A figura 26(a) apresenta os resultados da acurácia e a figura 26(b) apresenta os resultados da taxa de erro obtidos por cada modelo na etapa de treinamento.

Figura 26 – Resultados da etapa de treinamento dos modelos de RNC do segundo experimento.



(a) Acurácia



(b) Taxa de erro

Fonte: Autor (2019).

Na figura 26(a), é possível observar que todos os modelos atingiram acurácia maior que 95% durante a etapa de treinamento, indicando a eficiência da metodologia proposta. Durante a avaliação de aprendizagem, o modelo 6 teve um comportamento atípico em relação ao demais, indicando alta capacidade de generalização aos dados e também a necessidade de mais épocas de treinamento.

Após a etapa de treinamento, os modelos foram avaliados em relação a sua capacidade de classificar novas amostras. Para isso, foi utilizada uma parte do conjunto de imagens exclusivamente destinadas a esta etapa, sendo 30 imagens térmicas da região ocular bovina (tabela 7), classificadas em duas classes pelos especialistas. Os modelos de RNC foram submetidos a análise da base de imagens citada e os resultados computados por meio de uma matriz de confusão. Em seguida, as métricas de avaliação da acurácia, taxa de erro, sensibilidade e especificidade foram calculadas. Os resultados obtidos por cada modelo de RNC na etapa de validação são apresentados na tabela 8.

Tabela 8 – Resultados obtidos pelos modelos de RNC na etapa de validação do segundo experimento.

Métricas	Modelos de RNCs					
	1	2	3	4	5	6
VP	3	3	3	4	2	6
FP	0	0	2	1	0	3
VN	23	23	21	22	23	20
FN	4	4	4	3	5	1
Acurácia	0,8667	0,8667	0,8000	0,8667	0,8333	0,8667
Taxa de erro	0,1333	0,1333	0,2000	0,1333	0,1667	0,1333
Sensibilidade	0,4286	0,4286	0,4286	0,5414	0,2857	0,8571
Especificidade	1,0000	1,0000	0,9130	0,9565	1,0000	0,8696

Fonte: Autor (2019).

As altas taxas de acurácia atingidas na etapa de treinamento foram refletidas na etapa de validação. Os modelos 1, 2 e 5 obtiveram 100% de especificidade, indicando que são muitos bons em prever valor de VN, elevando o níveis de acurácia. Nota-se ainda que há um alto desequilíbrio entre os valores de sensibilidade e especificidade na maioria dos modelos, tornando-os ótimos em classificar apenas uma instância. Neste caso, a exceção é o modelo 6, o qual obteve a melhor relação entre sensibilidade e especificidade, sendo assim o modelo mais adequado na predição de novas amostras.

III. Terceiro experimento

Os resultados apresentados no segundo experimento, além de serem superiores aos

do primeiro experimento, evidenciam a capacidade dos modelos de RNC desenvolvidos em detectar os sintomas da CIB em seu estágio inicial. A partir desses resultados, apesar de uma taxa de acurácia alta, nota-se que alguns modelos tem maior capacidade em prever valores de VP e baixa capacidade de prever valores de VN enquanto outros tem maior capacidade de prever valores de VN e baixa capacidade de prever valores de VP, atenuando a capacidade de predição de ambas instâncias.

Sabendo que modelos que possuem um equilíbrio na capacidade de prever tanto VP como VN são altamente desejáveis no diagnóstico precoce de doenças, neste experimento optou-se por utilizar a técnica de combinação de classificadores conhecida como *ensemble* na tentativa de atingir esse objetivo, combinando modelos que são bons em detectar classes opostas. Para isso, os resultados de treinamento e validação obtidos no segundo experimento serão utilizados como base para definir as estruturas dos *ensembles* deste experimento. A descrição da técnica *ensemble* pode ser vista na seção 2.2.4, do capítulo 2.

A arquitetura dos modelos de RNC, resultados de treinamento e resultados de validação, os quais são utilizados neste experimento para embasar a construção dos *ensembles* podem ser revistos no Item II, da seção 4.2. Após a etapa de treinamento e validação dos modelos de RNC, os *ensembles* foram construídos combinando dois ou mais classificadores. As saídas geradas pelos modelos foram combinadas utilizando duas estratégias distintas. A primeira utilizando a média aritmética dos resultados e a segunda o voto majoritário. A arquitetura de cada *ensemble* e as estratégias de combinação e desempate podem ser vistas na tabela 9.

Tabela 9 – Combinação dos modelos utilizando a técnica ensemble.

Ensemble	Modelos combinados	Estratégia de combinação	Estratégia de desempate
1	todos	média e voto majoritário	maior distância do ponto de indecisão (0.5)
2	5 e 6	média e voto majoritário	maior distância do ponto de indecisão (0.5)
3	4, 5 e 6	média e voto majoritário	-
4	2, 3 e 6	média e voto majoritário	-
5	3 e 5	média e voto majoritário	maior distância do ponto de indecisão (0.5)

Fonte: Autor (2019).

A estrutura do primeiro *ensemble* foi composta por todos os modelos. O objetivo dessa combinação é obter maior robustez do método proposto, uma vez que conta com maior número de modelos. Em seguida, os modelos foram combinados observando a disparidade em que os mesmos tinham em relação a sensibilidade e especificidade. Nesse sentido, modelos com maior capacidade de predição de VP e menor capacidade de VN foram combinados com modelos que possuem maior capacidade de predição de VN e menor capacidade de VP, no qual é esperado que a composição desses modelos em um *ensemble* atingisse um equilíbrio na capacidade de predição das duas métricas.

Como mencionado anteriormente, a média aritmética e o voto majoritário foram as estratégias de combinação adotadas. Desta forma, os resultados podem ser vistos do ponto de vista linear e não linear. No primeiro caso, as saídas produzidas pelos modelos são somadas e divididas pela quantidade de modelos, o valor resultante é a resposta final. No segundo caso, cada modelo gera uma saída, as quais são armazenadas em uma variável responsável por contabilizar a votação, ao final a maioria dos votos é considerada como resposta final. Nos casos que podem acontecer empate no voto majoritário, a resposta final é composta pelas saídas que possuem a maior distância em relação ao ponto de indecisão (0.5), visto que os resultados entre as classes variam na escala entre 0 e 1.

Após compor os *ensembles* e estabelecer as estratégias de combinação, estes foram avaliados utilizando as métricas descritas nas Equações 1, 2, 3 e 4, que representam acurácia, taxa de erro, sensibilidade e especificidade, respectivamente. Além disso, a partir dos valores de sensibilidade e especificidade, foi calculada a eficiência dos *ensembles* por meio da sua média aritmética, definida pela Equação 7.

$$Eficiencia = \frac{Sensitividade + Especificidade}{2} \quad (7)$$

Segundo Kohavi (1998), a sensibilidade e a especificidade variam em direções opostas. Isto é, geralmente, quando um método é muito sensível a positivos, tende a gerar muitos falso-positivos, e vice-versa. Assim, um método de decisão perfeito (100% de sensibilidade e 100% especificidade) raramente é alcançado, e um balanço entre ambos deve ser atingido. Os resultados obtidos pelos *ensembles* são apresentados na tabela 10.

Tabela 10 – Resultados obtidos pelos ensembles.

(continua)

Métricas	<i>Ensemble 1</i>		<i>Ensemble 2</i>		<i>Ensemble 3</i>	
	Média	Voto majoritário	Média	Voto majoritário	Média	Voto majoritário
VP	3	4	4	5	5	5
FP	0	0	0	0	1	1
VN	23	24	23	23	22	22
FN	4	2	3	2	2	2
Acurácia	0,8667	0,9355	0,9000	0,9333	0,9000	0,9000
Taxa de erro	0,1333	0,0645	0,1000	0,0667	0,1000	0,1000
Sensibilidade	0,4286	0,6667	0,5714	0,7143	0,7143	0,7143
Especificidade	1,0000	1,0000	1,0000	1,0000	0,9565	0,9565
Eficiência	0,7143	0,8333	0,7857	0,8571	0,8354	0,8354

Tabela 10 – Resultados obtidos pelos ensembles.

(conclusão)

Métricas	<i>Ensemble 5</i>		<i>Ensemble 6</i>	
	Média	Voto majoritário	Média	Voto majoritário
VP	2	3	3	3
FP	0	2	0	0
VN	23	21	23	23
FN	5	4	4	4
Acurácia	0,8333	0,8000	0,8667	0,8667
Taxa de erro	0,1667	0,2000	0,1333	0,1333
Sensibilidade	0,2857	0,4286	0,4286	0,4286
Especificidade	1,0000	0,9130	1,0000	1,0000
Eficiência	0,6429	0,6708	0,7143	0,7143

Fonte: Autor (2019).

Os resultados obtidos pelos modelos individualmente no segundo experimento, apresentados na tabela 8, demonstraram a capacidade dos modelos em diagnosticar os sintomas da CIB usando apenas um classificador. De modo geral, a combinação de dois ou mais classificadores, usando a técnica *ensemble*, potencializou esses resultados, tornando a metodologia proposta mais robusta e eficiente. Os resultados obtidos neste experimento serão discutidos na seção seguinte e comparados com os experimentos anteriores.

4.3 Discussão dos resultados

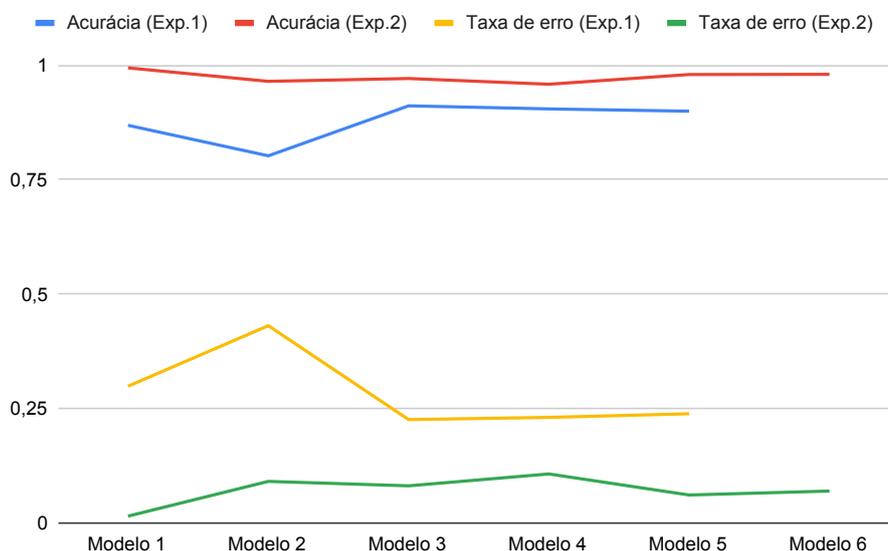
Os resultados alcançados nos experimentos realizados demonstram a capacidade das RNC desenvolvidas em diagnosticar os sintomas da CIB dado como entrada uma imagem termográfica da região ocular bovina. Embora o objetivo seja especificamente o mesmo, os experimentos são distintos do ponto de vista operacional. O objetivo do primeiro experimento é identificar os sintomas da CIB em qualquer estágio da doença, seja ela no momento inicial, seja ela no estágio mais avançado, enquanto o objetivo do segundo experimento é identificar somente os sintomas iniciais, mesmo antes de aparecer os primeiros sinais clínicos. O terceiro experimento aparece como uma alternativa para potencializar os resultados alcançados pelos classificadores de forma individual.

De forma geral, os resultados da etapa de treinamento indicaram que no primeiro experimento os modelos de RNC desenvolvidos tiveram uma taxa de acurácia média superior a 86% com uma taxa de erro média inferior a 30%. No segundo experimento os modelos de RNC desenvolvidos tiveram uma taxa de acurácia média superior a 96% e uma taxa de erro média inferior a 17%. Esses resultados indicam que os modelos de ambos os experimentos são eficientes em generalizar a informação aprendida para novas amostras mesmo utilizando uma base de imagens com poucas amostras, o que é uma realidade em termos de diagnóstico por imagem de doenças em bovinos. Além disso, percebe-se a efetividade da metodologia adotada no aumento de dados, a qual proporcionou aos modelos avaliar uma quantidade maior de imagens sem perder suas principais características.

Apesar dos resultados da etapa de treinamento de ambos os experimentos serem satisfatórios, percebe-se que a utilização de imagens do estágio inicial da CIB, classificadas com escore 0 e 1, proporcionaram um melhor desempenho dos modelos no reconhecimento dos sinais clínicos da doença, tornando o segundo experimento superior ao primeiro. Um comparativo da performance dos modelos de RNC durante a etapa de

treinamento de cada experimento pode ser visto na figura 27.

Figura 27 – Comparativo da performance dos modelos de RNC durante a etapa de treinamento entre os experimentos realizados.



Fonte: Autor (2019).

Além disso, nota-se que modelos com maior número de camadas responsáveis pela extração de características (camadas convolucionais) apresentaram maior capacidade de aprendizado em decorrência do número de épocas percorridas, contudo são mais suscetíveis a ocorrência de *overfitting*, por isso o equilíbrio entre o número de camadas convolutivas e totalmente conectadas é desejável. Observou-se ainda que modelos com arquiteturas mais profundas indicam a necessidade de mais épocas de treinamento, como pode ser visto na performance do modelo 6 apresentado na figura 26.

Na etapa de validação foi avaliada a capacidade dos modelos de RNC em prever corretamente novas amostras. Os resultados do primeiro experimento indicaram uma taxa média de acurácia superior a 70% e uma taxa de erro médio inferior a 29%. Além disso, neste experimento foi possível verificar que os modelos tiveram valores consistentes na capacidade de prever valores de VP e VN, o que é desejável no diagnóstico de doenças utilizando técnicas de aprendizado de máquina (DAVIS; GOADRICH, 2006). O Modelo 5 foi o que obteve a maior taxa de acurácia concomitantemente com menor taxa de erro dentre todos os modelos, assegurando que, neste caso, RNC mais profundas conseguem prever novos resultados com maior precisão, o que também foi visto na etapa de treinamento. Os resultados atingidos por este modelo em relação à sensibilidade e especificidade isoladamente não foram os melhores quando comparados ao desempenho

de outros modelos, mas demonstram ótima capacidade de generalização entre as classes, ou seja, possuem baixos índices de FP e FN, o que é indicado em casos que a aplicação deseja realizar predições de doenças com altos índices de assertividade.

No experimento seguinte, os resultados da etapa de validação demonstram que os modelos tiveram uma acurácia média de 85% e um erro médio de 25%. Em relação aos valores da sensibilidade e especificidade, os modelos 1, 2, 3 e 5 apresentaram menor capacidade de prever valor de VP, o que não é recomendado em uma ferramenta para diagnóstico médico precoce, mas são muito boas em detectar valor de VN. Os modelos 4 e 6 apresentaram um equilíbrio entre a capacidade de prever corretamente valor de VP e VN, o que é desejável no diagnóstico de doenças utilizando técnicas de aprendizado de máquina.

No terceiro experimento, os resultados alcançados utilizando a técnica *ensemble* apresentaram um aumento na taxa de acurácia e também uma redução na taxa de erro. Os modelos obtiveram uma acurácia média próxima a 90% e um erro médio próximo a 10%. Porém, o ganho maior utilizando essa técnica foi o equilíbrio alcançado entre a sensibilidade e especificidade, o qual torna a metodologia proposta eficiente na identificação precoce dos sinais clínicos da CIB, o que é determinante para a construção de uma ferramenta para diagnóstico automático.

As duas estratégias de combinação usadas nos *ensembles* foram eficientes, com destaque para o voto majoritário. O uso da média aritmética perde eficiência quando a maioria dos modelos possuem resultados semelhantes, com pouca margem de distinção entre as classes, o que não ocorre no voto majoritário. Os melhores resultados foram atingidos usando essa técnica nos *ensembles* 1 e 2, os quais obtiveram maior valor de acurácia e melhor equilíbrio na capacidade de predição de VP e VN, o que pode ser visto pela métrica da *Eficiência* na tabela 10. Percebe-se que o *Ensemble 2*, apesar de possuir uma acurácia inferior em relação ao *Ensemble 1*, tem maior capacidade de prever valor de VP e, portanto, é mais eficiente no ponto de vista operacional.

Os experimentos realizados apresentaram metodologias distintas, porém com o mesmo objetivo, detectar os sinais clínicos da CIB em imagens termográficas. De modo geral, o segundo experimento obteve melhores resultados em relação ao primeiro experimento, os quais foram superados pelo terceiro experimento utilizando a técnica de combinação de classificadores. Assim, é notável que os modelos de RNC desenvolvidos têm maior capacidade em detectar sinais clínicos da CIB nas imagens termográficas em seu estágio inicial. A identificação da doença em seu estágio inicial é importante para a

saúde do animal e também para o controle e prevenção da contaminação no rebanho.

Um fator que certamente exerceu influência nos resultados dos experimentos é o desbalanceamento da base de dados original, uma vez que haviam mais imagens classificadas como escore 0 do que imagens classificadas como escore 1, 2, 3 e 4. Nesse sentido, a coleta de novas imagens classificadas com escore diferentes de 0 é uma alternativa a ser explorada e que pode aumentar a acurácia dos modelos desenvolvidos.

5 CONCLUSÕES

A CIB é uma das doenças mais graves que acomete o gado de corte e de leite no mundo. Atualmente, existem duas formas de diagnosticar um surto de CIB, a realizada pelo especialista e a laboratorial. Porém, por vezes, o pecuarista não tem essa disponibilidade em tempo hábil e o surto contagioso acaba afetando mais animais, intensificando o problema. Neste contexto, este trabalho teve como objetivo principal explorar uma nova forma de diagnosticar a CIB utilizando tecnologias atuais. Para isso, foram utilizadas a termografia infravermelho como forma de aquisição de imagens e RNC como um classificador inteligente.

Durante o desenvolvimento desta pesquisa foram realizados três experimentos. O primeiro experimento tinha como objetivo detectar a manifestação da CIB em imagens termográficas da região ocular bovina, independentemente do seu estágio. Os melhores resultados indicaram que os modelos de RNC são capazes de detectar os sinais clínicos da CIB com acurácia próxima de 70%. No segundo experimento foram utilizadas apenas imagens com escores 0 e 1 com o objetivo de detectar os sintomas iniciais da CIB, no qual os modelos de RNC obtiveram uma acurácia próxima de 85%, ampliando o poder de predição do método proposto. No terceiro experimento, os modelos de RNC desenvolvidos no segundo experimento foram combinados utilizando a técnica *ensemble*, o que resultou em uma aumento da taxa de acurácia do método proposto para 93%. Além disso, modelos de RNC mais profundos, com maior número de camadas convolucionais e camadas densas, possuem vantagem em relação a modelos mais simples, porém um treinamento com maior número de épocas se mostrou desejável ao passo que a complexidade dos modelos aumenta.

Este trabalho apresentou resultados que proporcionam um avanço no que tange a forma de diagnosticar a CIB, simulando o trabalho de um especialista. A utilização de imagens termográficas é uma forma não invasiva de coletar dados dos animais e, por meio das RNC, a interpretação desses dados torna-se uma ferramenta capaz de apoiar o diagnóstico definitivo da CIB, além de tornar esse processo mais ágil. Desta forma, observando os resultados alcançados do decorrer desta pesquisa, conclui-se que os objetivos foram plenamente satisfeitos.

A principal limitação encontrada é em relação a base de dados, a qual possui um número pequeno de amostras. Embora a metodologia de aumento de dados adotada ter se mostrado eficiente, estima-se que um fator que possivelmente influenciou, de forma

negativa, na precisão dos modelos foi a quantidade reduzida de imagens. Sugestões para resolver esse problema e melhorar os resultados deste trabalho podem ser vistas na seção 5.2.

5.1 Contribuições

A principal contribuição deste trabalho foi desenvolver, aplicar e validar um método computacional que permita identificar automaticamente os sintomas da CIB em imagens termográficas da região ocular bovina. Embora a termografia infravermelha seja um método eficiente de coletar dados do animal, a interpretação destes dados é uma tarefa complexa para o especialista. Assim, o método desenvolvido pode auxiliar o especialista na interpretação desses dados, fornecendo um diagnóstico preliminar.

Além disso, durante a realização deste trabalho foram elaborados dois artigos para externar ao meio acadêmico as descobertas e avanços obtidos:

1. *Recognition of Bovine Infectious Keratoconjunctivitis using Thermographic Imaging and Convolutional Neural Networks* – artigo aceito e publicado na Revista Brasileira de Computação Aplicada (ISSN 2176-6649).
2. Diagnóstico Automático de Ceratoconjuntivite Infecciosa Bovina por meio de Imagens Termográficas e Deep Learning – artigo aceito e publicado no 12º Congresso Brasileiro de Agroinformática (SBI Agro).

5.2 Trabalhos futuros

Como trabalhos futuros, pretende-se: testar outras arquiteturas de RNC na mesma base de dados variando alguns hiperparâmetros e comparar os resultados com os obtidos até o presente momento; agregar mais imagens a base de dados atual, realizando coletas periódicas em possíveis surtos de CIB; e testar a eficiência do método desenvolvido em imagens do espectro visível.

REFERÊNCIAS

- ABADI, M. *et al.* **Tensorflow: Large-scale machine learning on heterogeneous systems.** Software available from tensorflow, Distributed, Parallel, and Cluster Computing, v. 39, 2015.
- ALEXANDER, D. **Infectious bovine keratoconjunctivitis: a review of cases in clinical practice.** Veterinary clinics: food animal practice, Elsevier, v. 26, n. 3, p. 487–503, 2010.
- ALVAREZ, J. R. *et al.* **Body condition estimation on cows from depth images using convolutional neural networks.** Computers and Electronics in Agriculture, Elsevier, v. 155, p. 12–22, 2018.
- ALVES, M. B. R. *et al.* **Recovery of normal testicular temperature after scrotal stress in rams assessed by infrared thermography and its effects on seminal characteristics and testosterone blood serum concentration.** Theriogenology, Elsevier, v. 86, n. 3, p. 795–805, 2016.
- ANGELOS, J. A. **Infectious bovine keratoconjunctivitis (pinkeye).** Veterinary Clinics: Food Animal Practice, Elsevier, v. 31, n. 1, p. 61–79, 2015.
- ANGELOS, J. A. *et al.* **Moraxella bovoculi sp. nov., isolated from calves with infectious bovine keratoconjunctivitis.** International journal of systematic and evolutionary microbiology, Microbiology Society, v. 57, n. 4, p. 789–795, 2007.
- ARAÚJO, F. H. *et al.* **Redes neurais convolucionais com tensorflow: teoria e prática.** III Escola Regional de Informática do Piauí, Sociedade Brasileira de Computação, v. 1, p. 382–406, 2017.
- BAILEY, S. R.; MARR, C. M.; ELLIOTT, J. **Current research and theories on the pathogenesis of acute laminitis in the horse.** The Veterinary Journal, Elsevier, v. 167, n. 2, p. 129–142, 2004.
- BAMBINI, M. D. *et al.* **Software para agropecuária: panorama do mercado brasileiro.** Embrapa Informática Agropecuária, Parcerias Estratégicas, v. 18, n. 36, p. 175–198, 2013.
- BAPTISTA, P. **Infectious bovine keratoconjunctivitis a review.** British Veterinary Journal, Elsevier, v. 135, n. 3, p. 225–242, 1979.
- BENGIO, Y.; COURVILLE, A.; VINCENT, P. **Representation learning: a review and new perspectives.** IEEE transactions on pattern analysis and machine intelligence, IEEE, v. 35, n. 8, p. 1798–1828, 2013.
- BOUZIDA, N.; BENDADA, A.; MALDAGUE, X. P. **Visualization of body thermoregulation by infrared imaging.** Journal of Thermal Biology, Elsevier, v. 34, n. 3, p. 120–126, 2009.
- BRAGA, A. d. P.; CARVALHO, A.; LUDERMIR, T. **Redes neurais artificiais: teoria e prática.** Editora LTC, 2000.

BRAGA, A. de P.; FERREIRA, A. C. P. de L.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. LTC Editora Rio de Janeiro, Brazil, 2007.

BRAGAMONTE, J. *et al.* **Estimação automática de espessura de gordura subcutânea bovina em imagens ultrassonográficas utilizando deep learning**. X Congresso de AgroInformática (CAI), 2018.

BRIOSCHI, M. L.; MACEDO, J. F.; MACEDO, R. d. A. C. **Termometria cutânea: novos conceitos**. Sociedade Brasileira de Angiologia e Cirurgia Vasculiar, v. 2, p. 151–60, 2003.

CARMO, P. M. *et al.* **Surto de ceratoconjuntivite infecciosa bovina e hemonose causando mortalidade em bezerros**. Pesquisa Veterinária Brasileira, Scielo, v. 31, n. 5, p. 374–378, 2011.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA. **PIB do Agronegócio Brasileiro**. 2018. Disponível em: <<https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>>. Acesso em: 15 Jun. 2019.

CERVO, A. B. **Metodologia Científica**. 5ª edição. São Paulo, 2002.

ÇETİNKAYA, M. A.; DEMİRUTKU, A. **Thermography in the assessment of equine lameness**. Journal of Veterinary and Animal Sciences, The Scientific and Technological Research Council of Turkey, v. 36, n. 1, p. 43–48, 2012.

CHANDLER, R.; BAPTISTA, P.; TURFREY, B. **Studies on the pathogenicity of moraxella bovis in relation to infectious bovine keratoconjunctivitis**. Journal of comparative pathology, Elsevier, v. 89, n. 3, p. 441–448, 1979.

CHIU, W. *et al.* **Infrared thermography to mass-screen suspected sars patients with fever**. Asia Pacific Journal of Public Health, Sage Publications Sage CA: Thouse Oaks, CA, v. 17, n. 1, p. 26–28, 2005.

CHOLLET, F. *et al.* **Keras: deep learning library for theano and tensorflow**. There is no corresponding record for this reference, 2015.

CIHAN, P. *et al.* **A review of machine learning applications in veterinary field**. Kafkas Univ Vet Fak Derg, v. 23, n. 4, p. 673–680, 2017.

COLAK, A. *et al.* **Early detection of mastitis using infrared thermography in dairy cows**. Journal of dairy science, Elsevier, v. 91, n. 11, p. 4244–4248, 2008.

COMIN, H. B. *et al.* **Descrição de um surto de ceratoconjuntivite infecciosa bovina em animais da raça hereford em quatro propriedades no estado do rio grande do sul**. XVIII Encontro de Pós-Graduação UFPel, 2016.

COSTA, G. M. da *et al.* **Descrição de um surto de ceratoconjuntivite infecciosa bovina em uma propriedade no sul de minas gerais**. Clínica Veterinária Tropical, v. 11, n. 1, p. 25–29, 2008.

DAVIS, J.; GOADRICH, M. **The relationship between precision-recall and roc curves**. Proceedings of the 23rd international conference on Machine learning, v. 6, p. 233-240, 2006.

DIETTERICH, T. G. **Ensemble methods in machine learning**. International workshop on multiple classifier systems, Springer, p. 1–15, 2000.

EUCLIDES FILHO, K.; EUCLIDES, V. **Desenvolvimento recente da pecuária de corte brasileira e suas perspectivas**. Bovinocultura de corte., FEALQ, v. 1, p. 11–40, 2010.

FACELI, K. *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro, 2011.

FAGLIN, I. *et al.* **Identification and characterisation of a biosynthetic locus for moraxella bovis lipo-oligosaccharide**. Carbohydrate research, Elsevier, v. 421, p. 9–16, 2016.

FARIA, E. L. **Redes neurais convolucionais e máquinas de aprendizado extremo aplicadas ao mercado financeiro brasileiro**. Universidade Federal do Rio de Janeiro, 2018.

FAUSETT, L. V. *et al.* **Fundamentals of neural networks: architectures, algorithms, and applications**. Hall Englewood Cliffs, 1994. v. 3.

FONSECA, J. J. S. **Metodologia da pesquisa científica**. São Paulo, 2002.

GARDENIER, J.; UNDERWOOD, J.; CLARK, C. **Object detection for cattle gait tracking**. IEEE International Conference on Robotics and Automation, IEEE, 2018.

GASPAR, E. *et al.* **Guia de coleta de dados de ceratoconjuntivite bovina infecciosa**. Embrapa Pecuária Sul, Bagé, Embrapa Pecuária Sul, 2016.

GLOROT, X.; BENGIO, Y. **Understanding the difficulty of training deep feedforward neural networks**. Proceedings of the thirteenth international conference on artificial intelligence and statistics, p. 249–256, 2010.

GODYŃ, D.; HERBUT, E.; WALCZAK, J. **Infrared thermography as a method for evaluating the welfare of animals subjected to invasive procedures: a review**. Annals of Animal Science, Versita, v. 13, n. 3, p. 423–434, 2013.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press Cambridge, 2016.

GOODFELLOW, I. *et al.* **Deep learning**. MIT press Cambridge, 2016. v. 1.

GULLI, A.; PAL, S. **Deep Learning with Keras**. Packt Publishing Ltd, 2017.

HAN, C. M.; HURD, C. D. **Diagnóstico por imagem para a prática veterinária**. Editora Roca, 2007.

HAN, D.; LIU, Q.; FAN, W. **A new image classification method using cnn transfer learning and web data augmentation**. Expert Systems with Applications, Elsevier, v. 95, p. 43–56, 2018.

HAUSSLER, D. **Quantifying inductive bias: Ai learning algorithms and valiant's learning framework**. Artificial intelligence, Elsevier, v. 36, n. 2, p. 177–221, 1988.

HAYKIN, S. **Redes Neurais Artificiais: princípios e práticas. 2ª edição**. Editora Bookman, Porto Alegre, 2001.

HAYKIN, S. **Redes neurais: princípios and prática**. Bookman Editora, Porto Alegre, 2007.

HAYKIN, S. S. *et al.* **Neural networks and learning machines**. New York: Prentice Hall, 2009.

HINTON, G. E. *et al.* **Improving neural networks by preventing co-adaptation of feature detectors**. *Neural and Evolutionary Computing*, 2012.

HOVINEN, M. *et al.* **Detection of clinical mastitis with the help of a thermal camera**. *Journal of Dairy Science*, Elsevier, v. 91, n. 12, p. 4592–4598, 2008.

INCROPERA, F. P.; DEWITT, D. P.; BERGMAN, T. L. **Fundamentos de transferência de calor e de massa**. Grupo Gen-LTC, 2000.

INFERNUSO, T. *et al.* **Thermal imaging of normal and cranial cruciate ligament deficient stifles in dogs**. *Veterinary Surgery*, Wiley Online Library, v. 39, n. 4, p. 410–417, 2010.

JANSSENS, O. *et al.* **Deep learning for infrared thermal image based machine health monitoring**. *Transactions on Mechatronics, IEEE*, v. 23, n. 1, p. 151–159, 2018.

JARRETT, K. *et al.* **What is the best multi-stage architecture for object recognition?** 12th international conference on computer vision, p. 2146–2153, 2009.

KIM, W.; CHO, Y. B.; LEE, S. **Thermal sensor-based multiple object tracking for intelligent livestock breeding**. *IEEE Access, IEEE*, v. 5, p. 27453–27463, 2017.

KNÍŽKOVÁ, I. *et al.* **Applications of infrared thermography in animal production**. *Journal of the Faculty of Agriculture*, v. 22, n. 3, p. 329–336, 2007.

KOHAVI, R. Glossary of terms. **Special issue on applications of machine learning and the knowledge discovery process**, v. 30, n. 271, p. 127–132, 1998.

KOHAVI, R. *et al.* **A study of cross-validation and bootstrap for accuracy estimation and model selection**. *Ijcai, Montreal, Canada*, v. 14, n. 2, p. 1137–1145, 1995.

KOPECKY, K.; PUGH, J. G.; MCDONALD, T. **Infectious bovine keratoconjunctivitis: contact transmission**. *American journal of veterinary research, Europe PMC*, v. 47, n. 3, p. 622–624, 1986.

KOTRBA, R. *et al.* **Comparison between the coat temperature of the eland and dairy cattle by infrared thermography**. *Journal of Thermal Biology, Elsevier*, v. 32, n. 6, p. 355–359, 2007.

KOVÁCS, Z. L. **Redes neurais artificiais**. Editora Livraria da Física, 2002.

KOVALEV, V.; KALINOVSKY, A.; KOVALEV, S. **Deep learning with theano, torch, caffe, tensorflow, and deeplearning: Which one is the best in speed and accuracy?** Minsk Publishing Center of BSU, 2016.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. **Imagenet classification with deep convolutional neural networks**. In: *Advances in neural information processing systems*. 2012. p. 1097–1105.

KUMAR, S. *et al.* **Deep learning framework for recognition of cattle using muzzle point image pattern.** Measurement, Elsevier, v. 116, p. 1–17, 2018.

KUNCHEVA, L. I. **Combining pattern classifiers: methods and algorithms.** John Wiley & Sons, 2014.

LAHIRI, B. *et al.* **Medical applications of infrared thermography: a review.** Infrared Physics & Technology, Elsevier, v. 55, n. 4, p. 221–235, 2012.

LEÃO, J. M. *et al.* **Uso da termografia infravermelha na pecuária de precisão.** Embrapa Gado de Leite, Cadernos Técnicos de Veterinária e Zootecnia, n. 79, p. 97–109, 2015.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep learning.** Nature Publishing Group, v. 521, n. 7553, p. 436, 2015.

LOPES, T. *et al.* **Utilização de imagens termográficas para diagnóstico de ceratoconjuntivite infecciosa bovina em animais da raça hereford.** Simpósio de Iniciação Científica da Embrapa Pecuária Sul, v. 8, 2018.

LUDWIG, N. *et al.* **Applicability of infrared thermography as a non invasive measurements of stress in rabbit.** World Rabbit Science, v. 15, n. 4, p. 199–206, 2010.

LUGER, G. F. **Inteligência artificial: estruturas e estratégias para a solução de problemas complexos.** Bookman, 2004.

MAHLEIN, A.-K. **Plant disease detection by imaging sensors—parallels and specific demands for precision agriculture and plant phenotyping.** Plant disease, Am Phytopath Society, v. 100, n. 2, p. 241–251, 2016.

MCCONNEL, C.; SHUM, L.; HOUSE, J. **Infectious bovine keratoconjunctivitis antimicrobial therapy.** Australian veterinary journal, Wiley Online Library, v. 85, n. 1-2, p. 65–69, 2007.

MITCHELL, T. M. **Machine learning and data mining.** Communications of the ACM, Association for Computing Machinery, Inc., v. 42, n. 11, p. 30–30, 1999.

MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. **Using deep learning for image-based plant disease detection.** Frontiers in plant science, Frontiers, v. 7, p. 1419, 2016.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of machine learning.** MIT press, 2018.

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. **Agricultura de precisão.** Oficina de Textos, 2015.

NAIR, V.; HINTON, G. E. **Rectified linear units improve restricted boltzmann machines.** 27th international conference on machine learning, p. 807–814, 2010.

NAMIN, S. T. *et al.* **Deep phenotyping: deep learning for temporal phenotype/genotype classification.** Plant methods, BioMed Central, v. 14, n. 1, p. 66, 2018.

NIELSEN, M. A. **Neural networks and deep learning.** Determination press San Francisco, 2015. v. 25.

NILSSON, N. J. **Introduction to machine learning: An early draft of a proposed textbook.** Stanford University, 1996.

O'CONNOR, A. M. *et al.* **A review of randomized clinical trials reporting antibiotic treatment of infectious bovine keratoconjunctivitis in cattle.** *Animal health research reviews*, Cambridge University Press, v. 7, n. 1-2, p. 119–127, 2006.

OLIVEIRA, A. d. **Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão.** UFJF. Juiz de Fora, 2005.

PEREIRA, A. S. *et al.* **Metodologia da pesquisa científica.** Brasil, 2018.

PEREZ, L.; WANG, J. **The effectiveness of data augmentation in image classification using deep learning.** *Computer Vision and Pattern Recognition*, 2017.

PESSIN, G. **Estratégias inteligentes aplicadas em robôs móveis autônomos e em coordenação de grupos de robôs.** Tese (Doutorado), Universidade de São Paulo, 2013.

POLAT, B. *et al.* **Sensitivity and specificity of infrared thermography in detection of subclinical mastitis in dairy cows.** *Journal of dairy science*, Elsevier, v. 93, n. 8, p. 3525–3532, 2010.

PONTI, M. A.; COSTA, G. B. P. da. **Como funciona o deep learning.** Tópicos em Gerenciamento de Dados e Informações, Cornell University, 2018.

POSTMA, G. C.; CARFAGNINI, J. C.; MINATEL, L. **Moraxella bovis pathogenicity: an update.** *Comparative immunology, microbiology and infectious diseases*, Elsevier, v. 31, n. 6, p. 449–458, 2008.

PRADO, R. N. d. A. **Implementação de uma arquitetura fuzzy neural em hardware com treinamento online.** Universidade Federal do Rio Grande do Norte, 2014.

PUNCH, P. *et al.* **Plasma and tear concentrations of antibiotics administered parenterally to cattle.** *Research in veterinary science*, v. 39, n. 2, p. 179–187, 1985.

QUINN, P. *et al.* **Microbiologia veterinária e doenças infecciosas.** Artmed Editora, 2005.

RAINWATER-LOVETT, K. *et al.* **Detection of foot-and-mouth disease virus infected cattle using infrared thermography.** *The Veterinary Journal*, Elsevier, v. 180, n. 3, p. 317–324, 2009.

RAMPASEK, L.; GOLDENBERG, A. **Tensorflow: biology's gateway to deep learning?** *Cell systems*, Elsevier, v. 2, n. 1, p. 12–14, 2016.

REBETEZ, J. *et al.* **Augmenting a convolutional neural network with local histograms a case study in crop classification from high-resolution uav imagery.** *European Symp. on Artificial Neural Networks, Computational Intelligence and Machine Learning*, p. 515-520, 2016.

REKANT, S. I. *et al.* **Veterinary applications of infrared thermography.** *American journal of veterinary research*, Am Vet Med Assoc, v. 77, n. 1, p. 98–107, 2016.

REZENDE, E. d. S. J. *et al.* **Modelo de detecção de mastite em vacas leiteiras usando termografia infravermelho.** São Paulo, 2017.

RICH, E.; KNIGHT, K. **Problems, problem spaces, and search.** Artificial Intelligence, London: McGraw-Hill, p. 29–62, 1991.

ROBERTO, J.; SOUZA, B. d. **Utilização da termografia de infravermelho na medicina veterinária e na produção animal.** Journal of Animal Behaviour and Biometeorology, Citeseer, v. 2, n. 3, p. 73–84, 2014.

ROOPAEL, M.; RAD, P.; CHOO, K.-K. R. **Cloud of things in smart agriculture: intelligent irrigation monitoring by thermal imaging.** Cloud computing, IEEE, v. 4, n. 1, p. 10–15, 2017.

RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach.** Mech. Mater, v. 263, n. 5, p. 2829–2833, 2010.

RUSSWURM, M.; KÖRNER, M. **Multi-temporal land cover classification with long short-term memory neural networks.** The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Copernicus GmbH, v. 42, p. 551, 2017.

SAGE, A. P. **Concise encyclopedia of information processing in systems and organizations.** Pergamon Press Oxford, 1990.

SCHAEFER, A. *et al.* **The non-invasive and automated detection of bovine respiratory disease onset in receiver calves using infrared thermography.** Research in veterinary science, Elsevier, v. 93, n. 2, p. 928–935, 2012.

SCHAEFER, A. *et al.* **The use of infrared thermography as an early indicator of bovine respiratory disease complex in calves.** Research in Veterinary Science, Elsevier, v. 83, n. 3, p. 376–384, 2007.

SCHAEFER, A. *et al.* **Early detection and prediction of infection using infrared thermography.** Canadian journal of animal science, NRC Research Press, v. 84, n. 1, p. 73–80, 2004.

SCHNEE, C. *et al.* **Point prevalence of infection with mycoplasma bovoculi and moraxella spp. in cattle at different stages of infectious bovine keratoconjunctivitis.** The Veterinary Journal, Elsevier, v. 203, n. 1, p. 92–96, 2015.

SERMANET, P. *et al.* **Overfeat: integrated recognition, localization and detection using convolutional networks.** Computer Vision and Pattern Recognition, Cornell University, 2013.

SERRE, T. *et al.* **A quantitative theory of immediate visual recognition.** Progress in brain research, Elsevier, v. 165, p. 33–56, 2007.

SILVA, I. d.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas.** Artliber, São Paulo:, v. 23, n. 5, p. 33–111, 2010.

- SIMON, E. L. *et al.* **Influence of exercise on thermographically determined surface temperatures of thoracic and pelvic limbs in horses.** Journal of the American Veterinary Medical Association, Am Vet Med Assoc, v. 229, n. 12, p. 1940–1944, 2006.
- SLADOJEVIC, S. *et al.* **Deep neural networks based recognition of plant diseases by leaf image classification.** Computational intelligence and neuroscience, Hindawi, 2016.
- SLATTER, D. *et al.* **A national survey of the clinical features, treatment and importance of infectious bovine keratoconjunctivitis.** Australian veterinary journal, Wiley Online Library, v. 59, n. 3, p. 69–72, 1982.
- SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. **Beyond accuracy, f-score and roc: a family of discriminant measures for performance evaluation.** In: Australasian joint conference on artificial intelligence. Springer, 2006. p. 1015–1021.
- STEWART, M. *et al.* **Eye temperature and heart rate variability of calves disbudded with or without local anaesthetic.** Physiology & Behavior, Elsevier, v. 93, n. 4-5, p. 789–797, 2008.
- STEWART, M. *et al.* **Effects of an epinephrine infusion on eye temperature and heart rate variability in bull calves.** Journal of dairy science, Elsevier, v. 93, n. 11, p. 5252–5257, 2010.
- THRALL, D. **Diagnóstico de radiologia veterinária.** Elsevier Brasil, 2014.
- TURNER, T. A.; PANSCH, J.; WILSON, J. H. **Thermographic assessment of racing thoroughbreds.** Proceeding of the American Association of Equine Practitioners, v. 47, p. 344–346, 2001.
- TURNES, C. G, RIET-CORREA, F.; SCHILD. **Ceratoconjuntivite infecciosa bovina: Doenças de ruminantes e equinos.** Pelotas: Universitária/UFPel, p. 180–191, 2003.
- VIANNA, D. M.; CARRIVE, P. **Changes in cutaneous and body temperature during and after conditioned fear to context in the rat.** European Journal of Neuroscience, Wiley Online Library, v. 21, n. 9, p. 2505–2512, 2005.
- WU, Z.; PENG, M.; CHEN, T. **Thermal face recognition using convolutional neural network.** In: International Conference on Optoelectronics and Image Processing (ICOIP), IEEE, 2016. p. 6–9.
- ZHU, W. *et al.* **Sensitivity, specificity, accuracy, associated confidence interval and roc analysis with practical sas implementations.** NESUG proceedings: health care and life sciences, Baltimore, Maryland, v. 19, p. 67, 2010.