

ARTIGO ORIGINAL

## Reconhecimento da ceratoconjuntivite infecciosa bovina utilizando imagens termográficas e redes neurais convolucionais

### Recognition of bovine infectious keratoconjunctivitis using thermographic imaging and convolutional neural networks

Dhyonatan Santos de Freitas<sup>id,1,3</sup>, Sandro da Silva Camargo<sup>id,1,3</sup>, Helena Brocardo Comin<sup>id,2</sup>, Robert Domingues<sup>id,3</sup>, Emanuelle Baldo Gaspar<sup>id,3</sup>, Fernando Flores Cardoso<sup>1,3</sup>

<sup>1</sup>Programa de Pós-Graduação em Computação Aplicada (Unipampa), <sup>2</sup>Programa de Pós-Graduação em Zootecnia (UFPEL), <sup>3</sup>Embrapa Pecuária Sul

dhyonatanfreitas.aluno@unipampa.edu.br; sandrocamargo@unipampa.edu.br; helenacommin.92@hotmail.com; robert.domingues@embrapa.br; emanuelle.gaspar@embrapa.br; fernando.cardoso@embrapa.br

Recebido: 18/03/2019. Revisado: 03/09/2019. Aceito: 16/10/2019.

#### Resumo

A Ceratoconjuntivite Infecciosa Bovina (CIB) é considerada a doença ocular de maior importância na criação de bovinos, causando perdas significativas tanto no rebanho afetado quanto para o 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 e demorada. Neste trabalho, é avaliada a utilização da termografia infravermelha para aquisição de imagens da região ocular bovina de animais sadios e infectados pela CIB e, a partir disso utilizar essa base de imagens no treinamento e validação de um conjunto de redes neurais convolucionais (RNC), com o intuito de identificar se o animal está ou não infectado em novas amostras. Foram utilizadas 4.938 imagens termográficas da região ocular bovina no processo de treinamento e validação de cinco arquiteturas distintas de RNC, as quais foram avaliadas utilizando validação cruzada. Os melhores resultados obtidos neste trabalho indicam que as RNC são capazes de classificar corretamente os sinais clínicos da CIB em imagens termográficas com uma taxa de acurácia próxima de 80%.

**Palavras-Chave:** Análise de imagens digitais; Classificação; Doença ocular bovina; Reconhecimento de padrões.

#### Abstract

Infectious Bovine Keratoconjunctivitis (IBK) is considered the most important ocular disease in cattle rearing, causing significant losses in both the affected herd and as for producer. Because it is an infectious disease, the forms of diagnosis need to be improved. Currently, the diagnosis for IBK is performed through the evaluation of clinical signs by a specialist and confirmed by laboratory tests, which is usually a costly and time-consuming task. In this work, the use of infrared thermography for the acquisition of images of the bovine ocular region of healthy and infected animals by the IBK is evaluated, using this image base in the training and validation of a set of convolutional neural networks (CNN) with the aim of identifying whether or not the animal is infected in new samples. A total of 4.938 thermographic images of the bovine ocular region were used in the training and validation process of five different architectures of CNN, which were evaluated using cross-validation. The best results obtained in this study indicate that CNNs are able to correctly classify IBK clinical signs in thermographic images with an accuracy rate close to 80%.

**Keywords:** Analysis of digital images; Bovine ocular disease; Classification; Pattern Recognition.

## 1 Introdução

A Ceratoconjuntivite Infecciosa Bovina (CIB), também denominada *pinkeye* ou “doença do olho branco”, é considerada a doença ocular de maior importância na criação de bovinos responsável por perdas econômicas e produtivas consideráveis em rebanhos de todo o mundo (Alexander, 2010, Postma et al., 2008).

A CIB é uma doença contagiosa causada pela bactéria *Moraxella bovis*. Os animais acometidos apresentam manifestações clínicas que iniciam com lacrimejamento, fotofobia, edema e opacidade de córnea, podendo evoluir para úlcera de córnea e, nos casos mais graves, cegueira irreversível (Chandler et al., 1979). 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 80% do rebanho após três a quatro semanas do início do surto (Postma et al., 2008), ocasionando diminuição do ganho de peso e da produção de leite dos animais infectados, além de elevados custos com o tratamento.

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 da *Moraxella bovis* em laboratório por meio da coleta do líquido conjuntival de animais em fase inicial da doença (Angelos et al., 2007). Por vezes, o surto de infecção já se encontra em curso quando identificado pelo produtor e, muitas vezes, não há disponibilidade imediata dos meios de diagnóstico adequados.

Tecnologias inovadoras e biotecnologias contribuem significativamente para o avanço em pesquisa animal, atuando principalmente na identificação da variabilidade animal e seu bem-estar. Métodos não destrutivos nem invasivos podem ser úteis para obtenção de dados confiáveis sem interferir diretamente com os organismos, evitando reações de estresse. Neste sentido, a termografia infravermelha se torna um método adequado para alcançar esse objetivo, principalmente em relação à coleta de dados para subsidiar o diagnóstico. Possibilitando a detecção de alterações locais e sistêmicas de temperatura expressas na superfície da pele com a vantagem de identificá-las precocemente, antes do aparecimento dos primeiros sinais clínicos (Rekant et al., 2016).

Tendo em vista que a evolução da doença é rápida e contagiosa, o tempo de reação contra o surto de CIB é determinante para o controle da infecção. Nesse sentido, o desenvolvimento de uma ferramenta capaz de auxiliar o produtor rural no diagnóstico preliminar da CIB pode reduzir o tempo de reação clínica e tornar o tratamento mais eficaz. A utilização da termografia infravermelha como ferramenta de obtenção de dados possibilita a identificação dos sintomas de maneira ágil. Com esta percepção, este trabalho tem como objetivo desenvolver um método computacional capaz de identificar automaticamente os sinais clínicos da CIB em imagens termográficas da região ocular bovina utilizando redes neurais convolucionais, fornecendo o diagnóstico

de maneira auxiliar ao trabalho do especialista.

O trabalho está estruturado da seguinte forma: na Seção 2 é apresentada uma revisão bibliográfica sobre os conceitos abordados neste estudo; na Seção 3 são apresentados os materiais e os métodos utilizados durante o desenvolvimento; na Seção 4 é discutido os resultados alcançados; e na Seção 5 é abordada as conclusões e a idealização de trabalhos futuros.

## 2 Revisão Bibliográfica

Nesta seção, serão descritos alguns conceitos sobre a termografia infravermelha e redes neurais artificiais, bem como suas aplicações na medicina veterinária.

### 2.1 Termografia Infravermelha

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, através da avaliação da temperatura superficial, é possível avaliar o estado físico e saudável dos seres vivos (Chiu et al., 2005, Bouzida et al., 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 et al., 2000). No termograma, cada cor expressa a faixa de temperatura específica, relacionada à 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 do objeto em estudo.

#### 2.1.1 Termografia infravermelha na medicina veterinária

Com a importância que o bem-estar animal tem assumido nos mais diversos campos da medicina veterinária e também em pesquisas científicas da área, tornou-se imprescindível a utilização de técnicas e equipamentos não invasivos que preservem o conforto do animal, destacando-se assim a termografia infravermelha. De acordo com Stewart et al. (2005), ela vem sendo indicada como ferramenta útil em estudos de bem-estar animal, uma vez que pode medir a temperatura corporal dos animais de forma rápida, precisa e não invasiva.

Segundo Waldsmith and Oltmann (1994), as emissões infravermelhas do animal estão diretamente relacionadas à perfusão e metabolismo dos tecidos, sendo as variações de temperatura da superfície resultado de mudanças na circulação da área avaliada. Calor e edema são sinais de inflamação e, antes mesmo que os sinais clínicos apareçam no paciente é possível observar os indícios do processo inflamatório por intermédio desse

método (Gavrila, 1999). O equipamento de imagem infravermelha é importante para o médico veterinário por ser capaz de detectar temperaturas a partir  $0,05^{\circ}\text{C}$  enquanto a mão humana percebe variações de temperatura a partir que  $4^{\circ}\text{C}$  (Davis, 2004).

Em termos de pesquisa, a termografia infravermelha tem recebido maior atenção no desenvolvimento de pesquisas nas áreas de: mastite bovina (Colak et al., 2008, Hovinen et al., 2008, Polat et al., 2010), doença respiratória em bezerros (Schaefer et al., 2007, 2012), diagnóstico de febre aftosa (Rainwater-Lovett et al., 2009), avaliação de comportamento e bem-estar animal (Kotrba et al., 2007, McCafferty et al., 2011), produção de gás metano por vacas leiteiras e identificação de animais com melhor eficiência alimentar (Montanholi et al., 2008).

## 2.2 Redes Neurais Artificiais

A pesquisa exploratória utilizando redes neurais artificiais em outras áreas do conhecimento tem crescido nas últimas décadas, isso se deve à evolução da capacidade de processamento, interpretação e análise de grandes volumes de dados. Com isso, estima-se que a utilização desta tecnologia para detecção e prevenção de doenças oculares em bovinos baseada na interpretação de imagens digitais é uma alternativa com grandes chances de sucesso.

Redes Neurais Artificiais (RNAs) são processadores paralelos constituídos de neurônios artificiais inspirados no funcionamento do cérebro humano (Haykin et al., 2009). A função primordial de uma RNA é a classificação de instâncias com base em um modelo que é gerado a partir do treinamento da rede. Os neurônios de uma RNA são dispostos em camadas, onde cada neurônio é responsável por computar o resultado do produto de um vetor de parâmetros com os valores das entradas. Este valor é então passado a uma função de ativação, que restringe a amplitude do sinal de saída. Uma arquitetura padrão simplificada de uma RNA é mostrada na Fig. 1.

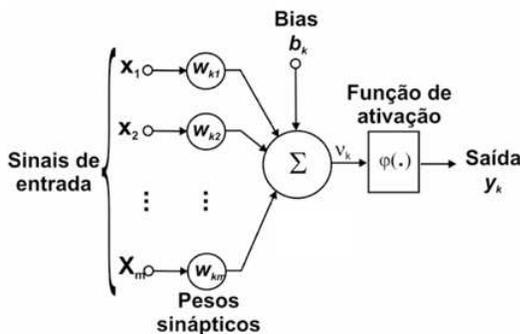


Figura 1: Arquitetura simplificada de uma RNA. Adaptado de Haykin et al. (2009)

Uma RNA pode ter diferentes arquiteturas, variando o número de camadas e como estas estão conectadas. As

arquiteturas mais comuns são *Single-Layer Feedforward*, *Multilayer Feedforward* e as chamadas RNAs recorrentes. O processo de aprendizagem de uma RNA pode ocorrer de duas maneiras: i) supervisionada, onde a classificação de cada exemplo é conhecida, neste caso o ajuste dos pesos ocorre de forma interativa entre todos os neurônios e, usualmente, utiliza-se o algoritmo *back-propagation* para essa tarefa; ii) não-supervisionada, onde não existe conhecimento sobre os exemplos, ou seja, a rede precisa identificar relações, padrões, regularidades ou categorias nos dados apresentados e codificá-los nas saídas (Haykin et al., 2009).

Diversas tarefas de aprendizado podem ser utilizadas para inúmeros fins. Porém, neste trabalho o foco é o reconhecimento de padrões e classificação de imagens, sendo este primeiro formalmente definido como o processo onde um padrão é atribuído para uma classe predefinida ou esperada. No processo de aprendizagem supervisionado, por exemplo, uma RNA executa o reconhecimento de padrões por meio de uma sessão de treinamento onde as entradas são exemplos com identificação das suas respectivas classes. Após treinada, a rede é utilizada para classificar padrões ainda não vistos, mas que pertencem a uma classe da população de exemplos utilizada para treino.

A qualidade no reconhecimento de padrões em imagens, classificação e detecção de objetos está cada vez melhor devido ao aprimoramento das redes neurais convolucionais, usualmente chamadas de RNC ou, do inglês, *CNN Convolutional Neural Network*. A maior parte do progresso se dá apenas por hardware melhor, bases de dados ou modelos maiores, mas uma consequência de novas ideias, algoritmos e arquiteturas das redes (Szegedy et al., 2015).

### 2.2.1 Redes Neurais Convolucionais

RNCs são um tipo de RNA especializado para o processamento de dados de entrada que possuem um formato de matriz, usualmente utilizadas para o processamento de informações visuais. O que caracteriza esse tipo de rede é ser composta basicamente de camadas convolutivas, que processam as entradas considerando campos receptivos locais. Em outras palavras, as RNCs são uma espécie de extrator de características automático que antecede uma RNA do tipo *Multilayer Feedforward* para classificação do resultado em classes distintas. A arquitetura de uma RNC é apresentada na Fig. 2.

**2.2.1.1 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 classificação.

**2.2.1.2 Camada convolucional.** Na camada convolucional, cada neurônio é utilizado como um filtro aplicado a uma imagem de entrada. Esse filtro é constituído por uma matriz de pesos. Assim, cada neurônio irá processar a imagem e produzir uma transformação dessa imagem por meio de uma combinação linear utilizando os pixels vizinhos (Ponti and da Costa, 2018). Cada representação gerada pelos neurônios da camada convolucional é conhecido como mapa de características, os quais são

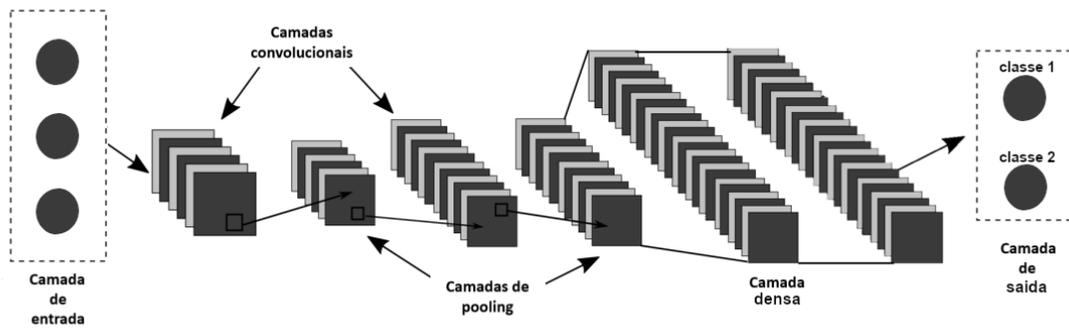


Figura 2: Arquitetura de uma RNC. Adapdata de Araújo et al. (2017)

utilizados como entrada para a próxima camada da rede. RNCs são complexas pelo ponto de vista operacional. Portanto uma forma de reduzir o custo computacional é utilizar o procedimento de *pooling* durante as camadas convolutivas de uma RNC – *pooling* é uma forma de reduzir a dimensionalidade espacial dos mapas de característica gerados pela rede.

Em outras palavras, cada neurônio da camada convolucional é responsável por coletar uma amostra da imagem de entrada e, a partir de um conjunto de pixels, gerar um único pixel de saída, evidenciando as características do conjunto inicial. Na arquitetura de uma RNC, o número de camadas convolutivas pode ser variado conforme o problema que desejamos resolver. As arquiteturas mais comuns de RNCs utilizam entre três e cinco camadas convolutivas para obter bons resultados (Rocha, 2015, Krizhevsky et al., 2012).

**2.2.1.3 Camada densa.** É uma camada oculta assim como a utilizada em redes do tipo *Multilayer Feedforward*. Nesta etapa, cada neurônio da camada densa possui um peso associado a cada elemento do vetor de entrada. A transição entre uma camada convolucional e a camada densa exige que o mapa de característica gerado pelas camadas convolutivas seja transformado em um vetor, o qual é utilizado como peso de entrada para a camada densa.

Como pode ser observado na Fig. 1, uma rede do tipo *Multilayer Feedforward* utiliza em seu processo uma função de ativação responsável por pequenas correções nos pesos da rede afim de aprimorar o funcionamento da camada de saída. Segundo Ponti and da Costa (2018), arquiteturas mais recentes de RNCs tem utilizado a função de ativação ReLU para as camadas ocultas e para a camada de saída (classificador), a função Softmax.

**2.2.1.4 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 constituirá a resposta final.

**2.2.1.5 Arquitetura de uma RNC e seus parâmetros.** A arquitetura de uma RNC é constituída pela camada de entrada juntamente com a combinação de blocos de ca-

mas convolucionais seguidas de funções de ativação que geram mapas de características. Esses mapas de características são processados por uma operação de *pooling*. Por fim, um conjunto de camadas completamente conectadas (camada densa), também acompanhadas por funções de ativação, são responsáveis por gerar o resultado final.

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

- i. número de camadas convolucionais, onde para cada camada deve-se definir o número de filtros, seu tamanho e o tamanho do passo dado durante a convolução;
- ii. número de camadas de *pooling*, onde é definido o tamanho da redução da dimensionalidade;
- iii. número de camadas totalmente conectadas (camada densa), onde é definido o número de neurônios contidos em cada camada.

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.

### 2.2.2 Redes Neurais na medicina veterinária

Na pecuária, RNAs têm sido amplamente utilizadas na identificação e prevenção de doenças, classificação de imagens, apoio à decisão e previsões baseadas em acontecimentos conhecidos.

Na prevenção de doenças, os autores Cavero et al. (2008) e Heald et al. (2000) utilizaram RNAs para identificar precocemente a mastite bovina. Nos trabalhos, sistemas de diagnóstico foram desenvolvidos com base em dados de monitoramento diário, os quais eram coletados durante as ordenhas e armazenados em uma base de dados. Esses dados serviam como entrada para a rede neural detectar com antecedência o surgimento da doença.

RNAs são comumente utilizadas para realizar previsões de acontecimento futuros. A partir dessa ideia, Mendes et al. (2009) aplicaram com sucesso redes neurais do tipo perceptron multicamadas nas previsões

do peso ao sobreano em bovinos de corte, auxiliando no apoio à decisão dos produtores. Neves (2007) também utilizou RNAs do tipo perceptron multicamadas para predição dos valores genéticos em características relacionadas à produção em gado de leite.

### 3 Materiais e Métodos

Nesta seção serão descritos os materiais utilizados neste trabalho (base de dados, linguagem de programação e bibliotecas), além da metodologia adotada para identificar sintomas da CIB em imagens termográficas da região ocular bovina utilizando redes neurais convolucionais.

#### 3.1 Materiais

##### 3.1.1 Base de Dados

A base de imagens utilizada neste trabalho foi desenvolvida pela Embrapa Pecuária Sul perante uma investigação onde os pesquisadores induziram experimentalmente a doença em 11 animais da raça Hereford para acompanhar o desenvolvimento da Ceratoconjuntivite Infeciosa Bovina (CIB)<sup>1</sup>. Os registros termográficos foram realizados em cinco dias (dia 0, 2, 4, 6 e 8), sendo que no dia zero os animais foram observados sadios e no dia 8 quando atingiram o pico máximo da infecção. Além disso, somente o olho direito foi infectado, permanecendo o olho esquerdo como controle negativo.

A base de imagens é composta por 186 imagens termográficas da região ocular bovina compactadas no formato JPEG com dimensões de 320 × 240 pixels e três canais do espaço de cores RGB, produzidas utilizando uma câmera térmica FLIR<sup>®</sup> T300.

Um exemplo de imagem térmica da região ocular bovina que compõe a base de imagens é apresentada na Fig. 3.

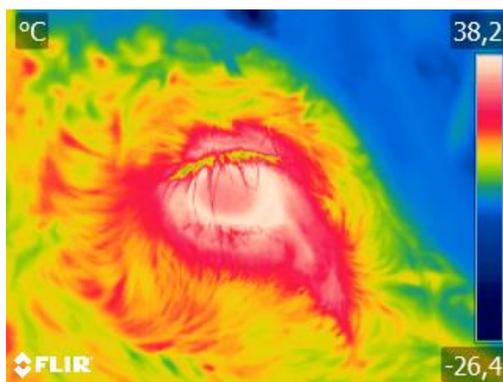


Figura 3: Imagem térmica da região ocular bovina.

As avaliações do progresso da doença foram realizadas por especialistas da Embrapa Pecuária Sul na

modalidade de *scores* (de 0 a 4) Gaspar et al. (2016). Na Tabela 1, é apresentada a classificação de cada *score* de acordo com o sinal clínico do animal no momento da avaliação.

Tabela 1: Classificação dos *scores* de acordo com o sinal clínico apresentado pelo animal no momento da avaliação.

Score	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)

Após as avaliações dos especialistas as informações foram armazenadas em uma planilha eletrônica, contendo a identificação do animal, o *score* atribuído e o ID da imagem para cada olho do animal.

##### 3.1.2 Ferramentas

Para a construção dos métodos foram utilizadas as bibliotecas de código aberto para aprendizado de máquina Tensorflow<sup>2</sup> (versão 1.5) e Keras<sup>3</sup> (versão 2.2.4), ambas da linguagem de programação Python<sup>4</sup>. O computador utilizado na construção e validação dos métodos foi um computador com processador Intel<sup>®</sup> Xeon<sup>®</sup> Octa Core de 2.10Ghz, com 8Gb de memória RAM e portando uma GPU NVIDIA<sup>®</sup> Tesla C1060. O sistema operacional utilizado é o Linux Ubuntu na versão 18.04 LTS 64 bits.

#### 3.2 Métodos

A metodologia utilizada na realização deste trabalho foi dividida em três momentos:

- i. pré-processamento dos dados;
- ii. construção das redes neurais convolucionais;
- iii. definição das métricas de avaliação.

##### 3.2.1 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 *scores* de 1 a 4. A segunda classe contém as imagens identificadas com ausência dos sinais clínicos da CIB, classificadas com o *score* 0. Desta forma, a primeira classe (imagens de olhos infectados) dispõe de 41 imagens originais, já a segunda classe (olhos não infectados) dispõe de 62 imagens originais.

Como as imagens são oriundas de um experimento realizado pela Embrapa, sua maioria continha análi-

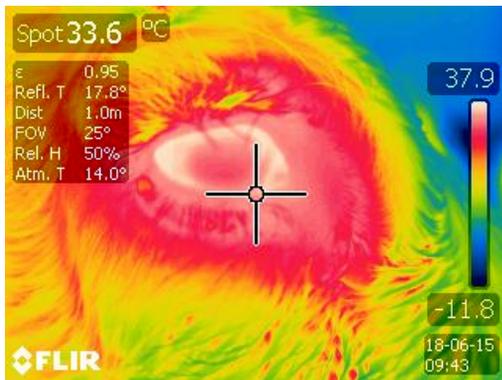
<sup>2</sup>Mais detalhes em <https://www.tensorflow.org>

<sup>3</sup>Mais detalhes em <https://keras.io/>

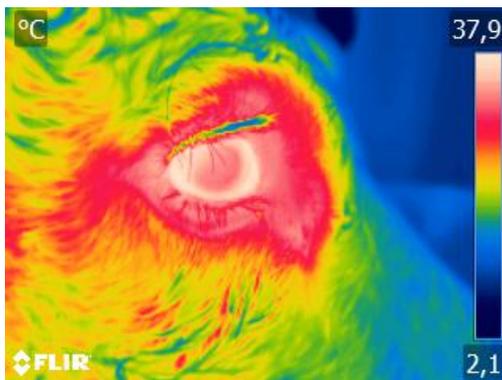
<sup>4</sup>Mais detalhes em <https://www.python.org/>

<sup>1</sup>Procedimento aprovado pela CEUA/CPPSul nº 10/2016.

ses de temperatura manuais 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<sup>®</sup>, essas análises de temperaturas foram removidas das imagens originais. Na Fig. 4(a) é apresentada uma imagem com análise de temperatura manual e na Fig. 4(b) é apresentada uma imagem com a análise de temperatura removida.



(a) Imagem com análise de temperatura manual.



(b) Imagem com a análise de temperatura removida.

**Figura 4:** Imagem termográfica com análise de temperatura e imagem com a análise removida.

Redes neurais são amplamente utilizadas para reconhecimento de padrões em imagens digitais, porém necessitam de grandes volumes de dados para efetuar um treinamento eficiente, para então, posteriormente, reconhecer ou classificar novas amostras de forma mais assertiva (Haykin, 2007, Goodfellow et al., 2016). Como nossa base de imagens possui poucas amostras para cada classe, foi necessário realizar um procedimento para, a partir dessas imagens, construir um conjunto maior de amostras.

Assim, a próxima etapa na preparação dos dados, foi aplicar uma técnica conhecida como “aumento de dados” (do inglês, *augmentation data*), a qual tem sido

utilizada em diversos trabalhos de reconhecimento de imagens utilizando *deep learning* (Perez and Wang, 2017, Han et al., 2018). Neste processo, foi utilizada a biblioteca Keras programada na linguagem Python. 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 utilizados rotações e deslocamentos na imagem principal para gerar 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. Um exemplo do processo de aumento de dados, utilizando a biblioteca Keras, é apresentada na Fig. 5, onde a partir de uma imagem são geradas 16 novas imagens.

Desta forma, utilizando o processo de aumento de dados, uma nova base de imagens foi gerada. A nova base de imagens possui 4938 imagens termográficas da região ocular bovina divididas em duas classes, sendo 3500 imagens de treinamento, 978 imagens de teste e 460 imagens de validação. A base de imagens gerada a partir do processo de aumento de dados é apresentada na Tabela 2.

**Tabela 2:** Base de dados gerada após o processo de aumento de dados.

	Imagens de olhos infectados	Imagens de olhos sadios
Total de imagens	2464	2474
Conjunto de treinamento	1750	1750
Conjunto de teste	484	494
Conjunto de validação	230	230

### 3.2.2 Desenvolvimento das Redes Neurais Convolucionais

O processo de desenvolvimento de uma rede neural para a interpretação e solução de novos problemas é um desafio constante, principalmente no que tange a busca pela arquitetura com melhor capacidade de abstração e generalização dos dados.

Os autores acreditam que o desenvolvimento do modelo que melhor se adapte ao dados é um processo exploratório e não definitivo. Nesse sentido, buscou-se neste trabalho desenvolver cinco modelos de RNC e avaliar sua capacidade de identificar os sintomas da CIB em imagens termográficas da região ocular bovina. Essas arquiteturas foram criadas utilizando a linguagem de programação Python e as bibliotecas Keras e Tensorflow. A arquitetura de cada um dos modelos de RNC desenvolvidos é apresentada na Fig. 6.

Os modelos desenvolvidos foram baseados no padrão convencional de uma RNC, conforme apresentado anteriormente na Subseção 2.2.1 (Fig. 2). Neste caso, alguns 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 em questão. A variação dos parâmetros observou a profundidade e complexidade da RNC onde, o Modelo 1 apresenta a RNC com a arquitetura mais simples, enquanto o Modelo 5

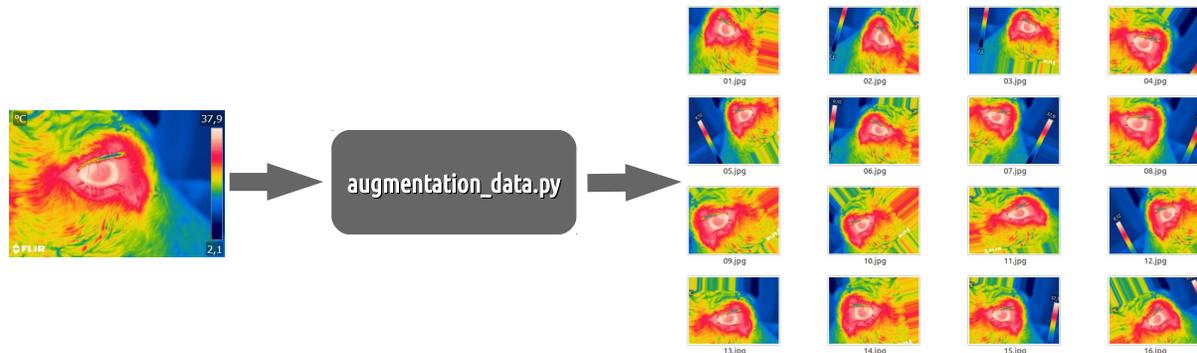


Figura 5: Processo de aumento de dados a partir de uma imagem utilizando a biblioteca Keras.

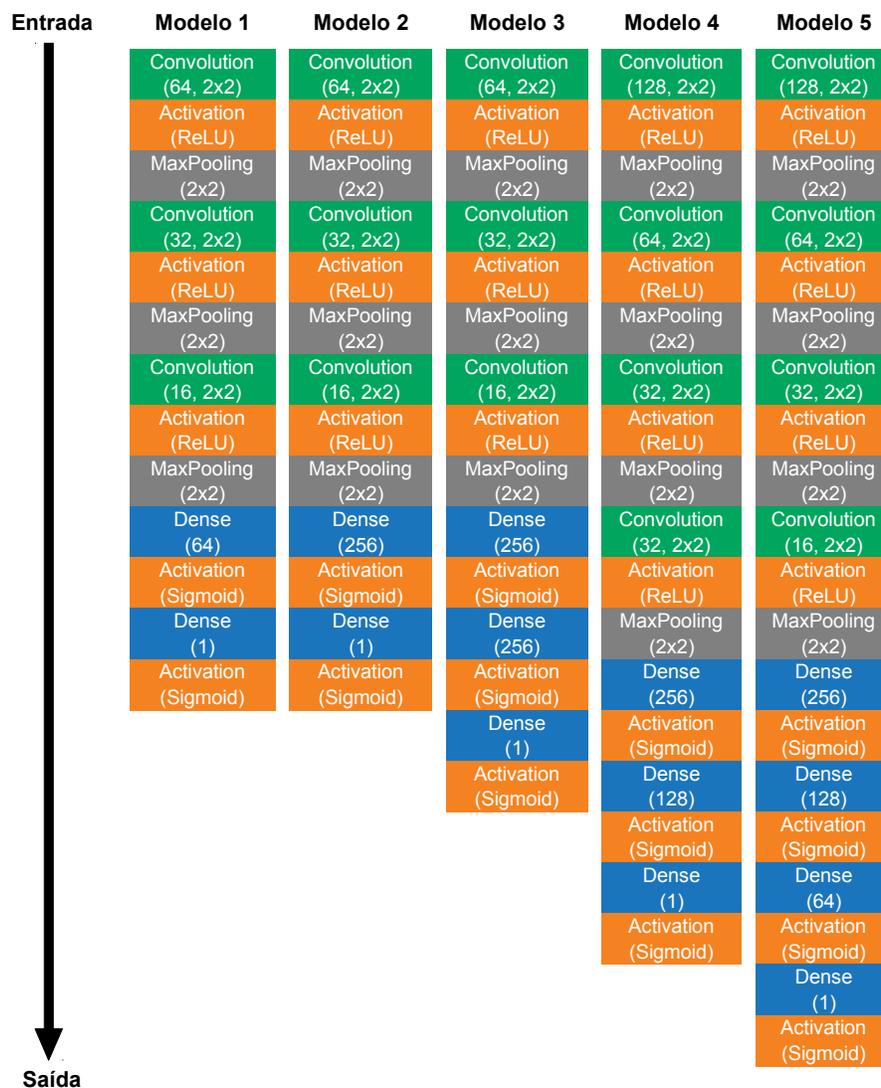


Figura 6: Arquitetura dos modelos de RNC desenvolvidas. Adaptada de da Silva and Raeder (2018).

apresenta uma arquitetura mais complexa e profunda. Além disso, optou-se por utilizar *kernel* de convo-

lução com tamanho  $2 \times 2$  em todos os modelos. A utilização de *kernels* pequenos torna a extração de ca-

racterísticas mais refinada, uma vez que a cada passo do processo convolucional um novo pixel é gerado a partir de um conjunto menor de pixels.

### 3.2.3 Métricas de avaliação

Técnicas de aprendizado de máquina utilizadas principalmente em tarefas de classificação de diagnósticos médicos necessitam de uma avaliação severa dos resultados e, para isso, algumas métricas são utilizadas. Segundo Sokolova et al. (2006), medidas que avaliam a qualidade de uma tarefa de classificação são construídas a partir de uma matriz de confusão, a qual 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 é apresentado na Tabela 3.

**Tabela 3:** Resultados obtidos pelos modelos de RNC na etapa de validação.

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

As métricas de avaliação de classificadores geralmente têm como base para cálculo os resultados gerados a partir dessa matriz de confusão. Segundo os autores Sokolova et al. (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 Eqs. (1) e (2). Porém, afirmam também que a avaliação utilizando apenas essas métricas é frágil, pois as mesmas não atendem plenamente às 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 que envolvem dados visuais (Davis and 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 (Kohavi, 1998). A sensibilidade e a especificidade são definidas pelas Eqs. (3) e (4).

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

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

Em posse dos valores de sensibilidade e especificidade, também é possível calcular a eficiência dos modelos por meio da sua média aritmética, definida pela Eq. (5). Na prática, a sensibilidade e a especificidade variam em direções opostas, isto é, quando um método é muito sensível a positivos, tende a gerar muitos falsos positivos e vice-versa. Assim, um método de decisão perfeito (100% de sensibilidade e 100% especificidade) raramente é alcançado e um equilíbrio entre ambos deve ser atingido (Kohavi, 1998).

$$Eficiência = \frac{Sensibilidade + Especificidade}{2} \quad (5)$$

Neste trabalho, as métricas citadas serão utilizadas para avaliar os modelos de RNC em dois momentos: i) na etapa de treinamento das RNC, utilizando a acurácia e a taxa de erro; ii) na etapa de validação, utilizando todas as métricas.

A divisão da base de imagens nesses dois momentos foi baseada na técnica da validação cruzada utilizando o método *holdout*. 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. O método *holdout* garante a exclusividade dos dados que serão empregados no modelo, ou seja, parte dos dados são utilizados para treinamento (usualmente 70% das amostras) e o restante para teste e validação.

## 4 Resultados e Discussão

Após o pré-processamento dos dados e o desenvolvimento dos modelos de redes neurais convolucionais, os resultados das etapas de treinamento e validação destes foram computados.

### 4.1 Treinamento dos modelos

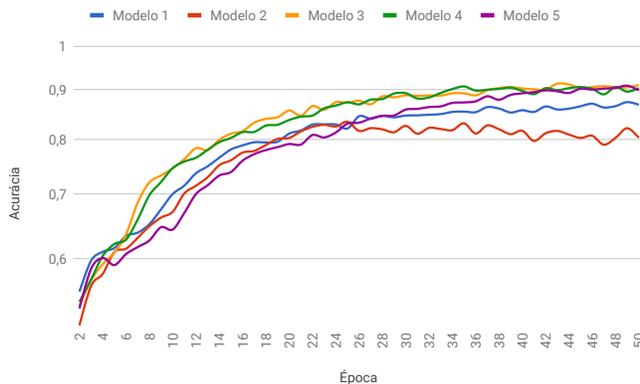
De acordo com a Tabela 2, o conjunto de imagens utilizado na etapa de treinamento é composto por dois agrupamentos, o primeiro contendo imagens de treino e o segundo contendo imagens de teste. O conjunto de treino é utilizado pela RNC para avaliar o desempenho do modelo durante seu treinamento, sendo a acurácia 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 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.

As imagens de treinamento foram divididas em duas classes, uma delas contendo imagens de olhos infectados pela CIB e outra com imagens de olhos saudáveis. A divisão das imagens dentro de cada classe ocorreu de acordo com a identificação e descrição das imagens com base na avaliação dos especialistas a campo (retratado na Subseção 3.1.1).

Em seguida, os cinco 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 sofrer variação, porém, os autores decidiram manter 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. *Overfitting* é um termo usado para descrever quando um modelo se ajusta muito bem ao conjunto de dados anteriormente observado, mas se mostra ineficaz para prever novos resultados (Srivastava et al., 2014).

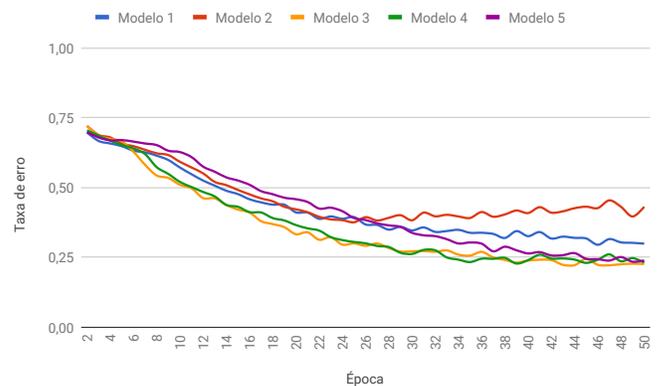
Os resultados da acurácia e taxa de erro obtidos por cada modelo na etapa de treinamento são apresentados na Fig. 7 e na Fig. 8, respectivamente.



**Figura 7:** Resultados da etapa de treinamento dos modelos de RNC em termos da Acurácia.

Os modelos foram desenvolvidos observando a complexidade de uma RNC. Dessa forma, temos que quanto mais profundo for o modelo mais complexa é sua arquitetura. Os resultados da etapa de treinamento indicam que todos os modelos tiveram uma acurácia acima de 80%. No entanto, algumas peculiaridades podem ser discutidas:

i. o desempenho dos modelos nesta etapa fica evi-



**Figura 8:** Resultados da etapa de treinamento dos modelos de RNC em termos da Taxa de erro.

denciado por sua profundidade e complexidade, onde aqueles com arquiteturas mais simples tiveram resultados inferiores àqueles com arquiteturas mais complexas. No entanto, o interessante foi que o Modelo 2, mesmo possuindo uma camada densa com maior número de neurônios em relação ao Modelo 1, obteve um resultado inferior;

ii. a arquitetura do Modelo 3 foi a mais acurada na etapa de treinamento. Observando sua curva de aprendizagem, podemos perceber que é o modelo que tem uma ascensão constante, chegando ao final das 50 épocas de treinamento com uma precisão próxima a 92%, juntamente com a menor taxa de erro. Sua principal diferença para os modelos 1 e 2 é o acréscimo de mais uma camada densa com 256 neurônios. Neste caso, o aumento no número de camadas totalmente conectadas, subsidiadas com uma extração de características consistente, garante melhor performance do modelo;

iii. o aumento de camadas convolutivas dentro da arquitetura de um modelo de RNC não garante melhor performance. Isso fica evidente quando observamos a arquitetura dos modelos 4 e 5, os quais possuem maior número de camadas convolutivas em relação aos demais, não sendo os mais efetivos nesta etapa. Pode-se perceber ainda que o modelo 4 possui uma evolução de treinamento próximo do modelo 3, contudo, decresce nas últimas épocas e a taxa de erro é maior.

De modo geral, os resultados alcançados na etapa de treinamento demonstram eficiência, embora tenha sido utilizada uma base de imagens com poucas amostras, o que é uma realidade em termos de diagnóstico por imagens de doenças em bovinos. A construção de bases de dados mais robustas para este fim é desejável para o aprimoramento de técnicas de reconhecimento de padrões, mas um desafio.

**Tabela 4:** Resultados obtidos pelos modelos de RNCs na etapa de validação.

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
Eficiência	0,6565	0,6978	0,6587	0,7587	0,7957

## 4.2 Validação dos modelos

Após a etapa de treinamento é necessário avaliar os modelos desenvolvidos em relação à sua capacidade de generalização. Para isso, utilizamos uma parte do conjunto de imagens totalmente desconhecidas pelos modelos de RNC, exclusivamente destinadas a esta etapa. Desta forma, foram utilizadas 460 imagens térmicas da região ocular bovina, sendo 230 de olhos infectados pela CIB e 230 de olhos sadios, conforme mostrado na [Tabela 2](#).

Os cinco modelos de RNC foram submetidos a análise da base de imagens citada e os resultados computados em uma matriz de confusão ([Tabela 3](#)) onde os valores de VP, FP, FN e VN foram obtidos para cada nova predição. Os resultados obtidos por cada modelo de RNC são apresentados na [Tabela 4](#).

Segundo [Sokolova et al. \(2006\)](#), os valores de acurácia e taxa de erro são comumente utilizados para avaliar aplicações de aprendizado de máquina, sendo considerado bons resultados aqueles que obtêm uma acurácia alta e uma taxa de erro baixa, isso caracteriza o poder de generalização de cada modelo. Deste modo, utilizando as métricas apresentadas na Subseção [3.2.3](#) e os valores obtidos por meio da matriz de confusão, foram computadas o valor da acurácia, taxa de erro, sensibilidade, especificidade e eficiência para cada modelo de RNC, os quais são apresentados na [Tabela 4](#).

Na etapa de validação, os modelos de RNC desenvolvidos tiveram resultados similares àqueles apresentados durante a etapa de treinamento, salvo o Modelo 3, que teve destaque na etapa de treinamento. Contudo, seu desempenho nessa etapa foi inferior a outros modelos, indicando baixo poder de generalização para novas amostras.

O Modelo 5 foi o que obteve a maior taxa de acurácia concomitantemente com menor taxa de erro dentre todos os modelos, assegurando que RNCs mais profundas conseguem prever novos resultados com maior precisão neste caso. Além disso, os resultados atingidos por este modelo em relação à sensibilidade e especificidade 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 extremamente indicado em casos que a aplicação deseja realizar predições de doenças com altos índices de acurácia.

Um fator que possivelmente influenciou, tanto nos resultados da etapa de treinamento, tanto na etapa de

validação é o fato das imagens representarem o estado físico do animal em termos da temperatura corporal. Redes Neurais Convolucionais são reconhecidas pela sua alta capacidade de extração de características dos objetos que compõem a imagem e, o fato das imagens usadas neste trabalho estarem em uma escala reduzida de cores, a diferença entre o animal sadio e o infectado é bastante confusa em alguns casos, embora essas imagens estejam alocadas em classes diferentes.

Além disso, outro fator que certamente exerce influência na precisão desta etapa é a quantidade de dados utilizados durante a etapa de treinamento. Estudos com altas taxas de acurácia (maiores que 98%) utilizam grandes bases de dados, tais como a CIFAR10 (60.000 imagens), MNIST (70.000 imagens) e ImageNet 2012 (1.2 milhões de imagens) ([CiresAn et al., 2012](#), [Serma-net et al., 2013](#)), demonstrando a necessidade de se ter uma quantidade maior de dados quando se deseja aumentar a precisão dos modelos.

Uma observação importante é que os resultados obtidos demonstraram que o uso de RNCs para detectar sintomas da CIB em imagens termográficas da região ocular do animal é uma alternativa viável e promissora, tendo em vista que existe grande margem para ajuste dos modelos desenvolvidos e o desenvolvimento de novas arquiteturas mais complexas e profundas.

## 5 Conclusão

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 a campo 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 explorar uma nova forma de diagnosticar a CIB aplicando tecnologias modernas. Para isso, foram utilizadas a termografia infravermelha como forma de aquisição de imagens e redes neurais convolucionais como um classificador automático inteligente.

Os melhores resultados obtidos indicam que as RNCs são capazes de classificar corretamente os sinais clínicos da CIB em imagens termográficas da região ocular bovina com uma taxa de acurácia próxima a 80%. Além disso, percebe-se que modelos de RNC mais profundos, com maior número de camadas convolucionais e

camadas densas, possuem vantagem em relação a modelos mais simples, proporcionando maior equilíbrio na capacidade de detectar animais doentes e sadios.

Apesar da limitação do número de imagens na base de dados, este trabalho proporcionou um avanço no que tange a forma de diagnosticar a CIB. A utilização de imagens termográficas é uma forma não invasiva de coletar dados dos animais e, por meio das redes neurais convolucionais, a interpretação desses dados se torna uma ferramenta poderosa capaz de agilizar o processo de identificação da doença e apoiar o médico veterinário no momento de seu diagnóstico definitivo.

Como trabalhos futuros, os autores pretendem testar outras arquiteturas de redes neurais convolucionais sobre a mesma base de dados, variando alguns hiperparâmetros e comparar os resultados com os obtidos neste trabalho. Além disso, almeja-se a coleta de dados em decorrência de novos casos de CIB de maneira a promover o desenvolvimento de um repositório de imagens que venha a colaborar com o aprimoramento das técnicas e, conseqüentemente, melhores resultados.

## Agradecimentos

Os autores agradecem a Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul pela bolsa de mestrado, a Embrapa-SEG pelo financiamento número 02.13.02.13.10.002 e a Prof<sup>a</sup>. Concepta Margaret McManus Pimentel pelo fornecimento do equipamento de termografia.

## Referências

- Alexander, D. (2010). Infectious bovine keratoconjunctivitis: a review of cases in clinical practice, *Veterinary Clinics: Food Animal Practice* 26(3): 487–503. <https://doi.org/10.1016/j.cvfa.2010.09.006>.
- Angelos, J. A., Spinks, P. Q., Ball, L. M. and George, L. W. (2007). *Moraxella bovoculi* sp. nov., isolated from calves with infectious bovine keratoconjunctivitis, *International journal of systematic and evolutionary microbiology* 57(4): 789–795. <https://doi.org/10.1099/ijs.0.64333-0>.
- Araújo, F. H., Carneiro, A. C., Silva, R. R., MEDEIROS, F. and USHIZIMA, D. (2017). Redes neurais convolucionais com tensorflow: Teoria e prática, *Sociedade Brasileira de Computação. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos* 1: 382–406.
- Bouzida, N., Bendada, A. and Maldague, X. P. (2009). Visualization of body thermoregulation by infrared imaging, *Journal of Thermal Biology* 34(3): 120–126. <https://doi.org/10.1016/j.jtherbio.2008.11.008>.
- Cavero, D., Tölle, K.-H., Henze, C., Buxadé, C. and Krieter, J. (2008). Mastitis detection in dairy cows by application of neural networks, *Livestock Science* 114(2–3): 280–286. <https://doi.org/10.1016/j.livsci.2007.05.012>.
- Chandler, R., Baptista, P. and Turfrey, B. (1979). Studies on the pathogenicity of *Moraxella bovis* in relation to infectious bovine keratoconjunctivitis, *Journal of comparative pathology* 89(3): 441–448. [https://doi.org/10.1016/0021-9975\(79\)90035-5](https://doi.org/10.1016/0021-9975(79)90035-5).
- Chiu, W., Lin, P., Chiou, H., Lee, W., Lee, C., Yang, Y., Lee, H., Hsieh, M., Hu, C., Ho, Y. et al. (2005). Infrared thermography to mass-screen suspected SARS patients with fever, *Asia Pacific Journal of Public Health* 17(1): 26–28. <https://doi.org/10.1177/101053950501700107>.
- CireşAn, D., Meier, U., Masci, J. and Schmidhuber, J. (2012). Multi-column deep neural network for traffic sign classification, *Neural networks* 32: 333–338. <https://doi.org/10.1016/j.neunet.2012.02.023>.
- Colak, A., Polat, B., Okumus, Z., Kaya, M., Yanmaz, L. and Hayirli, A. (2008). Early detection of mastitis using infrared thermography in dairy cows, *Journal of Dairy Science* 91(11): 4244–4248. <https://doi.org/10.3168/jds.2008-1258>.
- da Silva, W. F. and Raeder, M. (2018). Melampus: um modelo deep learning para triagem psicológica infantil, *Revista Brasileira de Computação Aplicada* 10(3): 21–33. <https://doi.org/10.5335/rbca.v10i3.8471>.
- Davis, J. and Goadrich, M. (2006). The relationship between precision-recall and roc curves, *Proceedings of the 23rd international conference on Machine learning*, ACM, pp. 233–240. <https://doi.org/10.1145/1143844.1143874>.
- Davis, J.; Silva, V. (2004). Subtração para detecção de pessoa em imagens térmicas., *Medicine & Biology* 88: 79–88.
- Gaspar, E., Cardoso, F., Gil de los Santos, J., Minho, A. and Domingues, R. (2016). Guia de coleta de dados de ceratoconjuntivite bovina infecciosa (cibi)., *Embrapa Pecuária Sul-Documentos (INFOTECA-E)*. Disponível em <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1035380>.
- Gavrila, D. (1999). A análise visual do movimento humano: pesquisa, visão computacional and compreensão de imagem, *Artigos de Ciência Veterinária* 13: 82–98.
- Goodfellow, I., Bengio, Y., Courville, A. and Bengio, Y. (2016). *Deep learning*, Vol. 1, MIT press Cambridge. <http://dx.doi.org/10.4258/hir.2016.22.4.351>.
- Han, D., Liu, Q. and Fan, W. (2018). A new image classification method using cnn transfer learning and web data augmentation, *Expert Systems with Applications* 95: 43–56. <https://doi.org/10.1016/j.eswa.2017.11.028>.
- Haykin, S. (2007). *Redes neurais: princípios e prática*, Bookman Editora.
- Haykin, S. S., Haykin, S. S., Haykin, S. S. and Haykin, S. S. (2009). *Neural networks and learning machines*, Vol. 3, Pearson Upper Saddle River.

- Heald, C., Kim, T., Sisco, W., Cooper, J. and Wolfgang, D. (2000). A computerized mastitis decision aid using farm-based records: An artificial neural network approach, *Journal of Dairy Science* **83**(4): 711–720. [https://doi.org/10.3168/jds.s0022-0302\(00\)74933-2](https://doi.org/10.3168/jds.s0022-0302(00)74933-2).
- Hovinen, M., Siivonen, J., Taponen, S., Hänninen, L., Pastell, M., Aisla, A.-M. and Pyörälä, S. (2008). Detection of clinical mastitis with the help of a thermal camera, *Journal of Dairy Science* **91**(12): 4592–4598. <https://doi.org/10.3168/jds.2008-1218>.
- Incropera, F. P., DeWitt, D. P. and Bergman, T. L. (2000). *Fundamentos de Transferência de Calor e de Massa*, Grupo Gen-LTC.
- Knížková, I., Kunc, P., Gürdil, G. A. K., Pinar, Y. and Selvi, K. (2007). Applications of infrared thermography in animal production, *Journal of the Faculty of Agriculture* **22**(3): 329–336. <https://doi.org/10.7161/anas.2007.22.3.329-336>.
- Kohavi, R. (1998). Glossary of terms, *Special issue on applications of machine learning and the knowledge discovery process* **30**(271): 127–132. Disponível em <http://deeplearning.lipinyang.org/wp-content/uploads/2016/12/Glossary-of-Terms-Journal-of-Machine-Learning.pdf>.
- Kohavi, R. et al. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection, *Ijcai*, Vol. 14, Montreal, Canada, pp. 1137–1145. Disponível em [https://www.researchgate.net/profile/Ron\\_Kohavi/publication/2352264\\_A\\_Study\\_of\\_Cross-Validation\\_and\\_Bootstrap\\_for\\_Accuracy\\_Estimation\\_and\\_Model\\_Selection](https://www.researchgate.net/profile/Ron_Kohavi/publication/2352264_A_Study_of_Cross-Validation_and_Bootstrap_for_Accuracy_Estimation_and_Model_Selection).
- Kotrba, R., Knížková, I., Kunc, P. and Bartoš, L. (2007). Comparison between the coat temperature of the elephant and dairy cattle by infrared thermography, *Journal of Thermal Biology* **32**(6): 355–359. <https://doi.org/10.1016/j.jtherbio.2007.05.006>.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097–1105. Disponível em <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>.
- Ludwig, N., Gargano, M., Luzi, F., Carenzi, C. and Verga, M. (2010). Applicability of infrared thermography as a non invasive measurements of stress in rabbit., *World Rabbit Science* **15**(4): 199–206. <https://doi.org/10.4995/wrs.2007.588>.
- McCafferty, D., Gilbert, C., Paterson, W., Pomeroy, P., Thompson, D., Currie, J. and Ancel, A. (2011). Estimating metabolic heat loss in birds and mammals by combining infrared thermography with biophysical modelling, *Comparative Biochemistry and Physiology Part A: Molecular & Integrative Physiology* **158**(3): 337–345. <https://doi.org/10.1016/j.cbpa.2010.09.012>.
- Mendes, R. A., Bertazzo, R. P., SILVA, D. et al. (2009). Sistemas especialistas na predição do fenótipo peso ao sobreamo em bovinos da raça brahman, *Simpósio Internacional de Iniciação Científica da USP (SIICUSP)*.
- Montanholi, Y. R., Odongo, N., e Swanson, K. C., Schenkel, F. S., McBride, B. W. and Miller, S. P. (2008). Application of infrared thermography as an indicator of heat and methane production and its use in the study of skin temperature in response to physiological events in dairy cattle (*bos taurus*), *Journal of Thermal Biology* **33**(8): 468–475. <https://doi.org/10.1016/j.jtherbio.2008.09.001>.
- Neves, A. (2007). *Aplicação de redes neurais artificiais na predição de valores genéticos em bovinos de leite da raça Pardo-Suíça*. 2007, PhD thesis, Dissertacao (Mestrado)-Instituto de Tecnologia, Universidade Federal do Pará, Belém, PA.
- Perez, L. and Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning, *arXiv preprint arXiv:1712.04621*. Disponível em <https://arxiv.org/abs/1712.04621>.
- Polat, B., Colak, A., Cengiz, M., Yanmaz, L., Oral, H., Bastan, A., Kaya, S. and Hayirli, A. (2010). Sensitivity and specificity of infrared thermography in detection of subclinical mastitis in dairy cows, *Journal of Dairy Science* **93**(8): 3525–3532. <https://doi.org/10.3168/jds.2009-2807>.
- Ponti, M. A. and da Costa, G. B. P. (2018). Como funciona o deep learning, *arXiv preprint arXiv:1806.07908*. Disponível em <https://arxiv.org/abs/1806.07908>.
- Postma, G. C., Carfagnini, J. C. and Minatel, L. (2008). *Moraxella bovis* pathogenicity: an update, *Comparative immunology, microbiology and infectious diseases* **31**(6): 449–458. <https://doi.org/10.1016/j.cimid.2008.04.001>.
- Punch, P., Costa, N., Chambers, E., Slatter, D. and Wilcox, G. (1985). Plasma and tear concentrations of antibiotics administered parenterally to cattle., *Research in veterinary science* **39**(2): 179–187. [https://doi.org/10.1016/s0034-5288\(18\)31742-9](https://doi.org/10.1016/s0034-5288(18)31742-9).
- Rainwater-Lovett, K., Pacheco, J. M., Packer, C. and Rodriguez, L. L. (2009). Detection of foot-and-mouth disease virus infected cattle using infrared thermography, *The Veterinary Journal* **180**(3): 317–324. <https://doi.org/10.1016/j.tvjl.2008.01.003>.
- Rekant, S. I., Lyons, M. A., Pacheco, J. M., Arzt, J. and Rodriguez, L. L. (2016). Veterinary applications of infrared thermography, *American journal of veterinary research* **77**(1): 98–107. <https://doi.org/10.2460/ajvr.77.1.98>.
- Rocha, R. H. S. (2015). *Reconhecimento de Objetos por Redes Neurais Convolutivas*, PhD thesis, PUC-Rio.
- Schaefer, A., Cook, N., Bench, C., Chabot, J., Colyn, J., Liu, T., Okine, E., Stewart, M. and Webster, J. (2012). The non-invasive and automated detection

- of bovine respiratory disease onset in receiver calves using infrared thermography, *Research in veterinary science* **93**(2): 928–935. <https://doi.org/10.1016/j.rvsc.2011.09.021>.
- Schaefer, A., Cook, N., Church, J., Basarab, J., Perry, B., Miller, C. and Tong, A. (2007). The use of infrared thermography as an early indicator of bovine respiratory disease complex in calves, *Research in Veterinary Science* **83**(3): 376–384. <https://doi.org/10.1016/j.rvsc.2007.01.008>.
- Sermanet, P., Eigen, D., Zhang, X., Mathieu, M.,ergus, R. and LeCun, Y. (2013). Overfeat: Integrated recognition, localization and detection using convolutional networks, *arXiv preprint arXiv:1312.6229*. Disponível em <https://arxiv.org/abs/1312.6229>.
- Sokolova, M., Japkowicz, N. and Szpakowicz, S. (2006). Beyond accuracy, f-score and roc: a family of discriminant measures for performance evaluation, *Australian joint conference on artificial intelligence*, Springer, pp. 1015–1021. [https://doi.org/10.1007/11941439\\_114](https://doi.org/10.1007/11941439_114).
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting, *The Journal of Machine Learning Research* **15**(1): 1929–1958. Disponível em <http://www.jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf>.
- Stewart, M., Webster, J., Schaefer, A., Cook, N. and Scott, S. (2005). Infrared thermography as a non-invasive tool to study animal welfare, *Animal Welfare* **14**(4): 319–325. Disponível em <https://www.ingentaconnect.com/content/ufaw/aw/2005/00000014/00000004/art00007>.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, e. (2015). Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9. <https://doi.org/10.1109/cvpr.2015.7298594>.
- Waldsmith, J. and Oltmann, J. I. (1994). Thermography: subclinical inflammation, diagnosis, rehabilitation, and athletic evaluation, *Journal of Equine Veterinary Science* **14**(1): 8–10. [https://doi.org/10.1016/s0737-0806\(07\)80302-9](https://doi.org/10.1016/s0737-0806(07)80302-9).