



XII Congresso Brasileiro de Agroinformática

11 a 14 de Novembro de 2019

ANAIS

**INDAIATUBA
Novembro de 2019**

ANAIS DO XII CONGRESSO BRASILEIRO DE AGROINFORMATICA

ORGANIZADORES

MARIA FERNANDA MOURA

JAYME GARCIA ARNAL BARBEDO

ALAINÉ MARGARETE GUIMARÃES

VALTER CASTELHANO DE OLIVEIRA

FATEC/EMBRAPA/UEPG-PPGCA

11 A 14 DE NOVEMBRO DE 2019

Ficha Catalográfica

Congresso Brasileiro de Agroinformática (11.: 2019: Indaiatuba, SP)

C749 Anais eletrônicos do XII Congresso Brasileiro de Agroinformática.
11 a 14 de novembro de 2019. Indaiatuba, SP; Universidade Esta-
dual de Ponta Grossa/ Maria Fernanda Moura et al. (Org.). Ponta
Grossa: SBIAGRO, 2019.

1. Agroinformática. 2. Agricultura digital. 3. Internet das coisas. I.
Moura, Maria Fernanda (Org.). II. Barbedo, Jayme Garcia Arnal
(Org.). III. Guimarães, Alaine Margarete (Org.). IV. Oliveira, Val-
ter Castelhano de (Org.). V. SBIAgro. VI. T.

CDD: 004.22



Diagnóstico Automático de Ceratoconjuntivite Infecciosa Bovina por meio de Imagens Termográficas e Deep Learning

Dhyonatan Santos de Freitas¹, Sandro da Silva Camargo¹, Helena Brocardo Comin¹, Robert Domingues², Emanuelle Gaspar Baldo², Fernando Flores Cardoso^{1,2}

¹Programa de Pós-Graduação em Computação Aplicada,
Universidade Federal do Pampa & EMBRAPA Pecuária Sul
Bagé, Rio Grande do Sul, Brasil

dhyonatanfreitas.aluno@unipampa.edu.br, sandro.camargo@unipampa.edu.br,

²Embrapa Pecuária Sul, Empresa Brasileira de Pesquisa Agropecuária
Bagé, Rio Grande do Sul, Brasil

robertdomingues@embrapa.br, emanuellebaldo@embrapa.br, fernandocardoso@embrapa.br

RESUMO

A Ceratoconjuntivite Infecciosa Bovina (CIB) é a doença ocular com maior incidência em bovinos no mundo, causando perdas no rebanho e prejuízos ao produtor. 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. Nesse sentido, é notória a necessidade em aprimorar as formas de diagnóstico da doença. Neste trabalho, é discutido o uso de Redes Neurais Convolucionais (RNC) para diagnóstico automático da CIB. A abordagem proposta foi treinada e testada em uma base de imagens termográficas da região ocular bovina de animais sadios e experimentalmente infectados. Foram desenvolvidos seis modelos de RNC com arquiteturas distintas e avaliados utilizando validação cruzada. Os melhores resultados indicam que as RNCs são capazes de identificar os sinais clínicos da CIB em imagens termográficas com uma acurácia próxima a 87%.

PALAVRAS-CHAVE: Redes Neurais Convolucionais, Doenças Oculares, Conjuntivite, *Moraxella bovis*, Inteligência Artificial.

ABSTRACT

Infectious Bovine Keratoconjunctivitis (IBK) is the ocular disease with the highest incidence in cattle herds in the world, causing losses in herds and, consequently, for farmers. Currently, the diagnosis for IBK is performed by evaluating clinical signs by an expert and confirmed by laboratory exams, which is usually a costly task. In this sense, it is perceived the need to improve the forms of identification of the disease. In this paper, the use of Convolutional Neural

Networks (CNN) for IBK automatic diagnosis is discussed. The proposed approach was trained and tested on a thermographic images dataset of the bovine ocular region of healthy and experimentally infected animals. Six CNN models were developed with different architectures and evaluated using cross-validation. The best results indicate that CNNs are able to identify the clinical signs of IBK in thermographic images with a accuracy rate close to 87%.

KEYWORDS: Convolutional Neural Networks, Ocular Diseases, Conjuntivitis, *Moraxella bovis*, Artificial Intelligence.

INTRODUÇÃO

A criação de bovinos é uma das principais atividades do agronegócio nacional, representando cerca de 5,5% do Produto Interno Bruto brasileiro (CEPEA, 2018). Além disso, o Brasil está inserido em posição de destaque no competitivo mercado internacional da carne. Apesar da posição favorável, melhorias nos aspectos gerenciais, zootécnicos e econômicos se fazem necessárias para manter a competitividade da pecuária brasileira (FILHO; EUCLIDES, 2010).

Do ponto de vista dos processos zootécnicos, percebe-se um grande esforço para integrar novas tecnologias que possam colaborar com o incremento da produtividade e redução de custos nas fazendas. Uma alternativa promissora é o desenvolvimento de ferramentas que auxiliem no diagnóstico precoce e na prevenção de doenças como a CIB. A CIB é considerada a doença ocular de maior impacto na criação de bovinos, sendo responsável por perdas econômicas e produtivas consideráveis em rebanhos de todo o mundo (POSTMA; CARFAGNINI; MINATEL, 2008; ALEXANDER, 2010). Trata-se de uma doença contagiosa causada pela bactéria denominada *Moraxella bovis*. Animais infectados 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; BAPTISTA; TURFREY, 1979). Embora não seja uma doença geralmente fatal, tem altas taxas de morbidade, chegando a afetar cerca de 80% do rebanho após 3 a 4 semanas do início do surto (POSTMA; CARFAGNINI; MINATEL, 2008).

As lesões características da CIB, que se originam na área central da córnea e progridem de forma centrífuga, facilitam o diagnóstico pelos sinais clínicos. Porém, o diagnóstico conclusivo depende do isolamento e identificação da *Moraxella bovis* em laboratório, por meio da coleta do líquido conjuntival de animais infectados (ANGELOS et al., 2007). Por vezes, o surto de infecção já se encontra em fase avançada quando identificado pelo produtor, podendo agregar-se a isso a indisponibilidade imediata dos meios de diagnóstico adequados.

Com o advento da tecnologia no campo, ferramentas inovadoras e biotecnologias são uma alternativa para o avanço em pesquisa animal, principalmente na identificação de doenças e promoção do bem-estar. A utilização de métodos não destrutivos nem invasivos tem sido uma alternativa preferencial para obtenção de dados. Neste sentido, a Termografia Infravermelha (TIV) é um método viável na medicina veterinária como forma de obtenção de dados para subsidiar o diagnóstico precoce de doenças (LEÃO et al., 2015).

Neste contexto, visando a necessidade de se ter um diagnóstico mais rápido e eficiente

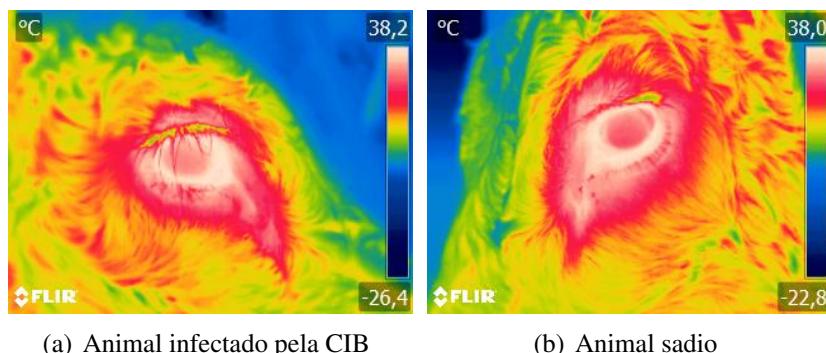
em casos de CIB, este trabalho tem como objetivo desenvolver um método computacional, baseado em *Deep Learning*, capaz de identificar autonomamente os sinais clínicos da CIB em imagens termográficas da região ocular bovina e fornecer o diagnóstico, simulando o trabalho do especialista.

MATERIAL E MÉTODOS

Base de Dados e Ferramentas Computacionais

A base de imagens disponível foi desenvolvida pela Embrapa Pecuária Sul onde 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 (procedimento aprovado pela CEUA/CPPSul nº 10/2016). A base 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. As imagens foram produzidas utilizando uma câmera térmica da marca FLIR® modelo T300. A Figura 1 mostra imagens termográficas da região ocular de um bovino infectado (a) e de um sadio (b). As avaliações do progresso da doença foram classificadas pelo

Figura 1: Imagens termográficas da região ocular bovina.



especialista por meio de escores, conforme o Guia de Coleta de Dados de Ceratoconjuntivite Bovina Infecciosa (CBI) (GASPAR et al., 2016). A Tabela 1 apresenta a classificação de cada escore de acordo com os sinais clínicos do animal no momento da avaliação. Para a construção

Tabela 1: Relação entre escores e sinal clínico identificado no momento da avaliação.

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

dos métodos, foi utilizada a linguagem de programação Python (versão 2.7) e as bibliotecas

para aprendizado de máquina *Tensorflow* (versão 1.5) e *Keras* (versão 2.2.4). 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).

Pré-processamento dos dados

As imagens originais continham análises de temperatura em seu conteúdo. Com isso, o primeiro passo do processamento dos dados foi remover essas análises de temperatura, as quais poderiam prejudicar a extração de características pelas RNCs. Nesta tarefa, o software disponibilizado pela fabricante da câmera, o FLIR Tools®, foi utilizado. Em seguida, com base nas informações contidas na planilha de avaliação dos especialistas, apenas as imagens classificadas com os escores 0 e 1 foram selecionadas e separadas em duas classes. A primeira classe contém 33 imagens identificadas com escore 1 e a segunda classe contém 111 imagens com escore 0.

Além disso, as classes supramencionadas 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.

Como a base de imagens original possui poucas amostras para cada classe e redes neurais necessitam de um volume grande de dados, foi utilizada uma técnica conhecida como aumento de dados nos agrupamentos de treino e teste. Essa técnica tem sido empregada frequentemente em trabalhos de reconhecimento de imagens por meio de *deep learning* (PEREZ; WANG, 2017; HAN; LIU; FAN, 2018).

Desta forma, a partir das imagens originais, foi gerada uma nova base de imagens, como mostra a Tabela 2.

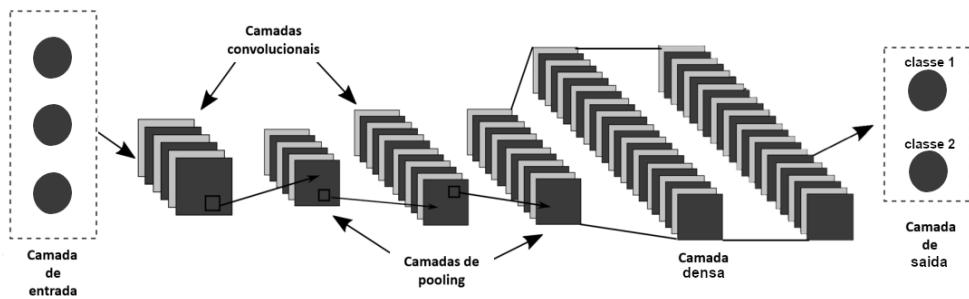
Tabela 2: Base de imagens gerada a partir do processo de aumento de dados.

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	-	-
Total de imagens	33	111	1260	1276

Desenvolvimento das Redes Neurais Convolucionais

RNC é um tipo de rede neural especializada no processamento de dados de entrada que possuem um formato de matriz, usualmente utilizadas para o processamento de informações visuais (GOODFELLOW; BENGIO; COURVILLE, 2016). São uma espécie de extrator de características automático que antecede uma rede neural do tipo *Multilayer Feedforward* para classificação do

Figura 2: Arquitetura de uma RNC.



Fonte: Adapdata de (ARAÚJO et al., 2017)

resultado em classes distintas. A arquitetura de uma RNC é apresentada na Figura 2. 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 por uma operação de *pooling*, a qual é utilizada para reduzir a dimensionalidade dos dados e refinar o mapa de características gerado na camada anterior. Por fim, um conjunto de camadas completamente conectadas (camada densa), também acompanhadas por funções de ativação, são responsáveis por gerar o resultado final.

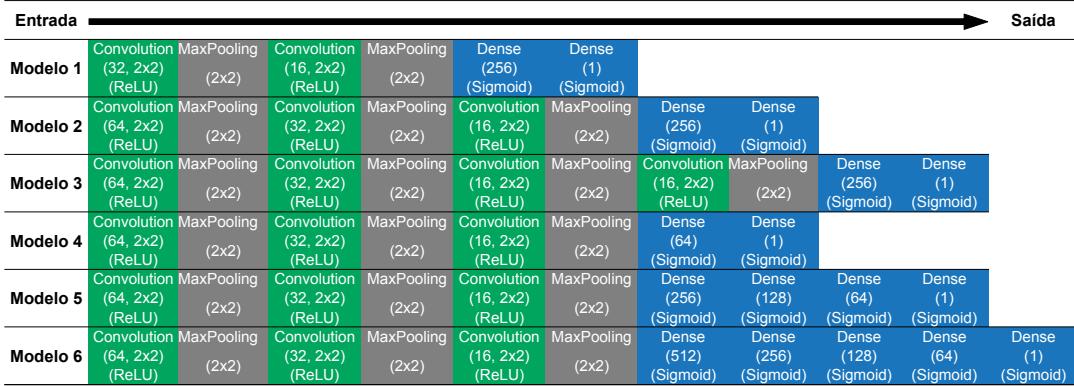
A configuração de uma RNC é definida pelos seguintes hiperparâmetros: i) Camadas convolucionais, onde para cada camada deve-se definir o número de filtros, seu tamanho e o tamanho do passo dado durante a convolução; ii) Camadas de *pooling*, onde são definidos o tamanho e o tipo do filtro utilizado; e iii) Camadas densas, onde são definidos a quantidade de camadas ocultas e o número de neurônios contidos em cada uma delas.

O processo de desenvolvimento de uma rede neural para a solução de novos problemas é um desafio, principalmente no que tange a busca pela arquitetura com melhor capacidade de abstração e generalização dos dados. Nesse sentido, buscou-se desenvolver modelos de RNC com arquiteturas distintas e avaliar sua capacidade de identificar os sintomas da CIB em imagens termográficas da região ocular bovina. Essas arquiteturas foram criadas utilizando as bibliotecas Keras e Tensorflow. A Figura 3 apresenta a arquitetura de cada um dos modelos de RNCs desenvolvidos. A variação dos hiperparâmetros observou 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 também de classificação teriam vantagem em relação a modelos com uma arquitetura mais simples.

Métricas de avaliação

Técnicas de aprendizado de máquina necessitam de uma avaliação confiável dos resultados. Medidas que avaliam a qualidade de uma tarefa de classificação são construídas a partir de uma

Figura 3: Arquitetura dos modelos de RNCs desenvolvidas.



matriz de confusão, contabilizando exemplos reconhecidos corretamente e incorretamente para cada classe (SOKOLOVA; JAPKOWICZ; SZPAKOWICZ, 2006). Em classificações binárias, essas matrizes são compostas por quatro elementos: Verdadeiros Positivos (VP); Falsos Positivos (FP); Verdadeiros Negativos (VN) e Falsos Negativos (FN), como mostra a Tabela 3. As métricas

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

Tabela 3: Matriz de confusão.

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. Porém, 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 (SOKOLOVA; JAPKOWICZ; SZPAKOWICZ, 2006).

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

$$Erro = 1 - Acurácia \quad (2)$$

Por outro lado, duas medidas que estimam separadamente o desempenho de um classificador em diferentes classes são sensibilidade e especificidade. A sensibilidade explica a capacidade do sistema em predizer corretamente a condição para casos que realmente a possui e a especificidade explica a capacidade do sistema em predizer corretamente a ausência da condição para casos que realmente não a possui (KOHAVI, 1998). A sensibilidade e a especificidade são definidas pelas Equações 3 e 4.

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

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

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

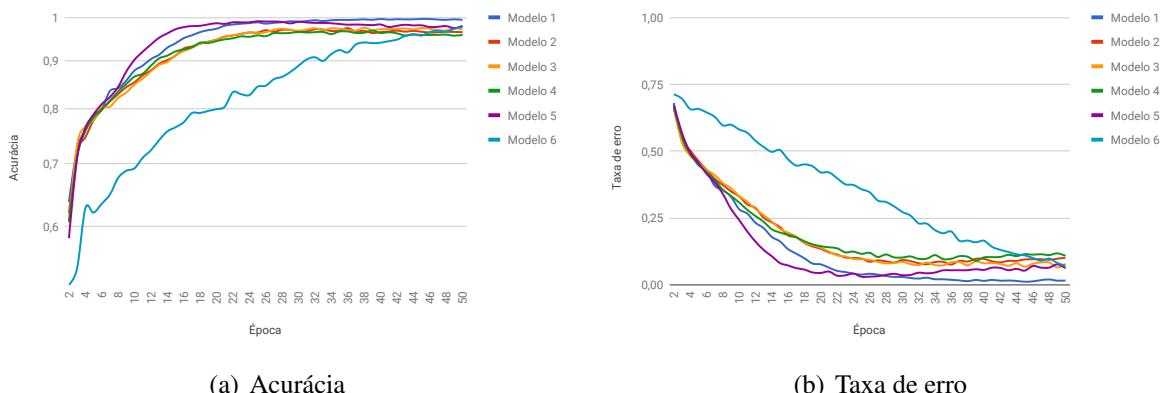
RESULTADOS E DISCUSSÃO

A utilização da TIV como método de obtenção de dados mostrou-se ser uma alternativa confiável e não invasiva para auxiliar no diagnóstico de animais acometidos pela CIB, conforme apontado em (LOPES et al., 2018). Diante disso, foi proposto neste trabalho o uso de *deep learning* para a construção de modelos de RNCs com o objetivo de reconhecer os sinais clínicos da CIB em imagens termográficas da região ocular bovina. Os modelos de RNCs desenvolvidos foram submetidos a uma sessão de treinamento na base de dados disponível e, posteriormente, validados.

Treinamento dos modelos

Foram utilizadas um total de 2536 imagens termográficas da região ocular bovina (Tabela 2) para treinar seis modelos de RNCs com arquiteturas distintas. Os modelos de RNCs 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. A Figura 4(a) apresenta os resultados da acurácia e a Figura 4(b) os resultados da taxa de erro obtidos por cada modelo na etapa de treinamento. Os resultados alcançados na etapa de treinamento mostram

Figura 4: Resultados da etapa de treinamento dos modelos de RNC.



que os modelos apresentaram uma acurácia entre 95% e 99%, apresentando uma boa capacidade de generalização no conjunto de teste, validando a técnica de aumento de dados utilizada para construir a base de dados de treinamento.

Nesta etapa, modelos com mais camadas responsáveis pela extração de características apresentaram maior capacidade de aprendizado em decorrência do número de épocas de treinamento, 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 curva de aprendizado do modelo 6 na Figura 4(a).

Validação dos modelos

Após a etapa de treinamento, os modelos foram avaliados em relação à 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 2), 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 (Tabela 3) e as Equações 1, 2, 3 e 4, como mostra a Tabela 4.

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

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

Os resultados da etapa de validação demonstram que os modelos tiveram uma acurácia média de $85\% \pm 2,79$ e um erro médio de 25%. Isso demonstra a viabilidade das RNCs em detectar os sinais clínicos da CIB em imagens termográficas. Além disso, os valores da sensibilidade e especificidade evidenciam a capacidade dos modelos em predizer corretamente valores de VP e VN, respectivamente. Os modelos 1, 2, 3 e 5 apresentaram menor capacidade de predizer valor de VP, o que não é recomendado em uma ferramenta para diagnóstico médico precoce. Os modelos 4 e 6 apresentaram um equilíbrio entre a capacidade de predizer corretamente valor de VP e VN, o que em diagnóstico de doenças é desejável (DAVIS; GOADRICH, 2006).

O desbalanceamento da base de dados original pode ser um fator que influenciou nos resultados deste trabalho, uma vez que haviam mais imagens classificadas como escore 0 do que imagens classificadas como escore 1. Nesse sentido, a coleta de novas imagens classificadas com escores diferentes de 0 é uma alternativa a ser explorada.

CONCLUSÕES

A utilização da TIV como método não invasivo de obtenção de dados mostrou-se uma alternativa eficiente e promissora para o auxílio na detecção dos sinais clínicos da CIB, conforme relatado em (LOPES et al., 2018) e neste trabalho.

O uso de técnicas de aumento de dados mostrou-se uma alternativa eficiente dada a quantidade reduzida de imagens disponíveis, o que é uma realidade comum em termos de diagnóstico por imagem na pecuária. Os melhores resultados obtidos neste trabalho indicam que as RNCs são capazes de classificar corretamente os sinais clínicos da CIB em imagens termográficas com uma acurácia próxima de 87%. Contudo, aprimoramentos são necessários para encontrar a arquitetura que melhor se adapta aos dados disponíveis. Além disso, um treinamento com maior número de épocas se mostrou desejável ao passo que a complexidade dos modelos aumenta. Desta forma, 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 RNCs, a interpretação desses dados se torna uma ferramenta capaz de apoiar o médico veterinário no momento de seu diagnóstico definitivo.

Como possíveis trabalhos futuros, estima-se que o desenvolvimento de novas arquiteturas de RNCs, juntamente com uma base de treinamento maior, podem fornecer resultados mais acurados. Além disso, a construção de bases de dados maiores para este fim é desejável para o aprimoramento de técnicas de reconhecimento de padrões e apoio ao diagnóstico.

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.^a. Concepta Margaret McManus Pimentel pelo fornecimento do equipamento de termografia.

REFERÊNCIAS

- ALEXANDER, D. Infectious bovine keratoconjunctivitis: a review of cases in clinical practice. *The Veterinary clinics of North America. Food animal practice*, Elsevier, v. 26, n. 3, p. 487–503, 2010.
- 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 and prática. *SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos and Minicursos*, Sociedade Brasileira de Computação, v. 1, n. 1, p. 382–406, jun 2017.
- CEPEA. *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: 15/05/2019.
- 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.

- DAVIS, J.; GOADRICH, M. The relationship between precision-recall and ROC curves. In: *Proceedings of the 23rd International Conference on Machine Learning*. New York, NY, USA: ACM, 2006. (ICML '06), p. 233–240. ISBN 1-59593-383-2.
- FILHO, K. E.; EUCLIDES, V. Desenvolvimento recente da pecuária de corte brasileira e suas perspectivas. *PIRES, AV Bovinocultura de corte. Piracicaba: FEALQ*, v. 1, p. 11–40, 2010.
- GASPAR, E. et al. Guia de coleta de dados de ceratoconjuntivite bovina infecciosa (CBI). *Embrapa Pecuária Sul-Dокументos (INFOTECA-E)*, Bagé: Embrapa Pecuária Sul, 2016., 2016.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. London, England: MIT Press Cambridge, 2016.
- 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.
- 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.
- KOVALEV, V.; KALINOVSKY, A.; KOVALEV, S. Deep learning with theano, torch, caffe, tensorflow, and deeplearning4j: Which one is the best in speed and accuracy? Minsk: Publishing Center of BSU, 2016.
- LEÃO, J. M. et al. Uso da termografia infravermelha na pecuária de precisão. *Embrapa Gado de Leite-Artigo em periódico indexado (ALICE)*, Cadernos Técnicos de Veterinária e Zootecnia, n. 79, p. 97-109, 2015., 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.
- PEREZ, L.; WANG, J. The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*, 2017.
- 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.
- RAMPASEK, L.; GOLDENBERG, A. Tensorflow: Biology's gateway to deep learning? *Cell systems*, Elsevier, v. 2, n. 1, p. 12–14, 2016.
- SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. In: *Proceedings of the 19th Australian Joint Conference on Artificial Intelligence: Advances in Artificial Intelligence*. Berlin, Heidelberg: Springer-Verlag, 2006. (AI'06), p. 1015–1021.