

Sistema de Classificação de Imagens por meio da Aplicação de Aprendizagem Profunda para o Pré-diagnóstico de Doenças Dermatológicas Bovinas.

Image Classification System through the Application of Deep Learning for the Pre-diagnosis of Bovine Dermatological Diseases.

Frederico Barbosa Muniz	frederico.muniz @fatec.sp.gov.br
Isabelle Fernanda Severo Hondo	isabelle.hondo @fatec.sp.gov.br
Mayara Karen Marques Pereira	mayara.pereira6 @fatec.sp.gov.br
Nayara de Azevedo Leal	nayara.coelho @fatec.sp.gov.br
Rebeca Baruch Gusmão de Oliveira	rebeca.oliveira9 @fatec.sp.gov.br
Thissiany Beatriz Almeida	thissiany.almeida @fatec.sp.gov.br

RESUMO

As doenças dermatológicas em bovinos representam um desafio significativo para a saúde animal, a saúde pública e a economia da pecuária bovina, devido ao impacto econômico e ao potencial zoonótico de algumas enfermidades. O diagnóstico dessas doenças é tradicionalmente realizado de forma manual, um processo que demanda tempo e depende de profissionais especializados. Este estudo tem como objetivo desenvolver uma plataforma baseada em inteligência artificial (IA) para o pré-diagnóstico de quatro principais doenças dermatológicas bovinas: dermatofilose, dermatofitose, dermatite nodular contagiosa e berne. Foi implementada uma abordagem que combina Redes Neurais Convolucionais (CNN) e Perceptrons Multicamadas (MLP) para a análise de imagens, acelerando o processo diagnóstico. O modelo de IA foi treinado com Keras e TensorFlow utilizando um conjunto de dados de imagens dermatológicas. O treinamento foi realizado com até 500 épocas e validação cruzada, atingindo uma acurácia superior a 70%. A solução proposta mostrou potencial para facilitar o pré-diagnóstico, promovendo o tratamento precoce, reduzindo a disseminação das doenças e oferecendo maior acessibilidade a regiões com limitada infraestrutura veterinária.

PALAVRAS-CHAVE: Doenças dermatológicas; Bovinos; Inteligência Artificial.

ABSTRACT

Dermatological diseases in cattle represent a significant challenge to animal health, public health, and the cattle farming economy due to their economic impact and the zoonotic potential of certain conditions. The diagnosis of these diseases is traditionally performed manually, a process that is time-consuming and relies on specialized professionals. This study aims to develop an artificial intelligence (AI)-based platform for the pre-diagnosis of four major dermatological diseases in cattle: dermatophilosis, dermatophytosis, contagious nodular dermatitis, and warble fly infestation (berne). An approach combining Convolutional Neural Networks (CNN) and Multi-Layer Perceptrons (MLP) was implemented for image analysis, accelerating the diagnostic process. The AI model was trained using Keras and TensorFlow on a dataset of dermatological images. Training was conducted for up to 500 epochs with cross-validation, achieving an accuracy exceeding 70%. The proposed solution demonstrated potential to facilitate pre-diagnosis, promote early treatment, reduce the spread of diseases, and improve accessibility in regions with limited veterinary infrastructure.

KEYWORDS: Dermatological Diseases; Cattle; Artificial Intelligence.

INTRODUÇÃO

O Brasil é um dos maiores produtores de carne bovina do mundo. Dada a importância da pecuária bovina não somente para a economia do Brasil, mas também para a sua alimentação e a de outros países, faz-se necessário atentar-se às questões relacionadas à saúde do gado e a de seus criadores (Ferreira *et al.*, 1999). Este trabalho abordará quatro

doenças dermatológicas de grande incidência nas propriedades rurais que praticam a criação de gado, sendo as elas: o berne, a dermatofitose bovina, a dermatofilose bovina e a dermatite nodular contagiosa.

O berne (Fig. 1a) trata-se de uma infecção causada pela mosca *Dermatobia hominis*, prevalente em regiões tropicais e subtropicais. A transmissão ocorre por meio do depósito dos ovos em locais frequentados pelo hospedeiro ou diretamente sobre sua pele. A infecção é caracterizada pela a formação de nódulos cutâneos, que contêm um variado número de larvas, representando um portal para complicações, como a infiltração bacteriana (GOMES, 1998). O impacto econômico do berne na pecuária bovina é significativo, uma vez que há uma queda na produção de carne e leite, além de depreciação do couro.

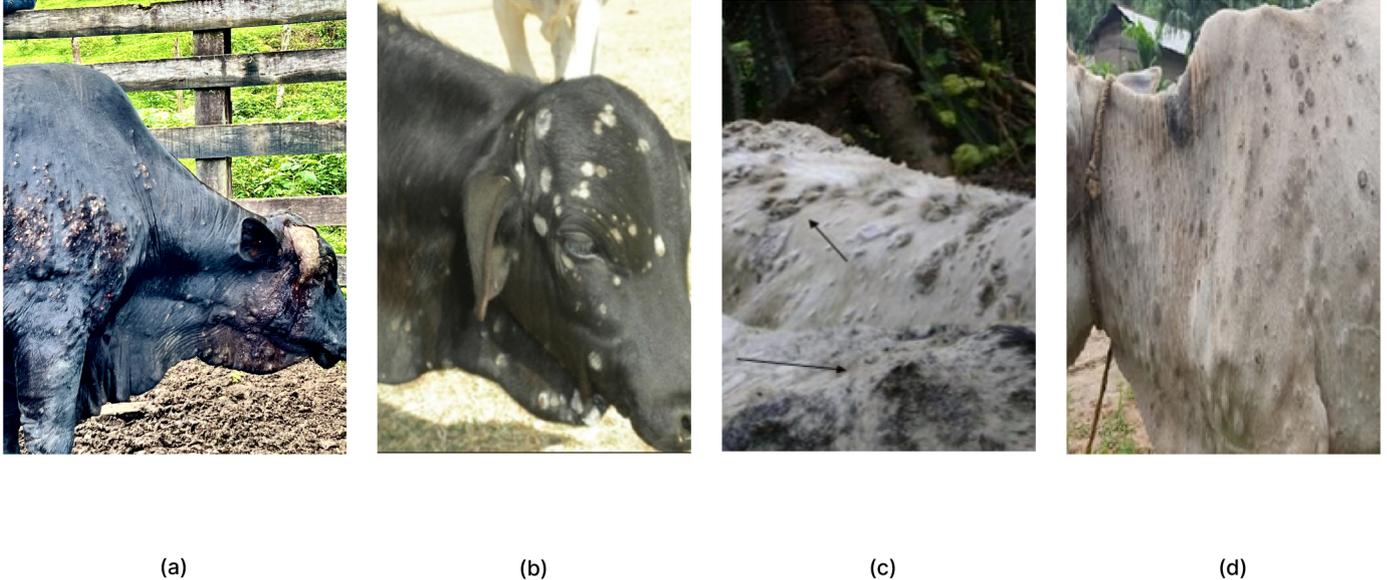
A dermatofitose bovina (Fig. 1b) é causada por fungos dermatófitos dos gêneros *Trichophyton*, *Microsporum* e *Epidermophyton*, afetando sobretudo a pele dos animais com lesões descamativas, esbranquiçadas e bordas bem definidas. Comum em ambientes úmidos, é uma zoonose que pode infectar humanos e outros animais, provocando sérios problemas de saúde pública e prejuízos econômicos. No contexto da produção de bovinos, a dermatofitose representa uma perda significativa no ganho de peso, no rendimento do couro, além de aumentar o risco de infecções secundárias o que leva ao aumento de gastos com tratamentos. A transmissão pode ocorrer por contato direto ou indireto com os conídios ou através dos pelos frágeis que contêm esporos e que contaminam o ambiente (Avante *et al.*, 2009)(Silveira *et al.*, 2003).

Já a dermatofilose bovina (Fig. 1c), causada pela bactéria *Dermatophilus congolensis*, é uma doença infecciosa que afeta principalmente bovinos, equinos e ovinos. Sua ocorrência está associada a fatores ambientais como chuvas prolongadas e umidade excessiva, causando danos cutâneos como pápulas e crostas. A transmissão ocorre pelo contato com animais portadores, sendo prevalente em regiões tropicais e subtropicais durante períodos quentes e chuvosos. A doença é mais comum em bezerros entre 1 e 12 meses e vacas nas primeiras semanas pós-parto. O diagnóstico envolve a observação do agente em crostas de lesões coradas e o tratamento inclui terapia com antibióticos como penicilina, estreptomicina e oxitetraciclina. Medidas de controle e prevenção incluem isolamento e tratamento de animais, prevenção de lesões cutâneas e controle de carrapatos (Cunha *et al.*, 2010)(Haas; Torres, 2016).

Por fim, a dermatite nodular contagiosa (Fig. 1d), também conhecida como *Lumpy Skin Disease* (LSD), é uma enfermidade viral altamente contagiosa que afeta ruminantes, especialmente bovinos. Seu principal meio de propagação é por vetores como insetos e ácaros. Dentre os ácaros conhecidos por disseminar a doença, destacam-se: *Rhipicephalus appendiculatus*, *R. decoloratus* e *Amblyomma hebraeum*. Os sintomas da doença incluem a formação de nódulos cutâneos, febre, aumento dos gânglios linfáticos, salivação excessiva e perda de peso. O controle da doença requer medidas de biossegurança, restrições de movimento de animais suscetíveis e produtos de origem animal, além da implementação de estratégias de vacinação quando disponíveis. O diagnóstico é realizado por meio de exames moleculares, virológicos e sorológicos em amostras de pele, sangue e excreções, sendo essencial para a eficácia das medidas de controle e prevenção (AGES - Austrian Agency for Health and Food Safety, 2023)(Weiss, 1964).

Devido à abordagem corrente no pré-diagnóstico das doenças dermatológicas, que é realizada manualmente, exigindo que o médico veterinário conduza exames clínicos para observar as lesões características de cada patologia, seguido da confirmação por meio de

Figura 1 – Doenças Dermatológicas



Fonte: Autoria Própria (2024); Dalis. JS et al. (2019); Dalis. JS et al. (2010); Sachin Kumar. (2022).

exames laboratoriais específicos para cada doença, este projeto se propõe a servir como uma ferramenta complementar ao diagnóstico veterinário.

Para embasar a proposta deste projeto, realizou-se uma pesquisa de campo com o objetivo de coletar dados sobre o cenário real das doenças bovinas no Vale do Ribeira. Optou-se por uma abordagem qualitativa, utilizando a estratégia de amostragem por conveniência, a fim de capturar de maneira representativa as particularidades de cada fazenda. A pesquisa abrangeu seis fazendas distintas, sendo três localizadas no município de Registro e as demais em Sete Barras, ambas no estado de São Paulo. Os resultados indicaram a ausência das três enfermidades inicialmente abordadas, o que ocasionou a inclusão do berne bovino para viabilizar os testes com usuários em um contexto real.

Este trabalho aprimora o processo de pré-diagnóstico ao analisar imagens de lesões dermatológicas, permitindo que o sistema automatizado realize uma avaliação preliminar e indique a probabilidade de cada lesão estar associada a uma das doenças consideradas. Além disso, sua estrutura e metodologia servem como base para pesquisas futuras no campo da dermatologia, facilitando o desenvolvimento de novos métodos de diagnóstico e ampliando o conhecimento científico na área. A aplicação potencial deste projeto também não se restringe ao contexto atual, podendo ser adaptada para outras condições dermatológicas ou até para diferentes espécies animais, ampliando sua relevância e utilidade no âmbito acadêmico e clínico.

OBJETIVO

Este projeto visa otimizar e agilizar o processo diagnóstico, por meio do desenvolvimento de uma aplicação móvel que realize o pré-diagnóstico através do registro e classificação de imagens, proporcionando aos criadores agropecuários e médicos veterinários uma valiosa

assistência na identificação precoce e precisa das condições dermatológicas em animais.

ESTADO DA ARTE

Para embasar o projeto, realizou-se uma pesquisa sobre trabalhos correlatos. Observou-se que muitos projetos focaram na classificação de imagens para diagnóstico precoce de doenças humanas, bem como doenças em animais, usando Inteligência Artificial (IA), destacando-se na literatura médica. Esses projetos demandam sistemas complexos de processamento de imagens, baseados em técnicas avançadas de Aprendizagem Profunda e IA. Alguns trabalhos relevantes:

- O trabalho de Fangfang Lu (2023) propõe um modelo de CNN-MLP para segmentação de lesões e classificação de gravidade da COVID-19 em imagens de tomografia computadorizada. (Lu *et al.*, 2023).
- O sistema de Lopes (2016) apresenta um modelo matemático para classificação de rebanhos positivos e negativos para brucelose bovina, utilizando redes neurais artificiais. (LOPES, 2016).

Essa síntese entre os resultados da pesquisa de campo e a contribuição dos trabalhos correlatos oferece uma visão abrangente sobre um contexto geral nas áreas rurais e destaca a importância da aplicação de tecnologias avançadas, como IA, no pré-diagnóstico de doenças em bovinos.

METODOLOGIA

O projeto contempla uma aplicação para dispositivos móveis e uma plataforma Web. A aplicação tem como uma de suas principais funções servir como uma interface para a inclusão de imagens das manchas descamativas, que serão analisadas por um algoritmo de reconhecimento de Aprendizagem Profunda integrado a aplicação, uma vez que as lesões causadas pelas doenças possuem características marcantes. Outra função que deve ser desempenhada pela aplicação é a exibição dos resultados do pré-diagnóstico de modo que facilite o controle da saúde do gado. Complementando a aplicação, a plataforma Web será dedicada à gestão dos registros das análises realizadas. Ela funcionará como uma ferramenta que organiza e apresenta de forma visual as informações sobre a propriedade, destacando detalhadamente os dados relevantes. Essa integração permitirá um controle mais eficaz da saúde do gado, especialmente em propriedades com um grande número de animais.

METODOLOGIA DE DESENVOLVIMENTO DA APRENDIZAGEM PROFUNDA

A IA destinada à classificação de imagens das lesões dermatológicas em bovinos foi treinada para classificar em três categorias, sendo estas: Dermatite Nodular, Berne e Saudável. O processo de treinamento da IA foi realizado utilizando uma combinação de CNN e MLP. A CNN é um tipo de modelo de Aprendizagem Profunda especializado no processamento e análise de imagens, uma vez que extrai características visuais por meio de camadas convolucionais, capazes de identificar padrões de complexidade crescente. A MLP, por sua vez, é um tipo de rede neural composta de camadas conectadas, que permite associar as características visuais extraídas pela CNN com as classes específicas de lesões, proporcionando uma classificação precisa e automatizada. A técnica de Holdout estratificado foi aplicada, onde 80% das imagens foram reservadas para o treinamento e 20% para o teste,

garantindo uma distribuição equilibrada entre as classes.

O modelo CNN foi projetado para processar imagens com a resolução de 64x64 pixels. O pré-processamento inicial envolveu a aplicação de um corte central (*CROP*) e da técnica de limiarização binária (*Thresholding*) para focar nas áreas mais relevantes das imagens e convertê-las em uma representação binária. Utilizando camadas Lambda no *Tensor Flow* que é um framework, amplamente utilizado para o desenvolvimento de redes neurais e soluções de Aprendizagem Profunda (Falcão *et al.*, 2019). O modelo processa as imagens aplicando três camadas convolucionais, cada uma seguida por uma camada de *max pooling* que consiste em uma operação que reduz a dimensionalidade das saídas das camadas convolucionais, simplificando as informações e reduzindo a quantidade de parâmetros (Santos, 2017). Para extrair características visuais progressivamente mais complexas. As camadas convolucionais continham 32, 64 e 128 filtros de tamanho 3x3, ativados pela função ReLU (*Rectified Linear Unit*) que é definida pela equação:

$$f(x) = \max(0, x)$$

- x : representa o valor de entrada da função, que pode ser positivo ou negativo.
- $f(x)$: representa a saída da função ReLU. Se x for maior que 0, a saída será x ; caso contrário, será 0.

Essa função é comumente utilizada em Redes Neurais Profundas por sua simplicidade e eficácia (Camponogara; Seman, s.d.), foi utilizada para introduzir não-linearidade no modelo, permitindo que ele aprenda características complexas. Após a última camada convolucional, os mapas de características foram achatados em um vetor unidimensional (*Flatten*), preparando os dados para a próxima camada.

A MLP consistiu em duas camadas densas: a primeira com 64 neurônios ativados pela função ReLU e a última com três neurônios, correspondentes às classes Dermatite Nodular, Berne e Saudável. A função de ativação *Softmax* foi utilizada na camada de saída para a classificação multicategórica, e é definida pela seguinte equação:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}}$$

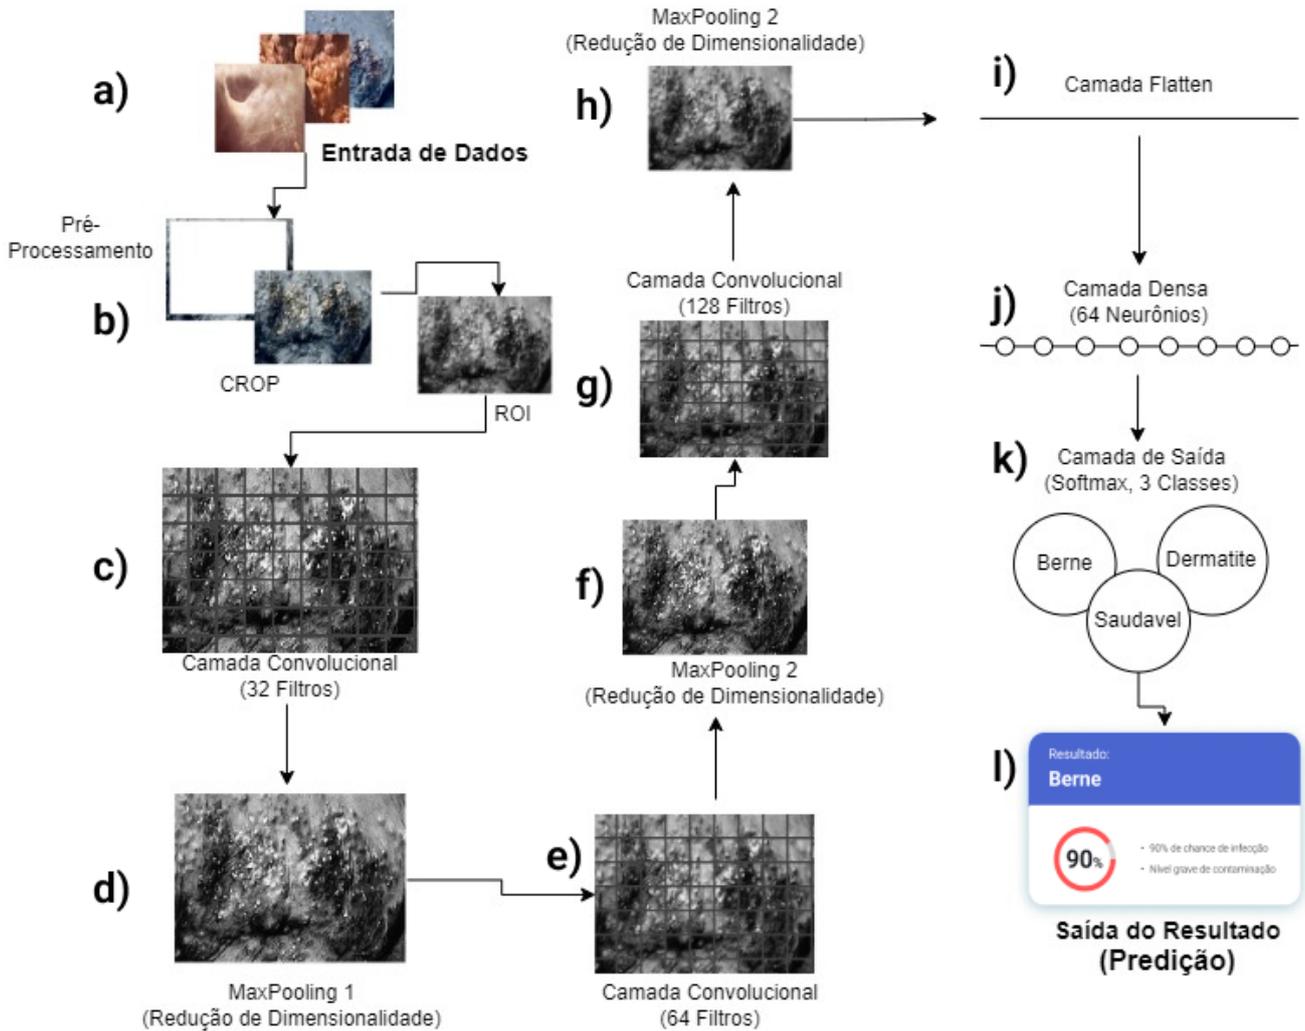
- z_i : representa o escore (logit) da classe i , ou seja, o valor de saída da rede neural antes da aplicação da função Softmax.
- e : é a base do logaritmo natural, que eleva o escore z_i para transformar os valores em uma escala exponencial.
- $\sum_j e^{z_j}$: a soma dos escores exponenciados de todas as classes j , usada para normalizar a probabilidade.
- $\text{Softmax}(z_i)$: a saída da função Softmax, que é a probabilidade prevista para a classe i , assegurando que a soma das probabilidades de todas as classes seja igual a 1.

Essa função garante que a soma das probabilidades previstas para cada classe seja igual a 1, facilitando a interpretação dos resultados como probabilidades. O modelo foi compilado utilizando o otimizador Adam, com a função de perda de entropia cruzada categórica (categorical crossentropy) e acurácia como métrica de desempenho. A acurácia é uma métrica que indica a proporção de predições corretas em relação ao total de predições realizadas. É uma medida simples e intuitiva para avaliar a performance geral de um modelo, especialmente em tarefas de classificação. No entanto, a acurácia pode ser uma métrica

limitada em conjuntos de dados desbalanceados, motivo pelo qual a perda é também considerada. Detalhando um pouco mais sobre o funcionamento de cada processo da IA, será descrito no texto abaixo e poderá ser observado na (Fig. 2).

- **a) Entrada de Imagens:** As imagens de bovinos foram redimensionadas para 64x64 pixels e normalizadas, com os valores de pixel variando entre 0 e 1.
- **b) Pré-Processamento (CROP e ROI):** Um corte central (CROP) foi aplicado para focar nas áreas mais relevantes da imagem, seguido pela técnica de limiarização binária (*Thresholding*), que converteu a imagem em uma representação binarizada.
- **c) Primeira Camada Convolutiva (32 Filtros):** A imagem passou por uma camada convolutiva com 32 filtros 3x3, extraíndo características iniciais como bordas e texturas, ativadas pela função ReLU.
- **d) MaxPooling 1 (2x2):** Após a primeira convolução, a imagem é reduzida por uma camada de pooling, que diminui a dimensionalidade dos dados (redução de ruído), mantendo as características mais importantes.
- **e) Segunda Camada Convolutiva (64 Filtros):** A imagem processada passa por uma segunda camada convolutiva com 64 filtros de 3x3, onde são extraídas características mais complexas da imagem.
- **f) MaxPooling 2 (2x2):** Novamente, ocorre uma redução da dimensionalidade da imagem por meio de uma operação de MaxPooling.
- **g) Terceira Camada Convolutiva (128 Filtros):** Agora, a imagem passa pela terceira camada convolutiva com 128 filtros, identificando características de nível ainda mais alto.
- **h) MaxPooling 3 (2x2):** Outra operação de pooling é aplicada para reduzir ainda mais a dimensionalidade, mantendo as características essenciais.
- **i) Camada Flatten (Achatar):** Após o processamento convolutivo, a imagem é achatada em um vetor unidimensional para ser usada nas camadas densas da MLP.
- **j) Camada Densa (64 Neurônios):** O vetor de características passa por uma camada totalmente conectada (*Dense Layer*) com 64 neurônios, ativada pela função ReLU, para combinar e interpretar as características extraídas.
- **k) Camada de Saída (3 Classes):** A última camada densa usa a função de ativação Softmax para classificar a imagem em uma das três categorias: Dermatite Nodular, Berne, ou Saudável.
- **l) Saída (Predição da Doença):** O modelo retorna a classe prevista (uma das três doenças) e a probabilidade associada a essa predição.

Figura 2 – Funcionamento da IA



Fonte: Aurtoria Própria (2024)

As métricas avaliadas durante o treinamento da IA foram: épocas, acurácia e perda. As épocas referem-se ao número de vezes que o algoritmo de aprendizado percorre completamente o conjunto de dados de treinamento. Cada época consiste em um ciclo onde o modelo ajusta seus parâmetros com base no erro observado após processar todas as amostras de treinamento. Um aumento no número de épocas pode permitir que o modelo aprenda padrões mais complexos, mas também pode levá-lo a um risco maior de *overfitting* se o número for excessivo. Assim, encontrar o equilíbrio entre um número de épocas suficiente para que o modelo aprenda adequadamente, sem que isso comprometa sua generalização para dados novos é essencial.

A perda mede o quanto as predições do modelo se desviam das respostas corretas. Para problemas de classificação, a função de perda utilizada foi a entropia cruzada categórica (*categorical crossentropy*), que penaliza predições incorretas de forma mais acentuada, ajustando os pesos do modelo para melhorar a precisão das predições.

O treinamento inicialmente foi realizado com 100 épocas, evoluindo para 250 épocas e por fim 500 épocas, utilizando um gerador de dados que realiza a normalização das imagens, redimensionando-as para 64x64 *pixels* e escalando o valor dos *pixels* para o intervalo [0,1].

Nos primeiros 100 ciclos, o modelo apresentou uma acurácia de testes de 70% e um valor de perda estabilizado em torno de 2.41. As previsões individuais indicaram uma acurácia variável. O modelo foi avaliado em um conjunto de testes estratificados. Além disso, o modelo foi salvo para a utilização posterior em um servidor *Flask*, integrando-o a uma *Application Programming Interface* (API) que permite realizar previsões em novas imagens submetidas pelo usuário.

Técnicas de prevenção de *overfitting* foram implementadas ao longo do treinamento. O uso do *early stopping* foi essencial para monitorar o desempenho no conjunto de validação, interrompendo o treinamento quando a perda nesse conjunto começasse a aumentar. Além disso, as camadas de *dropout* foram incluídas para evitar que o modelo dependesse exclusivamente de combinações específicas de neurônios, promovendo maior robustez. A técnica de *data augmentation* também foi incorporada, aumentando artificialmente o conjunto de treinamento com transformações de imagem, como rotações e ajustes de brilho, para aumentar a variabilidade dos dados e melhorar a capacidade de generalização do modelo.

A base de dados utilizada no treinamento foi composta por 266 imagens de alta qualidade, distribuídas em três categorias: Dermatite Nodular (144 imagens), Berne (30 imagens) e Saudável (92 imagens). As imagens da categoria Saudável e Dermatite Nodular foram obtidas do banco público *Lumpy Skin Images Dataset* disponível no Mendeley Data, criado por Kumar e Shastri (2022), que contém imagens pré-processadas de pele saudável e com dermatite. As imagens da categoria Berne foram coletadas manualmente pelos autores, assegurando a mesma qualidade visual. Para garantir a validade do conjunto de dados, todas as imagens foram selecionadas com base em critérios de nitidez e relevância para o diagnóstico. A técnica de *Holdout* estratificado foi aplicada, com 80% das imagens alocadas para o treinamento e 20% para o teste. A função "*StratifiedShuffleSplit*" da biblioteca *scikit-learn* foi utilizada para garantir a distribuição equilibrada entre as classes nos conjuntos de treino e teste. Este processo assegurou que as imagens de diferentes condições não fossem misturadas, preservando a integridade do treinamento.

Por fim, a IA foi integrada a uma API desenvolvida em *Flask*, que permite a classificação de novas imagens de bovinos enviadas via requisições HTTP. A API recebe a imagem, realiza o pré-processamento adequado e faz a previsão utilizando o modelo treinado. A resposta inclui a classe prevista, sendo elas Dermatite Nodular, Berne ou Saudável e a probabilidade associada à previsão. Essa arquitetura modular, com uma API acessível via rede, possibilita a utilização prática do modelo em um ambiente de produção, facilitando a análise e diagnóstico em tempo real de condições dermatológicas de bovinos.

Essa abordagem, combinando CNNs e MLPs em um ambiente de hardware otimizado, mostra-se eficiente para a tarefa de classificação de imagens bovinas, sendo uma contribuição relevante para a área de monitoramento e diagnóstico veterinário assistido por IA.

ANÁLISE DE COMPLEXIDADE: RELAÇÕES DE RECORRÊNCIA E ASSINTÓTICA

O algoritmo *Merge Sort* foi aplicado na etapa de pré-processamento da IA para ordenar os arquivos de imagem presentes nos diretórios de treino e teste antes do carregamento para o modelo. Essa ordenação visa garantir uma organização consistente das imagens, mantendo uma sequência definida e minimizando possíveis desvios de ordem que poderiam impactar o fluxo de dados. No código, cada diretório de imagens é listado, e o *Merge Sort* atua dividindo as listas de arquivos em metades até que cada segmento contenha apenas um elemento. Em seguida, as listas são mescladas de forma ordenada, resultando em uma única

lista final ordenada. Posteriormente, as imagens são processadas por geradores de dados configurados com "*ImageDataGenerator*", que realizam *data augmentation* nas imagens de treino para aumentar a variabilidade, enquanto as imagens de teste são apenas normalizadas. Durante a geração dos lotes, o parâmetro "*shuffle=False*" garante que as imagens sejam carregadas de acordo com a ordem estabelecida, permitindo um fluxo organizado e uniforme dos dados ao longo do treinamento e avaliação do modelo.

O *Merge Sort* é um algoritmo de ordenação que utiliza o método de divisão e conquista, alcançando uma complexidade assintótica de $O(n \log n)$, onde n é o número de elementos na entrada. Esse desempenho estável e eficiente torna-o apropriado para situações onde a ordenação prévia otimiza o processamento subsequente.

A complexidade do *Merge Sort* é modelada por uma relação de recorrência que reflete suas operações: dividir a entrada em duas metades, ordenar cada metade recursivamente e mesclá-las em uma lista ordenada. Para uma entrada de tamanho n , a relação de recorrência do tempo de execução é:

$$T(n) = 2 \cdot T\left(\frac{n}{2}\right) + O(n), \quad (1)$$

onde $T(n)$ representa o tempo de execução para ordenar n elementos. Usando o Teorema Mestre, essa relação resolve-se para $O(n \log n)$, pois o algoritmo executa $\log n$ divisões e cada nível de recursão requer uma mesclagem linear de $O(n)$.

Além disso, o *Merge Sort* tem complexidade de espaço de $O(n)$, usada para armazenar as sublistas temporárias durante a mesclagem, o que permite uma ordenação estável e eficiente dos elementos. Assim, a análise assintótica confirma a complexidade de $O(n \log n)$, tornando-o ideal para cenários que requerem uma ordenação consistente e confiável de grandes conjuntos de dados.

METODOLOGIA DE DESENVOLVIMENTO MÓVEL

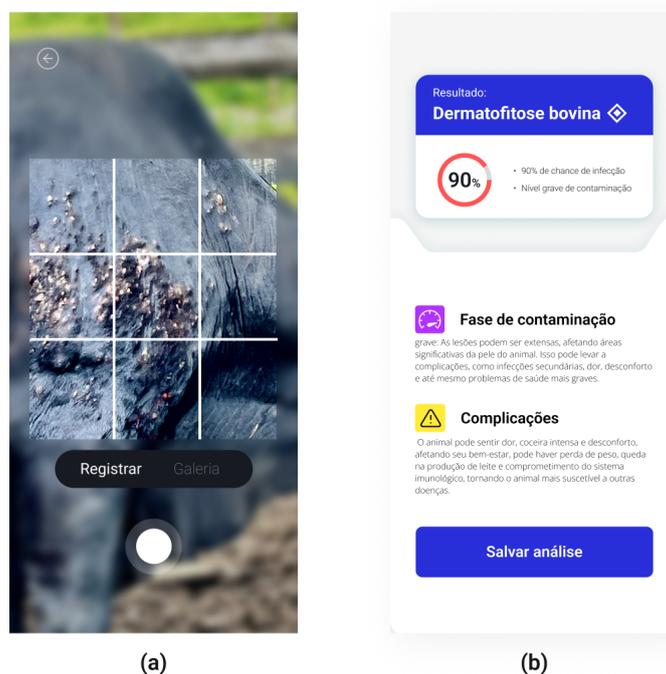
O público-alvo deste trabalho são os pecuaristas, que terão acesso aos recursos via uma aplicação móvel. Para facilitar o pré-diagnóstico do berne, da dermatite nodular contagiosa e da dermatofitose e dermatofilose bovinas, desenvolveu-se essa aplicação. O projeto capacita os pecuaristas a cadastrar e analisar imagens para facilitar o diagnóstico veterinário final.

Devido à quantidade e diversidade dos dados, optou-se por utilizar o MongoDB, um banco de dados de alto desempenho, como os Bancos de Dados Não-Relacionais (NoSQL). Os NoSQL são sistemas distribuídos que gerenciam dados semi-estruturados e não-estruturados, oferecendo escalabilidade simplificada e não requerendo servidores robustos ou grande equipe para gerenciamento (Oliveira, 2014).

A API a ser desenvolvida seguirá a arquitetura de microsserviços para facilitar a comunicação entre os componentes do sistema. A linguagem de programação Node JS foi escolhida para o back-end devido à sua popularidade e eficiência, usada na construção da API que garantirá a integração entre a aplicação, a IA e o banco de dados.

A aplicação possui duas interfaces principais que formam o núcleo deste projeto. A Figura (Fig. 3a) ilustra a interface de envio das imagens, onde o usuário poderá optar por gravar uma nova imagem ou enviar uma foto previamente capturada. Após o envio da imagem, o processo de pré-diagnóstico é iniciado e conduzido pela IA, por meio de um algoritmo baseado em CNN e MLP. Em seguida, o pecuarista é redirecionado para a interface exibida

Figura 3 – Processo de análise



Fonte: Autoria Própria (2024)

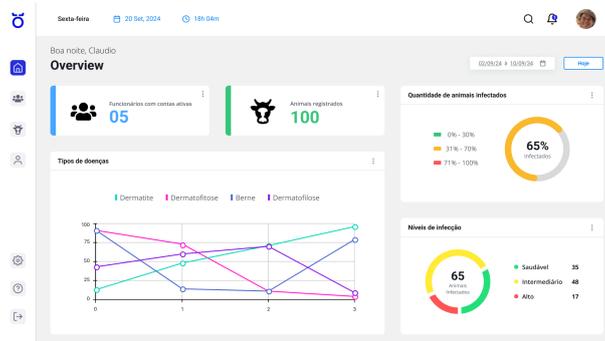
na Figura (Fig. 3b, onde os resultados são expostos. Nela, o pré-diagnóstico é explicado detalhadamente, indicando a doença detectada, o estágio de evolução caso o resultado dentro da probabilidade de ser positivo, e as potenciais complicações que o animal poderá enfrentar em cada fase da doença. Todos esses dados são registrados na aplicação móvel, permitindo ao usuário que os consulte posteriormente.

METODOLOGIA DE DESENVOLVIMENTO DA APLICAÇÃO WEB

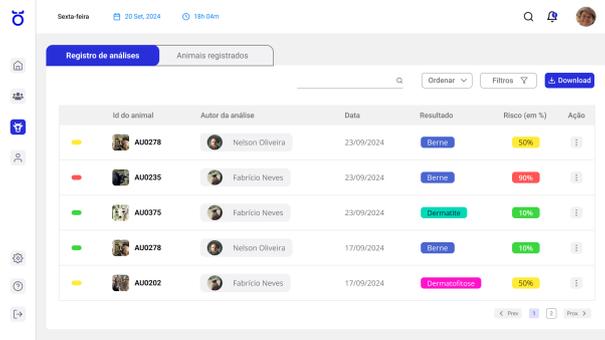
om o intuito de promover um monitoramento detalhado das análises registradas pela aplicação e, conseqüentemente, da saúde dos animais, foi desenvolvida uma aplicação Web, cuja principal função é estruturar os dados de forma a fornecer informações relevantes ao administrador. Em virtude dessa função e por atuar como um complemento à aplicação móvel, a base de dados utilizada é compartilhada entre ambas. Da mesma forma, a API é utilizada de maneira compartilhada, assegurando que todas as regras e comunicações estejam centralizadas. Devido à sua natureza Web, a biblioteca de estilos React foi escolhida para a construção da plataforma.

A Figura (Fig. 4) ilustra a essência da aplicação Web. A interface, exposta pela Figura (Fig. 4a), tem como sua principal função apresentar as informações significativas ao seu administrador, possibilitando a tomada de decisões informadas sobre ações futuras. A Figura (Fig. 4b) exibe a interface conectada diretamente às análises feitas pela aplicação para dispositivos móveis. Nela, serão evidenciadas todas as análises feitas de forma minuciosa, destacando não somente a probabilidade retornada pela IA para uma determinada imagem, mas também o responsável por cada uma das análises, levando em consideração as propriedades pecuárias com grandes rebanhos bovinos.

Figura 4 – Aplicação Web



a)



b)

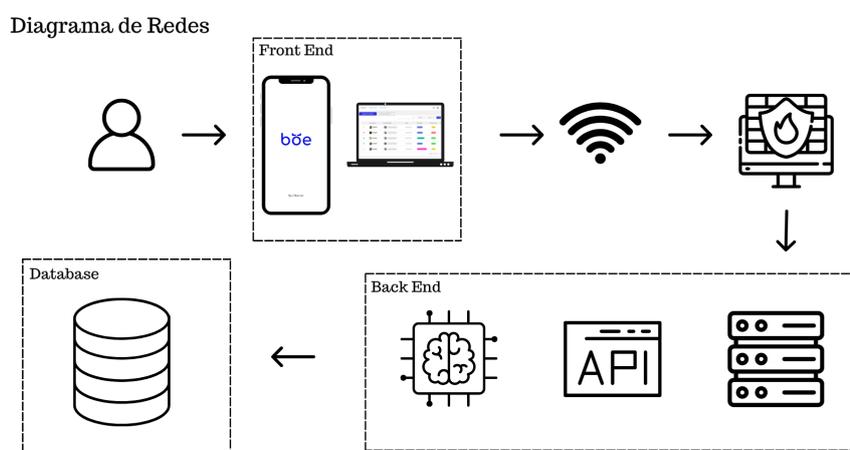
Fonte: Autoria Própria (2024)

METODOLOGIA DE DESENVOLVIMENTO DA REDE

O sistema de estrutura de rede do projeto é dividido em cinco partes, sendo elas: o *Front-end* da aplicação móvel e da aplicação *Web*, onde o usuário fará as interações com os recursos disponíveis; uma API criada em Node JS, que centralizará a comunicação entre os *Front-ends*, a base de dados, a Rede Neural e as rotas do sistema; uma segunda API contendo a Rede Neural, desenvolvida em *Python*, para que o envio das imagens a serem analisadas e o retorno do pré-diagnóstico sejam possíveis através da aplicação móvel; e ainda uma base de dados em nuvem.

O fluxo de comunicação inicia-se a partir de uma interação com a aplicação móvel, a qual envia uma requisição à API responsável. Esta, por sua vez, realiza uma consulta à base de dados e estrutura as informações de acordo com o formato requerido pela aplicação. Durante o processo de pré-diagnóstico, além da consulta ao banco de dados, a API envia uma requisição adicional para a Rede Neural. Após a análise da imagem fornecida, a Rede Neural retorna os resultados à API, que então os repassa à aplicação móvel. Considerando a necessidade de disponibilizar informações relevantes na aplicação *Web*, ao haver uma interação com esta plataforma, uma requisição é enviada para a mesma API, que processa e retorna a resposta de acordo com os parâmetros solicitados.

Fluxograma 1 – Arquitetura do fluxo das redes



Fonte: Autoria Própria (2024)

RESULTADOS PRELIMINARES

Ao longo deste trabalho, foram realizados três treinamentos distintos utilizando 100, 250 e 500 épocas, com o objetivo de otimizar a acurácia do modelo na classificação de lesões dermatológicas em bovinos. O desempenho do modelo foi mensurado com base em métricas como acurácia, perda (*loss*) e a validação cruzada com os conjuntos de teste, tanto para as métricas de acurácia quanto para as de perda. A análise dos resultados permitiu observar a evolução do modelo à medida que o número de épocas aumentou, culminando em um desempenho superior no treinamento de 500 épocas.

Além da acurácia e da perda no conjunto de treinamento, foram também avaliadas as métricas de validação, obtidas ao testar o modelo em um subconjunto separado de dados que não foram utilizados durante o treinamento. A acurácia de validação oferece uma estimativa mais realista da capacidade de generalização do modelo.

Compreendendo a importância da análise minuciosa dos resultados de treinamento, este trabalho buscar elucidar como diferentes períodos de treinamento impactaram a acurácia do modelo na classificação de lesões dermatológicas em bovinos. As seguintes análises serão feitas com base nos resultados obtidos para treinamentos de 100, 250 e 500 épocas, levando em consideração as métricas finais e as previsões de classes.

TREINAMENTO DA IA

Durante o treinamento de 100 épocas, o modelo apresentou uma acurácia de 76.53% e uma perda estabilizando em torno de 0.635945797. Contudo, as métricas das últimas épocas indicaram um desempenho variável. Com o aumento para 250 épocas, a acurácia do modelo estabilizou em 73.24%, com uma perda firmada em 0.6655.

Finalmente, o treinamento com 500 épocas foi o mais promissor por classificar mais imagens corretamente, resultando em uma acurácia final de 75.11% e uma perda de 0.6938. As métricas obtidas resultaram:

Tabela 1 – Análise dos Resultado com 500 épocas

Métrica	Valor (%)
Acurácia	75.11%
Perda	0.6938
Acurácia de Validação	75.99%
Perda de Validação	0.7317

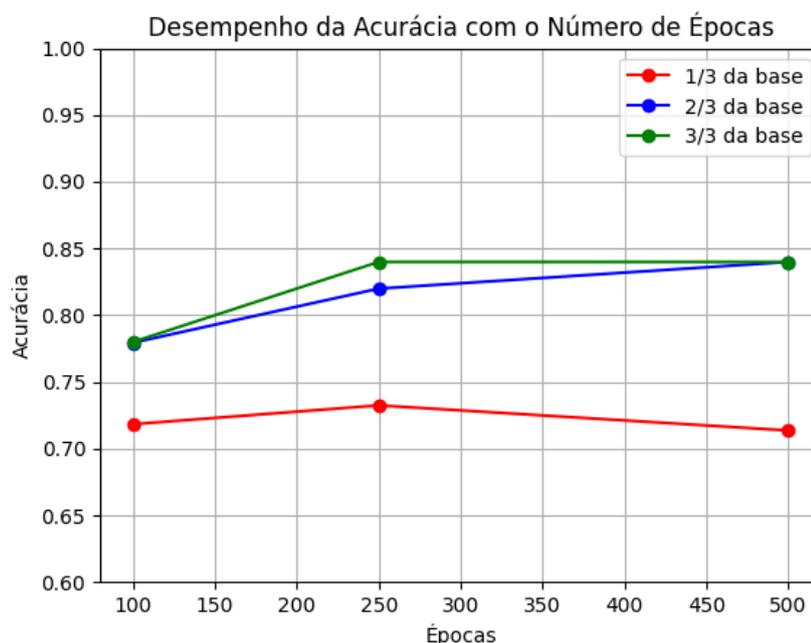
Fonte: Próprio Autor, (2024)

Os resultados indicaram uma melhora geral nas previsões, especialmente nas classes mais consistentes, o modelo ainda apresentou alguns desafios, embora menores. Dessa forma, esse foi o modelo escolhido para as etapas subsequentes do trabalho.

RESULTADO DO TREINAMENTO

O gráfico abaixo demonstra a evolução da acurácia à medida que o número de épocas aumenta, considerando diferentes porções da base de dados (1/3, 2/3 e 3/3). Como visto, a acurácia melhora significativamente com mais épocas, especialmente a partir de 250 épocas, onde a base completa (3/3) e duas partes da base (2/3) mostram valores superiores a 80% de acurácia, enquanto a mesma utilizando 1/3 da base permanece mais limitada.

Gráfico 1 – Desempenho da Acurácia com o Número de Épocas



Fonte: Autoria Própria (2024)

Esse comportamento reforça a ideia de que o aumento das épocas e a utilização de uma base de dados maior ajudam a refinar as previsões do modelo. Dessa forma, o modelo apresenta progresso conforme mais dados e épocas são utilizadas, mas ainda enfrenta alguns desafios em classes específicas.

LIMITAÇÕES

As limitações deste estudo incluem, primeiramente, a ausência de uma base de dados própria abrangendo todas as doenças de interesse, que no caso são: dermatofitose, dermatofilose e dermatite nodular contagiosa bovina. Essa limitação restringe a capacidade de generalização do modelo para essas condições. Além disso, a base de dados utilizada apresentou uma quantidade limitada de imagens da classe "Berne", o que pode ter impactado significativamente a precisão das previsões dessa categoria específica.

Outro fator limitante foi a falta de testes em contextos regionais que incluam as três doenças mencionadas, já que elas não ocorrem com frequência onde o estudo foi conduzido, inviabilizando a validação completa do modelo. Por fim, o treinamento da IA foi realizado em uma máquina com uma GPU *Radeon RX6600* (8GB GDDR6) e um processador *Intel Xeon E5-2670 v3*, suportada por 16GB de RAM DDR4. Embora essa configuração tenha possibilitado a execução eficiente do modelo, com aceleração por hardware, ela ainda representa uma limitação para treinar redes mais complexas ou com volumes maiores de dados.

CONCLUSÃO

Tendo em vista a grande influência da agropecuária bovina na economia, o presente estudo demonstra a relevância científica e o potencial benefício do sistema de classificação de imagens no pré-diagnóstico de doenças dermatológicas bovinas. A detecção precoce e o diagnóstico preciso da dermatofitose, dermatofilose e dermatite nodular contagiosa possibilitam o tratamento adequado dos animais afetados, evitando seu sofrimento e minimizando a disseminação das doenças. O uso eficiente de recursos é favorecido pelo sistema proposto, que reduz a necessidade de intervenção humana no processo de diagnóstico, otimizando o tempo e os recursos envolvidos. Além disso, a utilização de técnicas de Aprendizagem Profunda contribui para a automatização e padronização do diagnóstico, reduzindo possíveis erros humanos e garantindo resultados mais consistentes.

Como parte integral dos trabalhos futuros, o foco será na melhoria contínua da IA, aperfeiçoando o modelo atual e avaliando diferentes algoritmos para que ele possa atender outras condições dermatológicas.

Embora haja a necessidade de testes em um cenário real e uma análise completa da viabilidade do projeto, seu embasamento científico sólido e seu potencial para aprimorar a saúde animal o tornam uma iniciativa promissora, capaz de contribuir para o avanço do conhecimento e o desenvolvimento de soluções efetivas para as doenças dermatológicas bovinas e em outros animais.

REFERÊNCIAS

AGES - AUSTRIAN AGENCY FOR HEALTH AND FOOD SAFETY. Lumpy Skin Disease: Overview and Control Measures. **AGES Website**, 2023. Accessed: 2024-05-31. Disponível em: <<https://www.ages.at/en/human/disease/pathogens-from-a-to-z/lumpy-skin-disease>>.

AVANTE, Michelle Lopes *et al.* Dermatofitose em grandes animais. **Revista Científica Eletrônica de Medicina Veterinária**, v. 7, n. 12, p. 1–7, 2009.

CAMPONOGARA, Eduardo; SEMAN, Laio Oriel. Redes neurais ReLU como funções de aproximação em problemas inteiros-mistos.

CUNHA, Paulo Henrique Jorge da *et al.* Dermatofilose em bovinos criados em regime de confinamento. Brasil, 2010.

FALCÃO, João Vitor Regis *et al.* Redes neurais deep learning com tensorflow. **RE3C-Revista Eletrônica Científica de Ciência da Computação**, v. 14, n. 1, 2019.

FERREIRA, CRRPT *et al.* Caracterização da pecuária bovina no Estado de São Paulo. **INFORMACOES ECONOMICAS-GOVERNO DO ESTADO DE SAO PAULO INSTITUTO DE ECONOMIA AGRICOLA**, INSTITUTO DE ECONOMIA AGRICOLA, v. 29, p. 7–30, 1999.

GOMES, A. Berne: um pequeno parasito, porem um grande problema. Campo Grande, MS: EMBRAPA-CNPQC, 1998., 1998.

HAAS, Dionei Joaquim; TORRES, Ana Caroline Doyle. Dermatofilose em bovinos. **REVISTA VETERINÁRIA EM FOCO**, v. 13, n. 2, 2016.

LOPES, EDNA. SISTEMA NEURAL PARA PREDIÇÃO DE BRUCELOSE EM REBANHOS BOVINOS, 2016.

LU, Fangfang *et al.* CMM: A CNN-MLP Model for COVID-19 Lesion Segmentation and Severity Grading. **IEEE/ACM Transactions on Computational Biology and Bioinformatics**, p. 1–14, 2023. DOI: 10.1109/TCBB.2023.3253901.

OLIVEIRA, Samuel Silva de. Bancos de dados Não-Relacionais: um novo paradigma para armazenamento de dados em sistemas de ensino colaborativo. **Revista da Escola de Administração Pública do Amapá**, v. 2, n. 1, p. 184–194, 2014.

SANTOS, Igor Pedro Pinto dos. **Análise de sentimento usando redes neurais de convolução**. 2017. Tese (Doutorado) – Dissertação (Mestrado em Engenharia Eletrônica), Universidade do Estado do ...

SILVEIRA, Erica Silva da *et al.* Trichophyton verrucosum em bovinos com pele hígida e com lesões. **Acta Scientiae Veterinariae**, v. 31, n. 1, p. 45–49, 2003.

WEISS, K.E. Lumpy skin disease - A virus disease of cattle. **Bulletin de l'Office International des Epizooties**, v. 62, p. 517–527, 1964.