

Método Computacional Para Automação do FAMACHA em Cabras e Ovelhas

Mauricio Benjamin da Rocha¹, José Lindenberg Rocha Sarmiento^{3,2}, Natanael Santosa³, Ricardo Andrade Lira Rabelo^{4,2}, Romuere Rodrigues Veloso e Silvano^{1,2}, Antônio Oseas de Carvalho Filho^{1,2}, Flávio Henrique Duarte de Araújo^{1,2}

¹Departamento de Sistemas de Informação e Engenharia Elétrica, Universidade Federal do Piauí (PI) – Picos, PI – Brasil

²Departamento de Engenharia Elétrica, Universidade Federal do Piauí (PI) – Teresina, PI – Brasil

³Departamento de Zootecnia, Universidade Federal do Piauí (PI) – Teresina PI – Brasil

⁴Departamento de Computação, Universidade Federal do Piauí (PI) – Teresina PI – Brasil

{mauriciobenjamin,sarmiento, natanael, ricardoalr romuere, antoniooseas, flavio86 }@ufpi.edu.br

Abstract. *The breeding of goats and sheep is crucial to Brazil's economy, providing resources, driving local development, and generating jobs. However, producers face challenges in maintaining the health of their herds due to parasites, such as the stomach worm (*Haemonchus contortus*), which cause anemia and weight loss, thereby reducing productivity. The FAMACHA method, used to monitor herd health, is labor-intensive, subject to human error, and requires specialized training, with subjective interpretations that can lead to inaccurate diagnoses and inappropriate treatments. This work proposes to develop a methodology using computer vision and artificial intelligence to automate the FAMACHA method.*

Resumo. *A criação de cabras e ovelhas é crucial para a economia do Brasil, fornecendo insumos, impulsionando o desenvolvimento local e gerando empregos. No entanto, produtores enfrentam desafios na saúde de seus rebanhos devido a parasitas, como o verme do estômago (*Haemonchus contortus*), que causam anemia e perda de peso, reduzindo a produtividade. O método FAMACHA, utilizado para monitorar a saúde dos rebanhos, é trabalhoso, sujeito a erros humanos e requer treinamento especializado, com interpretações subjetivas que podem resultar em diagnósticos imprecisos e tratamentos inadequados. Este trabalho propõe desenvolver uma metodologia com visão e inteligência computacional para automatizar o método FAMACHA.*

1. Introdução

A criação de cabras e ovelhas exerce um papel significativo na economia agrícola brasileira, proporcionando diversos benefícios ao setor agropecuário. Tais animais são importantes fontes de proteína, fornecendo carne, leite e derivados para a população e contribuindo para a segurança alimentar do país. A criação é uma atividade que impacta positivamente as áreas rurais, gerando empregos e promovendo o desenvolvimento econômico

local [Nascimento 2022]. A pecuária desses animais é reconhecida por sua sustentabilidade, já que são adaptados ao clima tropical brasileiro e têm menor impacto ambiental comparado a outros ruminantes. Ademais, a criação de cabras e ovelhas desempenha um papel essencial na diversificação da produção agrícola do Brasil, permitindo a participação de pequenos e médios produtores [Magalhães et al. 2021].

Cuidados adequados com a saúde de cabras e ovelhas são fundamentais para o bem-estar, produtividade e rentabilidade da criação. Isso inclui medidas preventivas como vacinação, nutrição equilibrada e higiene, além da observação constante para detectar sinais de doença ou parasitismo. Um grande desafio é combater o parasita *Haemonchus contortus*, prevalente em regiões tropicais e subtropicais, causando anemia grave, perda de peso e baixo desempenho reprodutivo [Martins et al. 2016]. A resistência do parasita a medicamentos torna o controle complexo, tornando essencial investir em cuidados de saúde e estratégias eficazes para garantir um rebanho saudável e produtivo [Arshad et al. 2024]. Isso contribuirá para a sustentabilidade da criação de cabras e ovelhas no Brasil, fortalecendo o setor agropecuário e fornecendo produtos de qualidade.

O método FAMACHA é usado na seleção de animais para vermifugação, baseada na observação da coloração da mucosa ocular do animal em comparação com um cartão que associa as cores a seus respectivos graus anêmicos [de Oliveira Diniz et al. 2022]. Este teste consiste em categorizar a coloração em cinco níveis, onde as cores vermelhas indicam boa saúde e as cores esbranquiçadas indicam possíveis traços de anemia, sinalizando a necessidade de tratamento [Teixeira et al. 2023]. Embora seja uma ferramenta útil, sua eficácia pode ser afetada pela subjetividade do examinador, exigindo profissionais treinados para realizar a avaliação consistentemente em todo o rebanho. É importante destacar que variações ou erros podem ocorrer devido à fadiga durante o procedimento, tornando a avaliação do rebanho por um único profissional altamente recomendável.

Com base no exposto, este trabalho consiste em desenvolver uma metodologia fundamentada em visão e inteligência computacional, para identificar a necessidade de vermifugação em cabras e ovelhas. A identificação será efetuada por meio de imagens da mucosa ocular dos animais, possibilitando uma análise rápida e precisa. A referida metodologia poderá ser implementada em ferramentas de auxílio para os profissionais do ramo, viabilizando a realização do teste em quantidades substanciais de animais ao longo do tempo, sem que haja uma degradação na coerência dos dados. Com esta solução, mais indivíduos poderão efetuar o teste no mesmo rebanho, resultando em uma maior eficiência e precisão do processo de detecção da necessidade de medicação dos animais.

2. Trabalhos Relacionados

Nesta seção, são apresentados trabalhos que compartilham objetivos similares ao deste trabalho. A busca na literatura considerou apenas termos relacionados ao tema proposto neste trabalho. Os estudos retornados foram classificados e sintetizados conforme a relação de seu conteúdo ao contexto apresentado. Isto permitiu que fossem coletadas informações a respeito da metodologia proposta por cada trabalho, bem como a percepção de lacunas que poderiam ser preenchidas com outras técnicas além das usadas em cada estudo. Esta base de conhecimentos ajuda na formulação de uma nova metodologia, que seja mais robusta em relação aos trabalhos relacionados, e que preencha as lacunas encontradas, contribuindo para o desenvolvimento de uma solução definitiva.

O trabalho de [RIBEIRO 2018] explorou técnicas de segmentação e classificação para detectar anemia em pequenos ruminantes. Na segmentação, foram aplicados filtros e operadores morfológicos para segmentar a conjuntiva das imagens, utilizando o canal H do espaço de cor HSV, seguido por operações de limiarização e erosão. Para a extração de características, foram aplicadas técnicas como *Border Interior Classification* (BIC) e características estatísticas, incluindo média, variância, desvio padrão, curtose e assimetria. Na etapa de classificação, foram empregados os algoritmos KNN (k-Nearest Neighbors) e SVM. O KNN apresentou melhores resultados na classificação, especialmente quando aplicado às características estatísticas do canal H aplicado a conjuntiva. Os resultados da segmentação mostraram uma taxa de acerto de 86%, enquanto a classificação com KNN obteve uma acurácia variando entre 71,4% e 82,5%, dependendo das condições específicas. O estudo utilizou um total de 114 imagens, sendo 47 de caprinos e 67 de ovinos.

Em sua pesquisa, [Almeida 2021] utilizou várias técnicas de segmentação e classificação. Na segmentação, ele avaliou os modelos U-Net, *Fully Convolutional Networks* (FCN), DeepLabV3 e ERFNet, alcançando acurácias de até 97,29% com normalização para a U-Net e 96,65% para a FCN. Em uma base de dados de 105 imagens de ovinos e caprinos, os modelos apresentaram resultados variados, com a U-Net alcançando 78,06% com normalização. Para a classificação, foi utilizado ResNet-50 e a MobileNetV2, onde a MobileNetV2 conseguiu atingir uma acurácia de validação entre 70,00% e 75,00%, e a melhor acurácia de 95,23% sem normalização. Os dados utilizados totalizaram 105 imagens fornecidas por pesquisadores da Universidade Federal do Maranhão (UFMA). Esses resultados demonstram a eficácia dos modelos implementados, especialmente com normalização, destacando a U-Net e FCN na segmentação e MobileNetV2 na classificação.

O estudo de [Souza Filho et al. 2022], aborda a classificação utilizando três modelos de Redes Neurais Convolucionais: AlexNet, LeNet-5 e ZFNet. O modelo AlexNet, durante o treinamento, apresentou uma acurácia de 62%, mas teve dificuldades significativas em classificar corretamente animais doentes, frequentemente categorizando-os como saudáveis. Por outro lado, o modelo LeNet-5 apresentou um desempenho ainda mais insatisfatório, durante a classificação, atribuiu todas as amostras a uma única classe, resultando em uma acurácia geral de apenas 58%. O modelo ZFNet destacou-se como o mais eficiente, alcançando uma acurácia geral de 81%. Especificamente, a ZFNet demonstrou uma precisão de 92% na classificação de animais doentes e 71% para animais saudáveis, com pontuações F1 de 81% para animais doentes e 80% para animais saudáveis. Este modelo foi considerado o mais adequado para implementação prática, treinado com um total de 128 imagens e integrado a um sistema de classificação usando frameworks da linguagem Python como Flask e FastAPI para disponibilizar a API de classificação de imagens de mucosa ocular.

O trabalho de [de Souza et al. 2023] discute o desenvolvimento de um aplicativo móvel para auxiliar no controle de *Haemonchus contortus* em pequenos ruminantes. Foi utilizada a câmera do celular para adquirir imagens da mucosa conjuntival dos animais, classificando-os como saudáveis ou anêmicos por meio de técnicas de aprendizado de máquina. A classificação de animais como saudáveis ou anêmicos, alcançou 83% de precisão com uma rede neural sequencial e 87% SVM, sendo esta última a implementada no aplicativo. As técnicas incluíram estimativas estatísticas das funções de densidade de probabilidade para cada canal de cor, em modelos RGB ou HSV, e otimização com

Adabound para a rede neural. O banco de dados de imagens consistiu em 317 imagens de mucosa conjuntival ocular, coletadas de cinco rebanhos no sul do Brasil. Não houve uso de segmentação automática na versão atual, embora uma futura versão planeje incluir um subsistema de segmentação automática da mucosa conjuntival.

Tabela 1. Comparativo descritivo dos trabalhos relacionados.

Trabalho	Objetivo	Métodos	Algoritmos	Quantidade de Imagens	Resultados	Limitações
[RIBEIRO 2018]	Desenvolver uma metodologia fundamentada em visão computacional	Segmentação, Classificação	KNN, SVM	114	Segmentação: 86% Classificação: 82,5%	Quantidade de Imagens
[Almeida 2021]	Desenvolver uma metodologia fundamentada em visão computacional	Segmentação, Classificação	U-Net, FCN, DeepLabV3, ERFNet, ResNet-50, MobileNetV2	105	Segmentação: 97,29% Classificação: 95,23%	Quantidade de Imagens
[Souza Filho et al. 2022]	Construção de uma API	Classificação	AlexNet, LeNet-5, ZFNet	128	Classificação: 82,5%	Quantidade de Imagens
[de Souza et al. 2023]	Construção de um aplicativo móvel	Classificação	Rede neural sequencial, SVM	317	Classificação: 87%	Custo computacional para integração de segmentação

Os estudos revisados adotam métodos consistentes e obtêm resultados significativos ao empregar o método FAMACHA, conforme ilustrado na Tabela 1. No entanto, algumas limitações são evidentes. [RIBEIRO 2018] destacou desafios na segmentação e classificação, obtendo uma acurácia de 86% e entre 71,4% e 82,5% respectivamente, mas enfrentou dificuldades devido à quantidade limitada de imagens (114). [Almeida 2021] alcançou excelentes resultados com a U-Net (97,29%) e a MobileNetV2 (95,23%), porém, também sofreu com a escassez de dados (105 imagens). [Souza Filho et al. 2022] demonstraram que a ZFNet era a mais eficiente com uma acurácia de 81%, mas a dependência de segmentação manual limitou a aplicabilidade prática. [de Souza et al. 2023] desenvolveram um aplicativo móvel com SVM, alcançando 87% de precisão, mas a ausência de segmentação automática foi uma limitação significativa, embora planejassem implementá-la em futuras versões. Portanto, considerando estas percepções, nosso trabalho visou desenvolver uma estratégia que integre processos e técnicas para superar as lacunas identificadas, promovendo integrar segmentação e classificação com uma base de dados de 450 imagens.

3. Metodologia

A metodologia adotada para este trabalho está apresentada visualmente por meio da Figura 1. A metodologia consiste em realizar a aquisição da base de imagens através da coleta e classificação manual em rebanhos, pré-processamento dos dados visando separar

a zona de interesse do restante da imagem, extração de características via descritores matemáticos e ao final realizar a classificação dos dados direcionando-se para uma predição sobre a situação da saúde do animal.

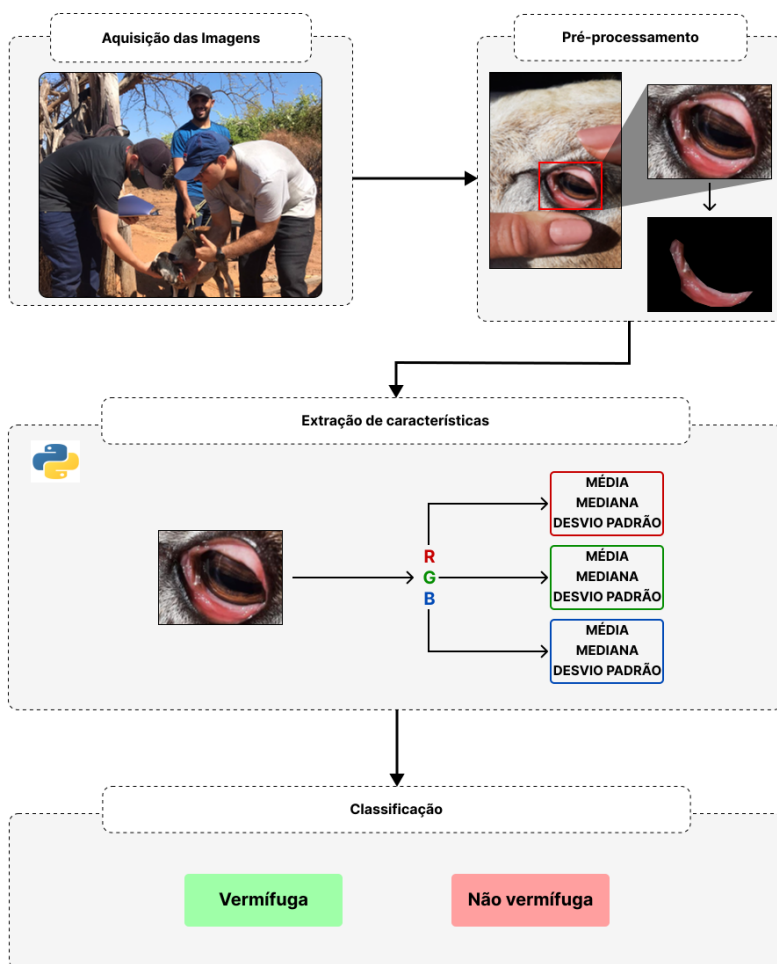


Figura 1. Metodologia adotada

3.1. Aquisição de imagens

A ausência de uma base de dados pública de mucosas oculares de pequenos ruminantes representa uma barreira significativa no desenvolvimento desta metodologia. Foram realizadas viagens de campo, visitando produtores com rebanhos variados visando adquirir imagens aplicando o método FAMACHA para coleta e classificação em diversos rebanhos. No total, foram coletadas 450 imagens, classificadas nas classes 1, 2, 3, 4 e 5 por um profissional especializado, conforme especificado no cartão FAMACHA apresentado na Figura 2. Devido à quantidade limitada de dados por classe, as imagens foram agrupadas em duas novas categorias: Vermífuga e Não Vermífuga. A classe Vermífuga é composta por imagens de animais nas classes 3, 4 e 5, que variam desde o estágio adequado para vermifugação até o estado crítico, onde a vermifugação deve ser realizada o mais rapidamente possível. Já a classe Não Vermífuga inclui as classes 1 e 2, que correspondem a animais não anêmicos ou em estágio inicial de anemia, permitindo adiar a

vermifugação sem prejudicar os animais e reduzir o uso de medicamentos. Este agrupamento facilita a consistência dos algoritmos de aprendizado de máquina, ao reduzir o problema de predição de cinco classes para apenas duas. A Tabela 2 apresenta a distribuição dos dados juntamente com o referido agrupamento, já a Figura 3 apresenta exemplos unitários de todas as classes.



Figura 2. Cartão FAMACHA padrão usado em exames

Tabela 2. Distribuição dos dados entre classes do cartão e agrupando

Classe	1	2	3	4	5	Vermífuga	Não Vermífuga
Quantidade	60	128	185	67	10	262	188
Percentual (%)	13.33	28.44	41.11	14.89	2.22	58,22	41,78

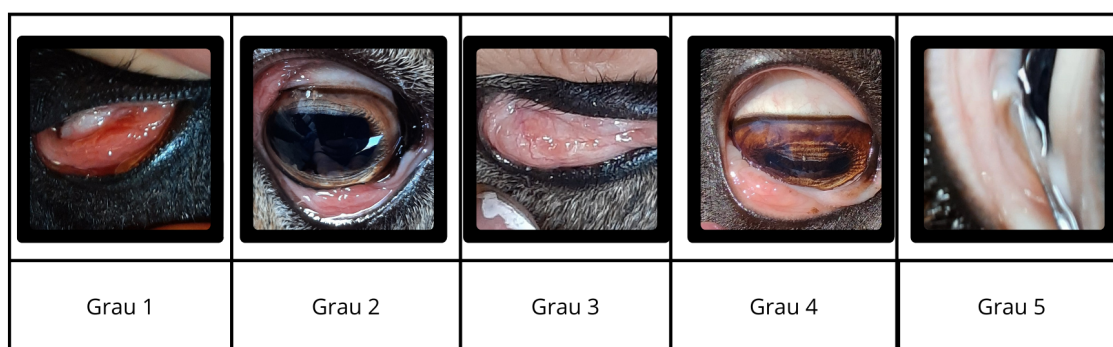


Figura 3. Exemplos de imagens contidas na base

3.2. Pré-processamento

Com a expansão contínua da quantidade de dados disponíveis, fez-se necessário o desenvolvimento de algoritmos capazes de realizar o recorte automatizado de imagens, segmentando exclusivamente a mucosa ocular dentre os demais elementos presentes na imagem.

Um dos algoritmos mais notáveis para essa finalidade é a YOLOv8n, cujo acrônimo significa “You Only Look Once” (Você Só Olha Uma Vez), reconhecido por sua eficiência na detecção de objetos e segmentação com um custo computacional significativamente melhor que em suas outras versões [Jiang et al. 2022]. Ao contrário de métodos tradicionais que realizam múltiplas fases de processamento, a YOLOv8n consegue identificar e localizar objetos em uma imagem de forma eficiente e com alta precisão, mesmo em imagens complexas. Usando a linguagem de programação *Python*, que fornece uma ampla gama de bibliotecas e *frameworks* de aprendizado de máquina, foi possível integrar o YOLO para desenvolver um algoritmo que automatiza o recorte e a segmentação da mucosa ocular. Este processo não só aumenta a eficiência na análise de imagens como também melhora a consistência e a precisão na extração das regiões de interesse.

3.3. Extração de Características

As imagens da base estão no formato RGB, onde cada *pixel* é composto por uma combinação de três cores primárias: vermelho (Red), verde (Green) e azul (Blue). Cada uma dessas cores é expressa numericamente em uma escala de 0 a 255, indicando a intensidade de sua contribuição. Portanto, a cor de um *pixel* é determinada pela combinação ponderada desses valores, resultando em uma vasta gama de cores e tonalidades na imagem [Arshad et al. 2024]. Para a extração das características, utilizamos o cálculo da Média, Mediana e Desvio Padrão para cada canal de cor das imagens separadamente e ao final, usando em todos os canais juntos, conforme Equações 1, 2 e 3.

$$\text{Média} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

$$\text{Mediana} = \begin{cases} x_{(n+1)/2} & \text{se } n \text{ ímpar} \\ \frac{x_{n/2} + x_{(n/2)+1}}{2} & \text{se } n \text{ par} \end{cases} \quad (2)$$

$$\text{Desvio Padrão} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

Tais métricas estatísticas fornecem uma descrição da distribuição das intensidades de cor em cada canal, permitindo uma análise das propriedades das imagens. A Média captura o valor central das intensidades de cor, a Mediana fornece uma medida contra valores extremos e o Desvio Padrão quantifica a variação das intensidades ao redor da média. Combinando essas medidas para cada canal de cor, é possível caracterizar as imagens de forma mais completa e identificar padrões importantes que podem auxiliar na classificação e análise das imagens.

3.4. Classificação

O algoritmo *Random Forest* (RF) foi escolhido como ferramenta de classificação pela sua capacidade superior de lidar com a variabilidade e complexidade dos dados em comparação com algoritmos clássicos como *Support Vector Machine* (SVM), *Multi-Layer Perceptron* (MLP) e *K-means*. O RF é um método de aprendizado de máquina que constrói

um conjunto de árvores de decisão e, subsequentemente, combina suas previsões para obter um resultado. Cada árvore de decisão é construída utilizando uma amostra aleatória dos dados de treinamento e também emprega uma abordagem de amostragem aleatória para selecionar as características (variáveis) a serem consideradas em cada divisão de nó [Boateng et al. 2020].

4. Resultados

Nesta seção, serão apresentados os resultados obtidos através da metodologia proposta. Inicialmente foi avaliado a precisão do algoritmo YOLO treinado para a segmentação, onde o mesmo apresentou uma taxa de precisão de segmentação perfeita (Segmentou corretamente toda a zona de interesse) em 70% das imagens da base. As imagens que não foram segmentadas pelo modelo, foram usadas em sua forma completa para a classificação conforme mostrado na Figura 4.



Figura 4. Original x Segmentação com YOLO

Para avaliar o desempenho do algoritmo, foi empregada a técnica de validação cruzada, que é uma técnica para avaliar a capacidade de generalização de um modelo, dividindo a base em 5 partes iguais e usando sempre 1 para teste as demais para treino, a partir de um conjunto de dados [Berrar et al. 2019]. A Tabela 3 apresenta os resultados de classificação com base nos resultados obtidos. A classificação foi dividida entre: imagens originais contendo 450 imagens, segmentadas com YOLO contendo 340 segmentações perfeitas e híbridas que são compostas pelas 340 imagens segmentadas perfeitamente junto com as 110 imagens originais que não foi possível realizar a segmentação.

Tabela 3. Resultados da validação cruzada

Dataset	Métrica	Média	Desvio Padrão
Imagens originais (450)	Acurácia	64%	6%
	Precisão	66%	4%
	Recall	77%	6%
	F1	71%	4%
	Kappa	23%	13%
Segmentação com YOLO (340)	Acurácia	62%	4%
	Precisão	68%	1%
	Recall	71%	13%
	F1	69%	7%
	Kappa	19%	6%
Híbridas (450)	Acurácia	56%	8%
	Precisão	62%	6%
	Recall	60%	21%
	F1	59%	15%
	Kappa	12%	12%

Conforme observado na Tabela 3, as imagens originais apresentaram resultados superiores em quase todas as métricas, levando a considerar que fatores externos como iluminação e zona de interesse podem afetar diretamente no resultado final. A Figura 5 mostra os resultados da classificação usando 5 amostras da base de dados, ilustrando casos de sucesso e falha do algoritmo. Nota-se um certo grau de similaridade na maioria dos itens, o que torna a classificação um desafio.

Resultado esperado	Vermifuga	Vermifuga	Não Vermifuga	Não Vermifuga	Vermifuga
Imagens					
Resultado Obtido	Vermifuga	Vermifuga	Não Vermifuga	Vermifuga	Não Vermifuga

Figura 5. Resultados obtidos na classificação

5. Conclusão

O Trabalho explorou a aplicação da visão computacional como uma ferramenta complementar ao método FAMACHA na gestão da saúde de cabras e ovelhas. Ao desenvolver uma metodologia baseada em algoritmos de processamento de imagens, ofereceremos uma abordagem mais eficiente e precisa para identificar a necessidade de vermifugação nos animais. Os resultados preliminares indicam que a automação do processo de análise das imagens da mucosa ocular pode facilitar a identificação de indivíduos anêmicos de forma rápida e confiável, reduzindo a dependência de avaliações subjetivas e minimizando erros de interpretação.

Em trabalhos futuros, com o crescimento da base de dados e a possibilidade de novos descritores que consigam descrever melhor os dados levando em consideração pro-

blemas de iluminação, espera-se que problemas identificados sejam tratados visando garantir uma maior precisão e qualidade na identificação prematura visando tratamento dos animais a serem analisados.

Referências

- Almeida, A. M. A. (2021). Detecção de anemia em ovinos através de aprendizagem profunda em imagens de mucosa ocular. *PPGEEC - SOBRAL - Dissertações defendidas na UFC*.
- Arshad, M. F., Burrai, G. P., Varcasia, A., Sini, M. F., Ahmed, F., Lai, G., Polinas, M., Antuofermo, E., Tamponi, C., Cocco, R., et al. (2024). The groundbreaking impact of digitalization and artificial intelligence in sheep farming. *Research in Veterinary Science*, page 105197.
- Berrar, D. et al. (2019). Cross-validation.
- Boateng, E. Y., Otoo, J., and Abaye, D. A. (2020). Basic tenets of classification algorithms k-nearest-neighbor, support vector machine, random forest and neural network: a review. *Journal of Data Analysis and Information Processing*, 8(4):341–357.
- de Oliveira Diniz, V. A., Teixeira, L. F., de Almeida, G. D., Meirelles, A. C. F., Junior, E. G., and Figueira, P. T. (2022). Utilização do método famacha como auxílio no controle de verminose em ovinos. *Pubvet*, 16:195.
- de Souza, L. F., Costa, M. H., and Riet-Correa, B. (2023). Mobile app for targeted selective treatment of haemonchosis in sheep. *Veterinary Parasitology*, 316:109902.
- Jiang, P., Ergu, D., Liu, F., Cai, Y., and Ma, B. (2022). A review of yolo algorithm developments. *Procedia Computer Science*, 199:1066–1073.
- Magalhães, K. A., Holanda Filho, Z. F., and Martins, E. C. (2021). Pesquisa pecuária municipal 2020: rebanhos de caprinos e ovinos. *Boletim do Centro de Inteligência e Mercado de Caprinos e Ovinos*, 1(16).
- Martins, E. C., Magalhães, K., Souza, J., Guimarães, V., Barbosa, C., and Holanda Filho, Z. (2016). Cenários mundial e nacional da caprinocultura e da ovinocultura. *Boletim ativos de ovinos e caprinos*, 3(2):1–6.
- Nascimento, M. I. d. S. S. (2022). *Produção, comercialização e consumo dos produtos e subprodutos caprinos e ovinos no Nordeste do Brasil*. PhD thesis, Universidade Federal Rural de Pernambuco.
- RIBEIRO, W. F. (2018). Uma metodologia para detectar anemia em pequenos ruminantes. *Graduação*.
- Souza Filho, J. L. d. et al. (2022). Desenvolvimento de api para aprendizado profundo de imagens de pequenos ruminantes. *Graduação*.
- Teixeira, M., Matos, A. F. I. M. d., Oliveira, T. N. d., and Souza, C. M. (2023). Cartilha controle de verminoses em caprinos e ovinos: recomendações para o controle integrado de verminose em caprinos e ovinos no sertão do são francisco. *PE*.