

Mauricio Benjamin da Rocha
Orientador: Flávio Henrique Duarte de Araújo

**Classificação Automatizada de Pequenos
Ruminantes para Vermifugação com YOLOv11n
e Análise Ocular Baseada no Método
FAMACHA**

Picos - PI
16 de junho de 2025

Mauricio Benjamin da Rocha
Orientador: Flávio Henrique Duarte de Araújo

Classificação Automatizada de Pequenos Ruminantes para Vermifugação com YOLOv11n e Análise Ocular Baseada no Método FAMACHA

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como requisito parcial para obtenção de grau de Bacharel em Sistemas de Informação

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
16 de junho de 2025

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

R672c

Rocha, Mauricio Benjamin da.

Classificação automatizada de pequenos ruminantes para vermifugação com YOLOv11n e análise ocular baseada no método FAMACHA / Mauricio Benjamin da Rocha – 2025.

43 f.

1 Arquivo em PDF.

Indexado no catálogo *online* da biblioteca José Albano de Macêdo, CSHNB. Aberto a pesquisadores, com restrições da Biblioteca.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Curso de Bacharelado em Sistemas de Informação, Picos, 2025. “Orientador: Flávio Henrique Duarte de Araújo”.

1. Sistemas informacionais. 2. Classificação automatizada. 3. Visão computacional. I. Rocha, Mauricio Benjamin da. II. Araújo, Flávio Henrique Duarte de. III. Título.

CDD 005.7

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB n° 03/1835

Classificação Automatizada de Pequenos Ruminantes para Vermifugação com YOLOv11n e
Análise Ocular Baseada no Método FAMACHA

Mauricio Benjamin da Rocha

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas
de Informação.

Data de Aprovação

Picos – PI, 27 de Junho de 2025

Documento assinado digitalmente
 **FLAVIO HENRIQUE DUARTE DE ARAUJO**
Data: 07/07/2025 10:11:10-0300
Verifique em <https://validar.iti.gov.br>

Prof. Flávio Henrique Duarte de Araújo

Documento assinado digitalmente
 **MAURO ANTONIO GUIMARAES CLARK**
Data: 07/07/2025 10:05:20-0300
Verifique em <https://validar.iti.gov.br>

Prof. Mauro Antonio Guimarães Clak

Documento assinado digitalmente
 **THIAGO JOSE BARBOSA LIMA**
Data: 07/07/2025 09:41:45-0300
Verifique em <https://validar.iti.gov.br>

Prof. Thiago José Barbosa Lima

Agradecimentos

Agradeço primeiramente aos meus pais, que sempre foram a base do meu caminho. À minha mãe, que cuidou da minha saúde com dedicação e nunca deixou de me incentivar a seguir em frente, mesmo diante das dificuldades. Ao meu pai, por estar sempre presente, me apoiando em cada escolha e me incentivando continuamente a buscar progresso e crescimento pessoal.

Ao meu orientador, que tem sido um verdadeiro parceiro desde os primeiros passos da minha trajetória acadêmica. Sua orientação constante, disposição para ensinar e até mesmo as viagens que fizemos juntos foram fundamentais para que este trabalho se concretizasse. Crescemos juntos nesse processo, e por isso sou profundamente grato.

Ao Laboratório PAVIC, pelo acolhimento desde o início, pelas oportunidades de participar de viagens de coleta em campo, e pelas trocas de conhecimento valiosas que tive com todos os colegas e professores envolvidos.

Ao meu amigo e professor Ismael, que teve um papel essencial na minha formação, um dos principais incentivos a enxergar o verdadeiro potencial que carregamos e o quanto podemos alcançar com esforço, foco e dedicação. Suas palavras e apoio foram decisivos em momentos importantes da minha jornada.

Ao meu amigo, Pedro Vital, que foi um companheiro nessa jornada de aprendizado e sobrevivência no meio acadêmico, meu muito obrigado pela companhia e apoio. Desde as épocas de calmarias até as tempestades, sempre resistimos e persistimos até o fim desta saga. O importante não foi o tamanho de cada passo, e sim continuar dando passos avante, independentemente da situação.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, meu muito obrigado.

A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê.

Arthur Schopenhauer

Resumo

Este trabalho propõe uma solução computacional de baixo custo, fundamentada em visão computacional e inteligência artificial, para automatizar o diagnóstico de anemia em cabras e ovelhas, com base no método FAMACHA. O FAMACHA é uma técnica amplamente utilizada no manejo sanitário de pequenos ruminantes, que avalia a coloração da mucosa ocular como indicador clínico da gravidade da anemia, geralmente causada pelo parasita *Haemonchus contortus*. Embora seja um método acessível, ele depende da experiência do avaliador, o que pode comprometer a precisão e a consistência do diagnóstico, especialmente em grandes rebanhos. Para superar essas limitações, este trabalho utiliza o algoritmo YOLOv11n, um modelo leve e eficiente para detecção, segmentação e classificação de imagens, projetado para funcionar em dispositivos móveis, com execução local e sem necessidade de conexão à internet. Isso garante baixo custo computacional, pois elimina a dependência de servidores em nuvem ou hardware especializado, e também reduz o custo operacional, viabilizando sua aplicação direta em campo, mesmo em regiões com infraestrutura limitada. Foram desenvolvidos modelos de segmentação e classificação que atingiram respectivamente 82,4% e 78,6% de acurácia na identificação de animais que necessitam de vermifugação, com base em 548 imagens coletadas pelo autor, em colaboração com o Laboratório PAVIC, formando uma base de dados privada. A proposta visa reduzir a subjetividade do método manual, otimizar o uso de vermífugos e contribuir para um manejo sanitário mais sustentável.

Palavras-chaves: Diagnóstico de Anemia. FAMACHA. Pequenos Ruminantes. YOLOv11n. Visão Computacional.

Abstract

This work proposes a low-cost computational solution based on computer vision and artificial intelligence to automate the diagnosis of anemia in goats and sheep, using the FAMACHA method. FAMACHA is a technique widely used in the sanitary management of small ruminants, which assesses the coloration of the ocular mucosa as a clinical indicator of anemia severity, typically caused by the parasite *Haemonchus contortus*. Although accessible, the method relies on the evaluator's experience, which can compromise the accuracy and consistency of the diagnosis, especially in large herds. To overcome these limitations, this study employs the YOLOv11n algorithm a lightweight and efficient model for image detection, segmentation, and classification designed to run on mobile devices, with local execution and no need for internet connectivity. This ensures low computational cost by eliminating the need for cloud servers or specialized hardware, and also reduces operational costs, enabling its direct application in the field, even in regions with limited infrastructure. Segmentation and classification models were developed, achieving accuracies of 82.4% and 78.6%, respectively, in identifying animals that require deworming, based on 548 images collected by the author in collaboration with the PAVIC Laboratory, forming a private dataset. The proposed solution aims to reduce the subjectivity of the manual method, optimize anthelmintic use, and contribute to more sustainable herd health management.

Keywords: Anemia Diagnosis. FAMACHA. Small Ruminants. YOLOv11n. Computer Vision.

Keywords: Anemia Diagnosis. FAMACHA. Small Ruminants. YOLOv11n. Automated Detection.

Lista de ilustrações

Figura 1 – Cartão FAMACHA (EMBRAPA, 2024).	15
Figura 2 – Abordagem do YOLO em imagens (COMPUTACIONAL, 2023).	19
Figura 3 – Fluxo de conversão de modelos TensorFlow para o formato TensorFlow Lite (TENSORFLOW, 2023).	21
Figura 4 – Fluxo de execução de modelos YOLOv11n em dispositivos móveis utilizando TFLite	22
Figura 5 – Esquema ilustrativo do processo de validação cruzada K-Fold ($k = 5$). Fonte: scikit-learn.org	23
Figura 6 – Metodologia adotada	30
Figura 7 – Coleta de imagens em fazendas da região	31
Figura 8 – Exemplo do processo segmentação da mucosa ocular com YOLOv11n	32
Figura 9 – Métricas selecionadas para segmentação e classificação	34
Figura 10 – Exemplos de acertos e erros durante a validação do modelo	37

Lista de tabelas

Tabela 1 – Classificação dos graus de anemia segundo o método FAMACHA . . .	15
Tabela 2 – Resumo dos classificadores avaliados e suas características técnicas . .	18
Tabela 3 – Comparativo descritivo dos trabalhos relacionados.	29
Tabela 4 – Distribuição dos dados entre classes do cartão e agrupando	32
Tabela 5 – Configuração de treinamento dos modelos	33
Tabela 6 – Métricas de desempenho na segmentação da mucosa ocular com YO- LOv11n	35
Tabela 7 – Desempenho dos modelos com validação cruzada ($k = 5$) e imagens sem segmentação	36
Tabela 8 – Resultados obtidos com validação cruzada usando $k = 5$ e imagens segmentadas	36

Lista de abreviaturas e siglas

API	Interface de Programação de Aplicações (<i>Application Programming Interface</i>)
CNN	Rede Neural Convolutacional (<i>Convolutional Neural Network</i>)
Deep Learning	Aprendizado Profundo
FN	Falso Negativo
FP	Falso Positivo
GUI	Interface Gráfica do Usuário (<i>Graphical User Interface</i>)
IA	Inteligência Artificial
IoU	Interseção sobre União (<i>Intersection over Union</i>)
K-Fold	Validação Cruzada com K Partições
mAP	Média de Precisão Média (<i>Mean Average Precision</i>)
ML	Aprendizado de Máquina (<i>Machine Learning</i>)
NPU	Unidade de Processamento Neural (<i>Neural Processing Unit</i>)
RF	Floresta Aleatória (<i>Random Forest</i>)
RGB	Vermelho, Verde e Azul (<i>Red, Green, Blue</i>)
RNC	Rede Neural Convolutacional
TFLite	TensorFlow Lite – Versão otimizada do framework TensorFlow para dispositivos móveis
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
YOLO	<i>You Only Look Once</i> – Arquitetura de detecção de objetos em tempo real

Lista de símbolos

k	Número de partições na validação cruzada (K-Fold)
μ	Média
σ	Desvio Padrão
\rightarrow	Implica ou resulta em
Σ	Somatório
$\frac{a}{b}$	Fração, razão entre dois valores

Sumário

1	Introdução	11
1.1	Objetivos Gerais e Específicos	12
1.2	Disposição do Trabalho	13
2	Referencial Teórico	14
2.1	Famacha e a Saúde de Caprinos e Ovinos	14
2.2	Visão Computacional	16
2.3	Classificadores para Diagnóstico de Anemia via FAMACHA	17
2.3.1	Random Forest	17
2.3.2	Outros Algoritmos Avaliados	17
2.4	Deep Learning e a Família YOLO	18
2.5	TensorFlow Lite e a Inferência em Dispositivos Móveis	20
2.6	Métricas de Avaliação	22
2.6.1	Validação Cruzada K-Fold	22
2.6.2	Métricas de Classificação	23
2.6.3	Métricas de Segmentação	24
3	Trabalhos Relacionados	26
4	Método proposto	30
4.1	Aquisição de dados	31
4.2	Pré-processamento	32
4.3	Classificação	32
4.4	Avaliação dos Resultados	33
5	Resultados	35
6	Conclusão	38
7	Publicações	39
	Referências	40

1 Introdução

A criação de cabras e ovelhas desempenha um papel relevante na economia brasileira, especialmente em regiões rurais e semiáridas como o Nordeste. Esses animais são importantes fontes de proteína, fornecendo carne, leite e derivados à população brasileira, além de contribuírem significativamente para a segurança alimentar e geração de renda em comunidades com acesso limitado à infraestrutura de trabalho (NASCIMENTO, 2022).

Apesar da sua importância, a produtividade dos rebanhos de pequenos ruminantes é severamente impactada por doenças parasitárias, com destaque para infecções causadas pelo *Haemonchus Contortus* (MARTINS et al., 2016). Este verme gastrointestinal é altamente prevalente em regiões tropicais e subtropicais, provocando quadros de anemia, perda de peso e até morte, o que compromete a eficiência reprodutiva e o bem-estar animal (MAGALHÃES; FILHO; MARTINS, 2021). O controle desse parasita tem se tornado cada vez mais desafiador devido à crescente resistência aos medicamentos antiparasitários, consequência do uso indiscriminado de vermífugos (ARSHAD et al., 2024).

Para racionalizar o uso desses medicamentos e evitar a resistência, o método FAMACHA foi desenvolvido como uma técnica de avaliação visual da coloração da mucosa ocular, associada ao grau de anemia do animal (DINIZ et al., 2022). Ele utiliza uma escala padronizada de cinco níveis, onde a coloração varia do vermelho vivo (indicando animal saudável) até o rosa pálido ou esbranquiçado (indicando anemia severa). Essa avaliação é feita comparando a mucosa ocular do animal com um cartão FAMACHA, permitindo identificar, de forma rápida e prática, quais animais necessitam realmente de tratamento com vermífugo. Dessa forma, o método promove um controle parasitário seletivo, evitando o uso excessivo de medicamentos e ajudando a preservar sua eficácia ao longo do tempo.

Embora seja simples e de baixo custo, o método FAMACHA apresenta limitações práticas importantes. Sua aplicação exige que o avaliador tenha treinamento adequado para interpretar corretamente as cores da mucosa ocular, o que nem sempre é garantido em ambientes rurais com pouca assistência técnica (TEIXEIRA et al., 2023). Além disso, o julgamento visual está sujeito à subjetividade humana, podendo variar entre operadores ou até mesmo para o mesmo operador em momentos diferentes, especialmente sob condições de iluminação desfavoráveis. Em rebanhos de grande porte, o método se torna ainda mais desafiador, pois demanda tempo e atenção individual para cada animal. A repetição constante desse processo pode gerar fadiga no avaliador, aumentando o risco de erros de classificação e comprometendo a eficácia do manejo sanitário (MARTINS et al., 2016).

Diante desse cenário, o uso de tecnologias como Visão Computacional e Inteligência Artificial (IA) surge como uma alternativa promissora para automatizar o processo de diagnóstico da anemia, oferecendo maior precisão e consistência em relação ao método tradicional. Ao permitir que imagens da mucosa ocular sejam analisadas automaticamente

por algoritmos treinados, essas tecnologias reduzem significativamente a dependência da avaliação humana, minimizam erros causados por subjetividade e aumentam a escalabilidade do diagnóstico, especialmente em rebanhos numerosos (RIBEIRO, 2018). Além disso, possibilitam decisões mais rápidas e assertivas no campo, otimizando o uso de vermífugos e melhorando o manejo sanitário. No entanto, grande parte das soluções encontradas na literatura científica ainda requer infraestrutura tecnológica robusta, como acesso constante à internet, servidores em nuvem ou dispositivos com alto poder computacional (SOUZA; COSTA; RIET-CORREA, 2023). Isso limita sua adoção em propriedades rurais de pequeno porte, onde o acesso à tecnologia é escasso, e reforça a necessidade de alternativas viáveis que funcionem de forma offline, com baixo custo e em dispositivos móveis.

Este trabalho propõe um método baseada em visão computacional e aprendizado de máquina, utilizando o algoritmo YOLOv11n, voltado para a segmentação e classificação automática de imagens da mucosa ocular de caprinos e ovinos. O YOLOv11n, por ser uma versão otimizada da arquitetura YOLO, combina velocidade e eficiência computacional, o que o torna especialmente adequado para execução em dispositivos com recursos limitados. A proposta visa criar uma solução totalmente offline, eliminando a necessidade de conectividade com a internet ou infraestrutura em nuvem, e permitindo que o diagnóstico seja realizado diretamente no campo. Com isso, o sistema pretende tornar o monitoramento da anemia mais acessível, confiável e escalável, mesmo em regiões rurais de difícil acesso. Além de automatizar o método FAMACHA e reduzir a subjetividade humana, a abordagem contribui para um uso mais racional e direcionado de vermífugos, o que ajuda a retardar o avanço da resistência antiparasitária e favorece práticas mais sustentáveis de manejo sanitário e bem-estar animal.

1.1 Objetivos Gerais e Específicos

O objetivo deste trabalho foi desenvolver um método computacional capaz de automatizar a seleção de caprinos e ovinos para vermifugação, por meio da análise de imagens da mucosa ocular, com base no método FAMACHA. Para isso, foi utilizado o algoritmo YOLOv11n, visando uma solução leve, eficiente e viável para execução em dispositivos móveis e ambientes offline.

Este projeto possui quatro objetivos específicos, descritos a seguir:

1. Construir uma base de imagens da mucosa ocular de caprinos e ovinos para experimentação, por meio de coletas em campo e anotação especializada com base no método FAMACHA.
2. Pré-processar e segmentar automaticamente as regiões de interesse nas imagens coletadas, utilizando um modelo leve de segmentação baseado na arquitetura YOLOv11n.

3. Treinar e validar modelos de classificação binária utilizando técnicas de aprendizado profundo e aprendizado tradicional, com base nas imagens segmentadas.
4. Avaliar o desempenho dos modelos desenvolvidos com métricas como acurácia, precisão, recall, F1-score, IoU e mAP, por meio de validação cruzada.
5. Demonstrar que método proposto contribui para um diagnóstico mais objetivo e racional no uso de vermífugos em campo, viabilizando aplicações em dispositivos móveis e ambientes *offline*.

1.2 Disposição do Trabalho

Este trabalho está estruturado em sete capítulos, além desta introdução. O Capítulo 2 apresenta os principais conceitos teóricos relacionados ao método FAMACHA, à visão computacional e aos algoritmos de aprendizado de máquina utilizados. O Capítulo 3 realiza uma revisão dos trabalhos relacionados, destacando abordagens semelhantes na detecção de anemia em pequenos ruminantes. O Capítulo 4 descreve detalhadamente a metodologia adotada, incluindo as etapas de aquisição de dados, pré-processamento, segmentação e classificação. O Capítulo 5 apresenta os resultados obtidos nos experimentos, com análise das métricas de desempenho. O Capítulo 6 discute as conclusões do trabalho e propõe direções para estudos futuros. Por fim, o Capítulo 7 apresenta publicações e registros associados aos resultados deste projeto.

2 Referencial Teórico

Este capítulo apresenta os principais fundamentos teóricos relacionados ao método FAMACHA e à aplicação de técnicas de visão computacional voltadas à saúde de caprinos e ovinos. O enfoque está na utilização de redes neurais profundas para a classificação e segmentação do grau FAMACHA por meio da análise de imagens da mucosa ocular dos animais. Para isso, foram utilizados modelos baseados na arquitetura YOLOv11n, conhecida por sua leveza e eficiência em tarefas de detecção em tempo real, especialmente quando aplicada em dispositivos com recursos computacionais limitados. Também são discutidas as características da própria arquitetura YOLOv11 e a utilização do *TensorFlow Lite*, uma ferramenta que possibilita a execução de modelos de *deep learning* em dispositivos móveis, favorecendo a criação de soluções portáteis e acessíveis para o monitoramento da anemia em campo. Esta introdução tem como objetivo fornecer uma visão geral das abordagens tecnológicas exploradas ao longo deste capítulo.

2.1 Famacha e a Saúde de Caprinos e Ovinos

O método FAMACHA foi desenvolvido na África do Sul pelos pesquisadores *François Malan, Gareth Bath e Jan Van Wyk*, e é amplamente reconhecido como uma estratégia eficaz no controle seletivo de infestações parasitárias em rebanhos de ovinos e caprinos (SOUZA et al., 2021). A principal proposta do método é permitir a administração de vermífugos apenas aos animais que apresentam sinais clínicos de anemia, promovendo um tratamento mais racional e sustentável.

O objetivo central do método FAMACHA é identificar, por meio de avaliação clínica, os diferentes graus de anemia nos animais, onde tal condição frequentemente associada à infecção pelo parasita hematófago *Haemonchus contortus* (LEAL; HASSUM, 2021). A análise é realizada com base na coloração da mucosa ocular, que reflete o nível de anemia do animal. Para isso, utiliza-se uma escala padronizada de cinco níveis de classificação, conforme apresentado na Tabela 1.

Tabela 1 – Classificação dos graus de anemia segundo o método FAMACHA

Grau	Descrição
1	A mucosa apresenta uma coloração vermelha intensa, indicando que o animal não apresenta sintomas de anemia e, portanto, não requer tratamento.
2	A coloração ainda é vermelha rosada, sem indicação de tratamento.
3	A coloração rosada indica que o animal já apresenta anemia, sendo recomendado o uso de tratamentos apropriados.
4	A vermifugação é essencial, pois a mucosa apresenta palidez intensa.
5	A mucosa fica bastante pálida, exigindo não apenas a vermifugação, mas também suplementos alimentares para repor nutrientes perdidos.

A avaliação da coloração da mucosa ocular é realizada por meio da exposição da conjuntiva do animal, obtida ao se aplicar uma leve pressão sobre a pálpebra superior (MINHO et al., 2014). Em seguida, a coloração observada é comparada com os níveis padronizados apresentados no cartão de teste FAMACHA, conforme ilustrado na Figura 2.1. A monitorização frequente dos animais é fundamental não apenas para a identificação precoce de casos de anemia, mas também para a prevenção do desenvolvimento de resistência aos anti-helmínticos, decorrente do uso indiscriminado de vermífugos.



Figura 1 – Cartão FAMACHA (EMBRAPA, 2024).

O processamento de imagens desempenha um papel essencial na automação do método FAMACHA, sendo composto por etapas como aquisição, pré-processamento, extração

de características e classificação (GONÇALVES, 2021). A presente pesquisa investiga a aplicação de técnicas de processamento digital de imagens e algoritmos de aprendizado de máquina para automatizar a identificação dos níveis de FAMACHA com base em imagens da mucosa ocular de caprinos e ovinos. Essa abordagem contribui significativamente para uma gestão mais eficiente da saúde dos rebanhos, ao permitir diagnósticos rápidos e com menor intervenção humana.

Uma das principais vantagens do método FAMACHA é a economia de recursos, uma vez que possibilita o tratamento seletivo apenas dos animais que apresentam sinais clínicos de anemia (FERREIRA, 2023). Tal prática reduz os custos associados ao uso indiscriminado de antiparasitários, prolonga a eficácia desses medicamentos e favorece a sustentabilidade da produção. Nesse contexto, o método FAMACHA exerce um papel estratégico ao minimizar a pressão de seleção sobre os parasitas, retardar o desenvolvimento de resistência e preservar a efetividade dos antiparasitários ao longo do tempo.

2.2 Visão Computacional

A visão computacional é uma área multidisciplinar que combina técnicas de computação, processamento de imagens e IA com o objetivo de capacitar máquinas a interpretar e compreender informações visuais (GONZALEZ; WOODS, 2000). No contexto da aplicação do método FAMACHA em caprinos e ovinos, essa área tem se mostrado promissora, permitindo a análise automatizada de imagens da conjuntiva ocular dos animais.

Para alcançar esse objetivo, diversas etapas são implementadas no processamento das imagens, incluindo o pré-processamento para melhorar a qualidade visual, a normalização de cores e técnicas de realce de detalhes. A segmentação é aplicada para isolar regiões de interesse, especialmente a conjuntiva ocular, cuja coloração serve como indicador clínico da presença de anemia.

Na etapa de classificação e segmentação, destacam-se o uso do algoritmo Random Forest (RF) e da arquitetura YOLOv11n. O RF é utilizado para interpretar padrões extraídos das imagens, fornecendo uma classificação precisa dos graus de FAMACHA com base em características visuais extraídas previamente. Já o modelo YOLOv11n (*You Only Look Once version 11 Nano*), pertencente à família de CNNs para detecção de objetos, permite realizar simultaneamente a segmentação e classificação em tempo real da conjuntiva ocular diretamente nas imagens, otimizando o diagnóstico e possibilitando sua aplicação em dispositivos móveis com auxílio do TensorFlow Lite (REDMON et al., 2016).

A combinação entre técnicas de visão computacional e modelos de ML como o YOLOv11n, juntamente com classificadores tradicionais como o RF, representa um avanço significativo na automação do diagnóstico clínico de anemia em rebanhos. Essa abordagem integrada oferece uma solução eficiente, precisa e adaptável ao campo, contribuindo

diretamente para a melhoria da gestão sanitária de caprinos e ovinos.

2.3 Classificadores para Diagnóstico de Anemia via FAMACHA

A aplicação de algoritmos de aprendizado de máquina no diagnóstico automatizado da anemia em ovinos e caprinos, por meio do método FAMACHA, exige a escolha criteriosa de classificadores que combinem bom desempenho, precisão diagnóstica e viabilidade computacional. Neste trabalho, foram avaliados algoritmos clássicos como Naive Bayes, Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Multi-Layer Perceptron (MLP) e RF, este último apresentando os melhores resultados gerais.

Para a extração de características, foram utilizadas imagens da mucosa ocular processadas nos espaços de cor RGB e HSV. A partir desses canais, foram calculadas medidas estatísticas simples como média, mediana e desvio padrão para cada componente individual de cor (R, G, B, H, S, V). Testes foram conduzidos tanto com canais isolados quanto com a combinação de todos os canais simultaneamente. Os melhores resultados foram obtidos quando todas as informações de cor (RGB+HSV) foram combinadas como vetor de entrada para os modelos, aumentando a representatividade dos dados e enriquecendo a etapa de classificação.

2.3.1 Random Forest

O RF é um algoritmo de aprendizado supervisionado baseado em conjuntos de árvores de decisão, amplamente reconhecido por sua robustez, capacidade de generalização e resistência ao overfitting (HU; SZYMCZAK, 2023). Durante o treinamento, o modelo constrói múltiplas árvores independentes, cujas decisões são combinadas para formar a predição final por votação majoritária (BOATENG; OTOO; ABAYE, 2020).

O RF destaca-se especialmente em contextos com alta dimensionalidade de atributos, como ocorre na análise de imagens com múltiplos canais de cor. Sua capacidade de lidar com ruídos e variáveis correlacionadas, aliada à simplicidade na configuração de hiperparâmetros, o torna uma opção atrativa para aplicações práticas em sistemas embarcados e soluções de diagnóstico automatizado. Com base nessas propriedades, o RF foi considerado um dos principais candidatos a ser avaliado na fase experimental deste trabalho, cujos resultados serão discutidos na Seção 5.

2.3.2 Outros Algoritmos Avaliados

Além do RF, este trabalho também considerou outros algoritmos clássicos de classificação supervisionada, amplamente utilizados na literatura em tarefas de reconhecimento de padrões e diagnóstico automatizado. A Tabela 2 apresenta um resumo das principais

características técnicas desses métodos, destacando seus princípios de funcionamento, vantagens e limitações teóricas.

Tabela 2 – Resumo dos classificadores avaliados e suas características técnicas

Algoritmo	Descrição e Observações
Naive Bayes	Classificador probabilístico baseado no Teorema de Bayes, conhecido por sua simplicidade e baixo custo computacional. É mais eficaz quando os atributos são estatisticamente independentes e os dados seguem distribuições conhecidas.
SVM	O <i>Support Vector Machine</i> utiliza hiperplanos para separar classes com base na maximização de margens. Apresenta bom desempenho em conjuntos de dados com fronteiras de decisão bem definidas, mas pode ser sensível a ruídos.
KNN	O algoritmo <i>K-Nearest Neighbors</i> classifica as amostras com base na proximidade com vizinhos em um espaço métrico. É de fácil implementação, porém menos escalável, além de apresentar sensibilidade a outliers e à escolha do valor de k .
MLP	As redes neurais do tipo <i>Multilayer Perceptron</i> são capazes de modelar relações não lineares complexas. Demandam, contudo, maior esforço de ajuste de hiperparâmetros e maior tempo de treinamento em comparação a métodos mais tradicionais.

A seleção desses algoritmos teve como base sua representatividade em problemas de classificação binária, além de sua diversidade de paradigmas estatísticos, geométricos e baseados em redes neurais. No contexto deste trabalho, eles foram utilizados para fins comparativos, cujos resultados experimentais serão discutidos em detalhe na Seção 5. Cabe destacar que a combinação de canais de cor (RGB e HSV), associada ao pré-processamento das imagens, foi uma estratégia adotada para potencializar a extração de características relevantes para a tarefa de classificação, conforme explorado nas etapas seguintes do desenvolvimento.

2.4 Deep Learning e a Família YOLO

O *Deep Learning* tem se consolidado como uma das abordagens mais eficazes em tarefas complexas de visão computacional, especialmente na detecção e classificação de objetos em imagens (PANAHI, 2025). Diferente dos métodos tradicionais de aprendizado de máquina, que dependem fortemente da extração manual de características, os modelos de *Deep Learning* em especial as Redes Neurais Convolucionais (RNCs) ou do inglês *Convolutional Neural Network* (CNNs) são capazes de aprender automaticamente padrões e

representações diretamente dos dados brutos, como imagens da mucosa ocular dos animais (RUSK, 2016).

Entre as arquiteturas mais promissoras no contexto de detecção de objetos, destaca-se a família YOLO. Esses modelos são projetados para realizar detecção em tempo real, com alta precisão e eficiência (ULTRALYTICS, 2024). A principal vantagem do YOLO é sua abordagem unificada, onde a imagem é processada por uma única rede neural que prevê simultaneamente as classes e as localizações dos objetos, o que o torna extremamente rápido e adequado para aplicações práticas em campo. A Figura 2 ilustra o processamento feito pelo YOLO, onde a imagem é dividida em uma grade e processada de uma única vez.

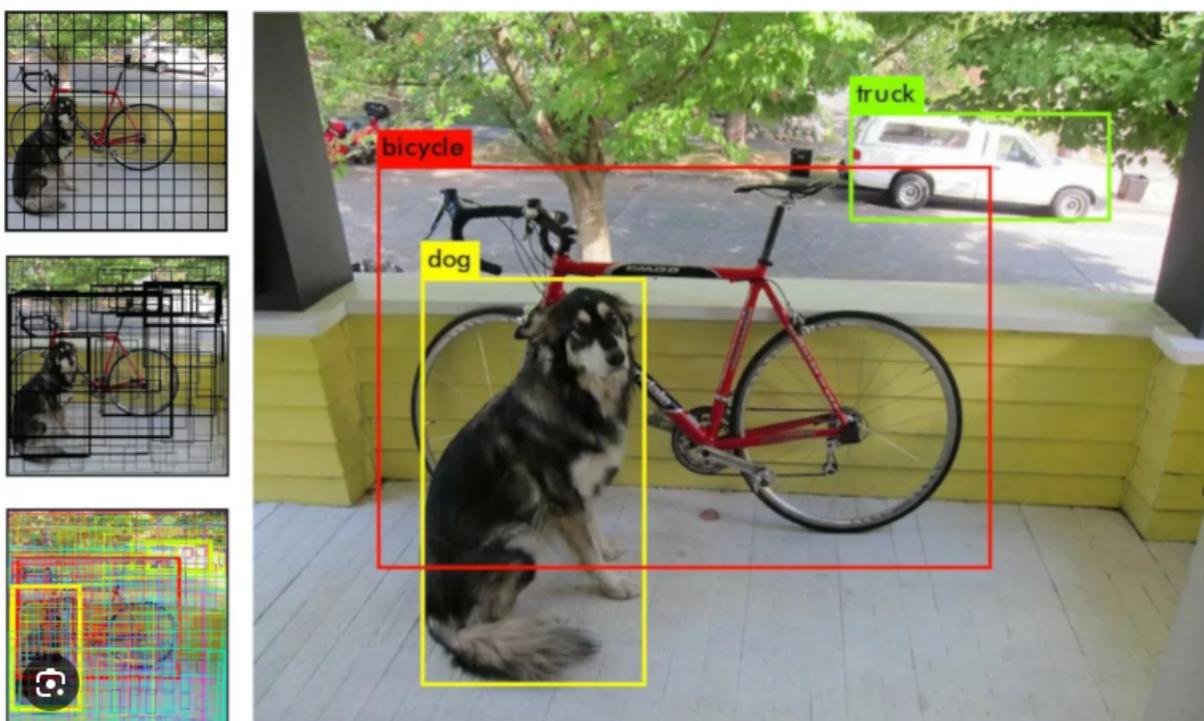


Figura 2 – Abordagem do YOLO em imagens (COMPUTACIONAL, 2023).

Conforme mostrado na Figura 2 a imagem é dividida em uma grade regular, normalmente de tamanho $N \times M$. Cada célula dessa grade é responsável por detectar objetos cujo centro esteja dentro de seus limites. Cada célula prevê múltiplas caixas delimitadoras (bounding boxes), juntamente com uma pontuação de confiança que indica a certeza de que a caixa contém um objeto e quão precisa é essa previsão (REDMON et al., 2016).

Além disso, a rede prevê a probabilidade condicional de cada classe para cada célula da grade. Ao final, essas informações são combinadas para gerar as detecções finais, descartando sobreposições por meio de técnicas como *Non-Maximum Suppression (NMS)* (JIANG et al., 2022). Essa abordagem permite que YOLO seja extremamente rápido e eficiente, realizando todas as previsões em uma única etapa, o que o torna ideal para

aplicações em tempo real.

A evolução da família YOLO, incluindo versões como YOLOv3, YOLOv4, YOLOv5 e YOLOv7 trouxe melhorias sucessivas em velocidade e desempenho (REDMON et al., 2016). A versão YOLOv11, mais recente, representa um avanço significativo em termos de capacidade de generalização, eficiência computacional e precisão na detecção de pequenos objetos, como a conjuntiva ocular em imagens de caprinos e ovinos (JOCHER; QIU, 2024).

No contexto do método FAMACHA, a aplicação de modelos de aprendizado de máquina como o YOLOv11 permite não apenas identificar automaticamente a região da conjuntiva, mas também integrá-la a sistemas de classificação baseados em redes neurais profundas. Essa abordagem possibilita o desenvolvimento de soluções totalmente automatizadas para a avaliação de anemia nos rebanhos, reduzindo a dependência de operadores humanos treinados e ampliando o alcance do diagnóstico.

2.5 TensorFlow Lite e a Inferência em Dispositivos Móveis

Com o avanço das tecnologias de aprendizado de máquina, cresce também a demanda por soluções capazes de executar modelos diretamente em dispositivos móveis, sem depender de conexões constantes com servidores na nuvem (DAVID et al., 2021). Nesse contexto, o TFLite surge como uma ferramenta fundamental. Trata-se de uma versão otimizada do *framework TensorFlow*, projetada para permitir a inferência de modelos de aprendizado de máquina em dispositivos com recursos computacionais limitados, como *smartphones*, *tablets* e sistemas embarcados.

A Figura 3 ilustra o fluxo típico de desenvolvimento e conversão de modelos com o TFLite. O processo se inicia com a construção de um modelo utilizando APIs de alto nível (como `tf.keras`) ou de baixo nível (`tf.*`), que podem gerar diferentes representações intermediárias para o modelo que será convertido.

O *Keras Model* é uma estrutura de alto nível baseada na API Keras, amplamente utilizada por sua simplicidade e modularidade. Ele representa modelos criados usando camadas encadeadas (*Sequential*) ou modelos funcionais (*Functional API*) e é ideal para prototipagem e treinamento em ambientes de desenvolvimento.

O *SavedModel* é o formato universal de serialização do *TensorFlow*, capaz de armazenar tanto a arquitetura quanto os pesos do modelo, além das funções de inferência exportadas. Esse formato é mais flexível e robusto, sendo o principal ponto de entrada para a conversão com o TFLite Converter.

Já as *Concrete Functions* são representações mais técnicas, derivadas da execução da função do modelo com tipos e formas de entrada fixos. Elas são geralmente utilizadas quando se trabalha com APIs de baixo nível ou se deseja controle mais detalhado sobre o comportamento do grafo computacional.

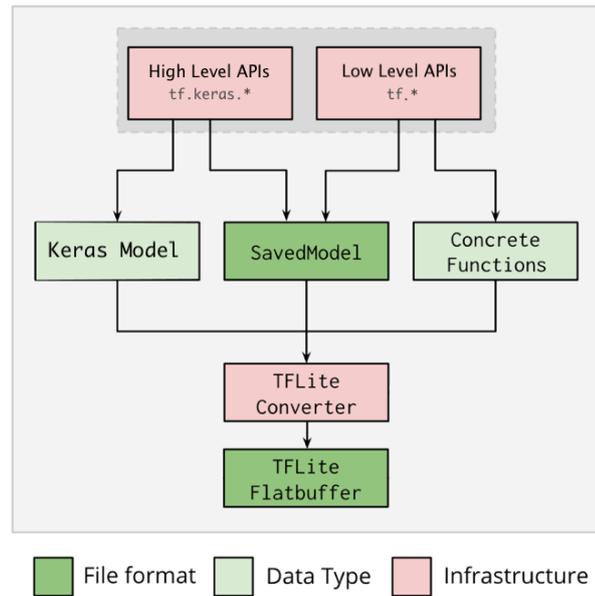


Figura 3 – Fluxo de conversão de modelos TensorFlow para o formato TensorFlow Lite (TENSORFLOW, 2023).

Esses formatos intermediários são então submetidos ao *TFLite Converter*, que transforma o modelo em um *TFLite Flatbuffer*, o formato final otimizado para execução eficiente em dispositivos móveis e embarcados. Esse arquivo *.tflite* contém a versão compacta e estática do modelo, pronta para ser interpretada pelo TensorFlow Lite Interpreter durante a inferência em tempo real.

O TFLite também oferece suporte a técnicas avançadas de otimização, como quantização, compressão e aceleração por *hardware* (utilizando GPUs, NPUs ou TPUs), visando reduzir o tamanho do modelo e melhorar sua performance (DEMOSTHENOUS; VASSILIADES, 2021). Esses recursos tornam viável a implementação de algoritmos de visão computacional e aprendizado profundo, como o YOLOv11n, diretamente em aplicações móveis e embarcadas, permitindo a inferência em tempo real mesmo sem conectividade com a internet e/ou serviços de nuvem.

Uma aplicação promissora dessa tecnologia é a exportação de modelos da família YOLO, em especial o YOLOv11n (*Nano Version*), para o formato compatível com o TFLite. A versão "n" da arquitetura YOLOv11 é projetada para oferecer alto desempenho com baixa demanda computacional, o que a torna ideal para inferência local em dispositivos móveis (PRANEETH et al., 2023). Após o treinamento, o modelo YOLOv11n pode ser convertido para o formato *.tflite*, viabilizando sua execução embarcada com eficiência e velocidade, mesmo em aparelhos com poder de processamento limitado conforme mostrado na Figura 4.

No contexto da automação do método FAMACHA, essa capacidade permite que um modelo de detecção e classificação da mucosa ocular seja integrado diretamente em um aplicativo móvel, facilitando o diagnóstico no campo, sem a necessidade de conexão com a

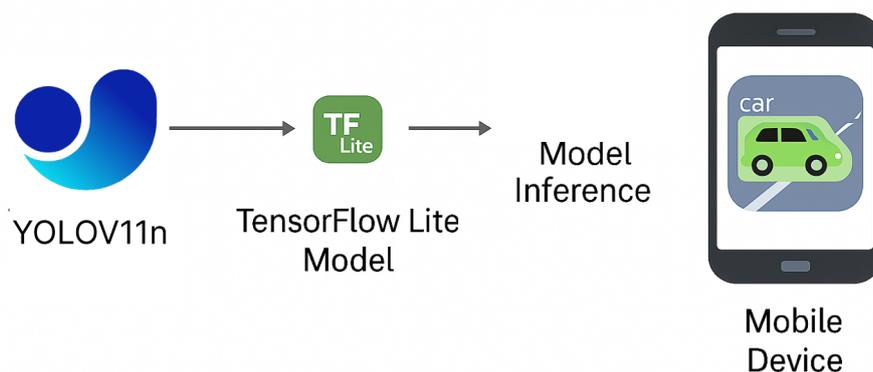


Figura 4 – Fluxo de execução de modelos YOLOv11n em dispositivos móveis utilizando TFLite

internet ou servidores remotos (FADLILAH; HANDAGA et al., 2021). Isso é especialmente importante em áreas rurais ou de difícil acesso, onde o uso de tecnologias embarcadas pode transformar a realidade da saúde animal (REDA et al., 2022).

Dessa forma, o uso do TFLite combinado com modelos leves como o YOLOv11n não apenas permite o acesso à IA no ambiente rural, mas também abre caminho para soluções móveis, rápidas e autônomas, que podem contribuir significativamente para a sustentabilidade e eficiência do manejo sanitário em rebanhos caprinos e ovinos.

2.6 Métricas de Avaliação

Nesta seção, são descritas as métricas utilizadas para avaliar o desempenho dos modelos desenvolvidos tanto para classificação quanto para segmentação. Inicialmente, adotou-se a validação cruzada K-Fold com $k=5$, uma estratégia amplamente utilizada para garantir a confiabilidade dos resultados em conjuntos de dados limitados, reduzindo riscos de sobreajuste. Para os classificadores, foram aplicadas métricas tradicionais como acurácia, precisão, *recall* e *F1-score*, permitindo analisar desde o desempenho geral até a sensibilidade a falsos positivos e falsos negativos. Já para o modelo de segmentação, avaliou-se a sobreposição entre a predição e a anotação manual por meio da métrica IoU (*Intersection over Union*), complementada pelas métricas de precisão e *recall* adaptadas ao contexto de segmentação. Por fim, a métrica mAP@0.5 foi utilizada para oferecer uma visão referente ao desempenho do modelo em diferentes níveis de confiança. Essas métricas, calculadas para cada uma das iterações da validação cruzada, foram sintetizadas por média e desvio padrão, garantindo uma análise representativa do desempenho dos modelos.

2.6.1 Validação Cruzada K-Fold

A validação cruzada *K-Fold* foi utilizada como estratégia de avaliação para garantir a confiabilidade dos resultados obtidos, especialmente em conjuntos de dados limitados

(BERRAR et al., 2019). Essa técnica consiste em dividir o conjunto de dados em k partes iguais (ou *folds*). Em cada uma das k iterações, um *fold* é reservado para teste, enquanto os demais são usados para o treinamento do modelo. Ao final do processo, os resultados de todas as iterações são combinados por meio da média e do desvio padrão das métricas, fornecendo uma estimativa estável da performance do modelo.

Esse processo minimiza os riscos de sobreajuste e viés amostral, além de assegurar que cada amostra do conjunto de dados seja utilizada tanto para treinamento quanto para validação. A Figura 5 ilustra o funcionamento do processo de validação cruzada.

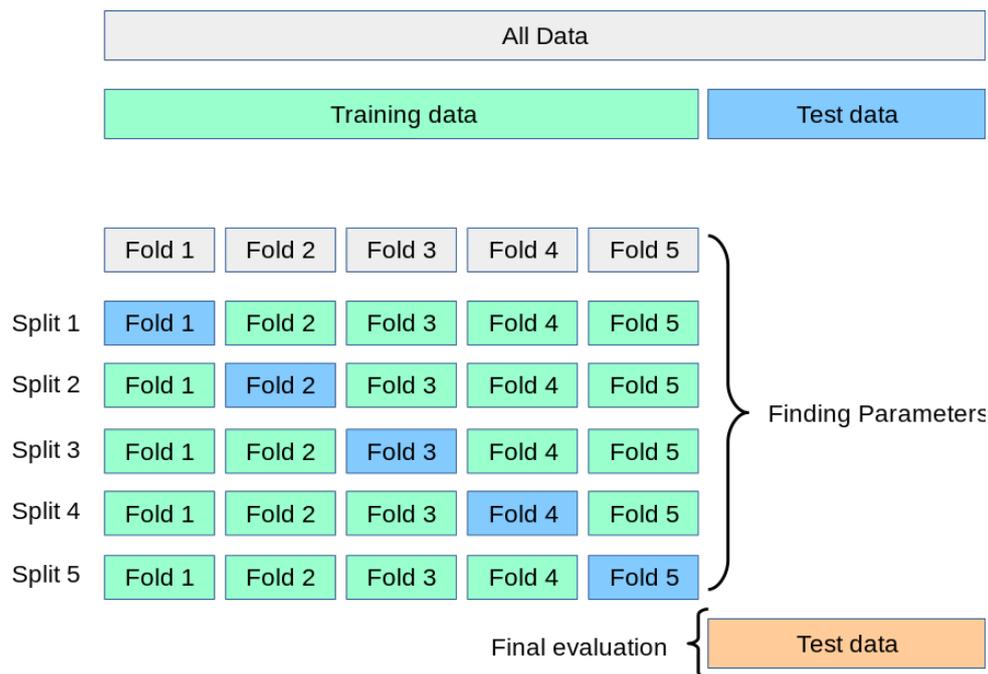


Figura 5 – Esquema ilustrativo do processo de validação cruzada K-Fold ($k = 5$). Fonte: scikit-learn.org

2.6.2 Métricas de Classificação

Para a avaliação dos modelos de classificação desenvolvidos neste trabalho, foram adotadas métricas clássicas que permitem analisar o desempenho preditivo em diferentes aspectos. A primeira delas é a acurácia, descrita na Equação 2.1, que representa a proporção total de predições corretas, tanto verdadeiros positivos (VP) quanto verdadeiros negativos (VN) em relação ao total de instâncias avaliadas (MAXWELL; WARNER; GUILLÉN, 2021a).

A precisão, definida pela Equação 2.2, indica a proporção de exemplos classificados como positivos que, de fato, pertencem à classe positiva, sendo uma métrica sensível à ocorrência de falsos positivos (FP). Já o recall, apresentado na Equação 2.3, mede a capacidade do modelo em identificar corretamente todas as instâncias relevantes da classe positiva, sendo impactado pela ocorrência de falsos negativos (FN) (MAXWELL; WARNER; GUILLÉN, 2021b).

Por fim, a métrica *F1-score*, mostrada na Equação 2.4, corresponde à média harmônica entre precisão e recall. Essa métrica é especialmente útil em cenários com classes desbalanceadas, pois oferece uma visão equilibrada entre os acertos e os erros do modelo (MAXWELL; WARNER; GUILLÉN, 2021a).

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.1)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2.2)$$

$$\text{Recall} = \frac{VP}{VP + FN} \quad (2.3)$$

$$\text{F1-score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (2.4)$$

Essas métricas foram calculadas para cada *fold* e, posteriormente, agregadas por média e desvio padrão, proporcionando uma análise mais consistente do desempenho real dos modelos em dados não vistos.

2.6.3 Métricas de Segmentação

Na etapa de segmentação, o modelo YOLOv11n-seg foi utilizado para detectar automaticamente a região da mucosa ocular nas imagens. Entre as métricas selecionadas, a principal delas é a Interseção sobre União (IoU), apresentada na Equação 2.5, que mede a sobreposição entre a área prevista pelo modelo e a área real anotada manualmente (MINAEE et al., 2021). Quanto maior o valor da IoU, maior a precisão espacial da segmentação.

Além da IoU, também foram utilizadas as métricas de precisão e recall, definidas anteriormente nas Equações 2.2 e 2.3. A precisão indica a proporção de regiões corretamente detectadas em relação ao total de predições feitas, enquanto o recall representa a proporção de regiões reais corretamente identificadas pelo modelo.

Outra métrica fundamental foi a média de precisão média com limiar de IoU igual ou superior a 0.5, conhecida como mAP0.5, cuja fórmula é apresentada na Equação 2.6. Essa métrica consiste na média das precisões médias (*Average Precision*) calculadas por classe, onde neste trabalho, apenas uma classe foi considerada: a mucosa ocular. O valor do mAP0.5 fornece uma visão global da performance do modelo em diferentes níveis de confiança, sendo especialmente útil para avaliar a consistência do desempenho em múltiplos cenários e imagens (MINAEE et al., 2021).

$$\text{IoU} = \frac{\text{Área da Interseção}}{\text{Área da União}} \quad (2.5)$$

$$\text{mAP@0.5} = \frac{1}{N} \sum_{i=1}^N AP_i \quad \text{com IoU} \geq 0.5 \quad (2.6)$$

Em que AP_i representa a precisão média para a classe i , e N é o número total de classes (neste caso, apenas uma: mucosa ocular). Essa métrica resume a capacidade do modelo de segmentar corretamente diferentes instâncias da região-alvo em múltiplos cenários.

3 Trabalhos Relacionados

Nesta seção, são apresentados trabalhos relacionados que compartilham objetivos, abordagens ou contextos semelhantes ao deste estudo, especialmente no que se refere à aplicação de técnicas de visão computacional, IA e aprendizado de máquina voltadas ao diagnóstico de enfermidades em animais ou à automação de processos no campo. A análise desses trabalhos permite identificar tendências, comparar métodos e destacar as principais contribuições e limitações de cada abordagem.

O trabalho de (RIBEIRO, 2018) investigou técnicas de segmentação e classificação para detectar anemia em pequenos ruminantes baseando-se no método FAMACHA. Na segmentação, foram aplicados filtros e operadores morfológicos para isolar a conjuntiva nas imagens, utilizando o canal H do espaço de cor HSV, seguido por operações de limiarização e erosão. Para a extração de características, foram usadas técnicas como *Border Interior Classification* (BIC) e atributos estatísticos, como média, variância, desvio padrão, curtose e assimetria. Na fase de classificação, os algoritmos KNN (k-Nearest Neighbors) e SVM foram testados, com o KNN obtendo melhores resultados, especialmente ao usar características estatísticas do canal H aplicado à conjuntiva. A segmentação alcançou uma taxa de sucesso de 86%, enquanto a classificação com KNN obteve acurácias variando entre 71,4% e 82,5%, dependendo das condições. Foram utilizadas 114 imagens, sendo 47 de cabras e 67 de ovelhas.

O estudo de Freitas (FREITAS et al., 2023) investigou o uso de imagens para classificar automaticamente a anemia em ovinos com base no escore FAMACHA. Utilizando 480 imagens da conjuntiva ocular, obtidas de 3 diferentes fazendas, os autores compararam os modelos de regressão logística multinomial (MLR) e RF. O modelo RF, implementado com quantis de intensidade de cor como variáveis explicativas, apresentou melhor desempenho, com sensibilidade de 80,9% para escore 3 e 60% para escore 5. Além disso, uma técnica de validação cruzada "leave-one-farm-out" (avaliar como o modelo se comporta quando aplicado a novos dados que não estavam presentes no treinamento e que vêm de um ambiente distinto) foi aplicada, simulando condições reais de uso em fazendas diferentes. Apesar da menor qualidade preditiva nesse cenário, os resultados destacam o potencial do modelo RF para eliminar a subjetividade humana no diagnóstico da anemia causada por *Haemonchus contortus*, especialmente nos graus de 2 a 4.

A pesquisa de (ALMEIDA, 2021) avaliou diversas técnicas de segmentação e classificação para extração da mucosa ocular e posteriormente classificação do grau FAMACHA. Na segmentação, foram testados os modelos U-Net, *Fully Convolutional Networks* (FCN), DeepLabV3 e ERFNet, com a U-Net alcançando uma acurácia de até 97,29% com normalização, enquanto a FCN obteve 96,65%. A base de dados continha 105 imagens de cabras e ovelhas, com a U-Net atingindo 78,06% de acurácia com normalização. Para a classifi-

cação, foram utilizados os modelos ResNet-50 e MobileNetV2, sendo que a MobileNetV2 atingiu uma acurácia de validação entre 70,00% e 75,00%, e o melhor desempenho foi de 95,23% sem normalização. Os dados foram fornecidos por pesquisadores da Universidade Federal do Maranhão (UFMA). Esses resultados destacam a eficácia da U-Net e FCN na segmentação e da MobileNetV2 na classificação.

O estudo de (SOUZA; COSTA; RIET-CORREA, 2023) descreve o desenvolvimento de um aplicativo móvel para auxiliar no controle de *Haemonchus contortus* em pequenos ruminantes. O aplicativo usa a câmera do celular para capturar imagens da mucosa conjuntival dos animais, classificando-os como saudáveis ou anêmicos por meio de técnicas de aprendizado de máquina baseado no grau FAMACHA. A precisão da classificação foi de 83% com uma rede neural sequencial e 87% com SVM, sendo este último modelo implementado no aplicativo. O trabalho utilizou estimativas estatísticas das funções de densidade de probabilidade para cada canal de cor, nos modelos RGB ou HSV, com otimização via *Adabound* para a rede neural. O banco de dados incluía 317 imagens de mucosas coletadas de cinco rebanhos no sul do Brasil. A versão atual do aplicativo não incluiu segmentação automática, mas futuras atualizações planejam incorporar essa funcionalidade.

O estudo de Freitas (FREITAS et al., 2024) propõe o **SheepEye**, uma aplicação web para diagnóstico automatizado da anemia em ovinos, com base na análise de imagens da conjuntiva ocular capturadas por dispositivos móveis. O sistema utiliza técnicas de aprendizado profundo, empregando a arquitetura U-Net para segmentar a região de interesse e a rede VGG19 para classificar o grau de anemia segundo a escala FAMACHA. Para tornar o modelo acessível, o autor desenvolveu uma API em Python com Flask, integrada a uma interface interativa via Streamlit. A solução apresentou desempenho satisfatório, com precisão de 71%, acurácia de 70% e F1-score de 79%, demonstrando seu potencial como ferramenta auxiliar no manejo sanitário e na redução do uso excessivo de vermífugos.

No estudo de (FILHO et al., 2022), foram comparados três modelos de Redes Neurais Convolucionais para classificação do grau FAMACHA: AlexNet, LeNet-5 e ZFNet. O AlexNet obteve uma acurácia de 62% durante o treinamento, mas apresentou dificuldades em identificar corretamente animais doentes, frequentemente classificando-os como saudáveis. O modelo LeNet-5 apresentou desempenho inferior, atribuindo todas as amostras a uma única classe, com uma acurácia de 58%. Já o modelo ZFNet se destacou com uma acurácia geral de 81%, alcançando 92% de precisão na identificação de animais doentes e 71% para animais saudáveis. As pontuações F1 foram de 81% para animais doentes e 80% para saudáveis. A ZFNet foi considerada a mais adequada para implementação prática, treinada com 128 imagens e integrada a um sistema de classificação via API, utilizando *frameworks* da linguagem de programação python como Flask e FastAPI.

Os estudos revisados apresentam resultados significativos ao empregar automações para o método FAMACHA, mas evidenciam algumas limitações. (RIBEIRO, 2018) obteve acurácia de 86% na segmentação e entre 71,4% e 82,5% na classificação, porém enfrentou

dificuldades devido à limitação de imagens (114). (ALMEIDA, 2021) alcançou altos índices com a U-Net (97,29%) e a MobileNetV2 (95,23%), mas também sofreu com a escassez de dados (105 imagens). (FILHO et al., 2022) demonstraram que a ZFNet foi a mais eficiente, atingindo 81% de acurácia, mas sua dependência de segmentação manual comprometeu a aplicabilidade do método em cenários reais.

(SOUZA; COSTA; RIET-CORREA, 2023) desenvolveram um aplicativo móvel baseado em SVM com precisão de 87%, contudo, a ausência de segmentação automática foi uma limitação, ainda que planejassem sua implementação futura. Além desses trabalhos, (FREITAS et al., 2023) explorou a classificação automática da anemia em ovinos por meio da análise de imagens da conjuntiva ocular, utilizando um conjunto de 480 imagens obtidas de três fazendas distintas. Comparando os modelos MLR e RF, identificaram que o RF, utilizando quantis de intensidade de cor como variáveis explicativas, obteve melhor desempenho, com sensibilidade de 80,9% para o grau 3 e 60% para grau 5.

Em continuidade aos estudos na área, o trabalho de Freitas (FREITAS et al., 2024) propôs o SheepEye, um aplicativo web que realiza o diagnóstico automatizado da anemia em ovinos com base em imagens da mucosa ocular e no escore FAMACHA. A solução utilizou aprendizado profundo, com redes U-Net e VGG19, e foi implementada com uma API Flask e interface em Streamlit. Diante das limitações observadas nos estudos anteriores, nosso trabalho propõe uma abordagem que integra técnicas avançadas para aprimorar a segmentação e classificação das imagens, minimizando o custo computacional e ampliando a base de dados para 548 imagens, garantindo maior precisão no diagnóstico automatizado e viabilizando sua aplicação prática no campo.

A Tabela 3 apresenta, de forma visual e organizada, uma síntese comparativa entre os estudos selecionados, evidenciando suas características, técnicas utilizadas, tipos de dados analisados, infraestrutura exigida e aplicabilidade prática, o que contribui para contextualizar a originalidade e a relevância da proposta desenvolvida neste trabalho.

Tabela 3 – Comparativo descritivo dos trabalhos relacionados.

Trabalho	Objetivo	Métodos	Algoritmos	Nº de imagens	Acurácia	Limitações
(RIBEIRO, 2018)	Método	Segmentação, Classificação	KNN, SVM U-Net, FCN,	114	Classificação: 82,5%	Quantidade de Imagens
(ALMEIDA, 2021)	Método	Segmentação, Classificação	DeepLabV3, ERFNet, ResNet-50, MobileNetV2 AlexNet,	105	Classificação: 95,23%	Quantidade de Imagens
(FILHO et al., 2022)	API	Classificação	LeNet-5, ZFNet Rede neural	128	Classificação: 82,5%	Quantidade de Imagens
(SOUZA; COSTA; RIET-CORREA, 2023)	Aplicativo Móvel	Classificação	sequencial, SVM	317	Classificação: 87%	Custo computacional
(FREITAS et al., 2023)	Método	Segmentação, Classificação	MLR RF	480	Classificação: +80%	Quantidade de Imagens
(FREITAS et al., 2023)	Aplicação Web	Segmentação, Classificação	U-Net, VGG19	480	Classificação: 70%	Custos de Servidor
Este Trabalho	Método	Classificação, Segmentação	Yolov11n	548	Classificação: 78,61%	Quantidade de Imagens

4 Método proposto

Este capítulo descreve o método proposto neste trabalho, onde a Figura 6 apresenta todo o ciclo de processos propostos. A metodologia consistiu em realizar a aquisição de imagens, visando construir uma base variada que represente múltiplos cenários operacionais a serem treinados. Após a aquisição de 548 imagens, as imagens foram pré-processadas, por meio de segmentação, com o objetivo de separar a zona de interesse do restante da imagem. Um modelo de aprendizado de máquina para classificação foi treinado para predição sobre a situação da saúde do animal, de forma binária, permitindo prever se o animal precisa ou não de vermifugação. Ao final, foi realizada a avaliação dos resultados, visando garantir a qualidade do método.

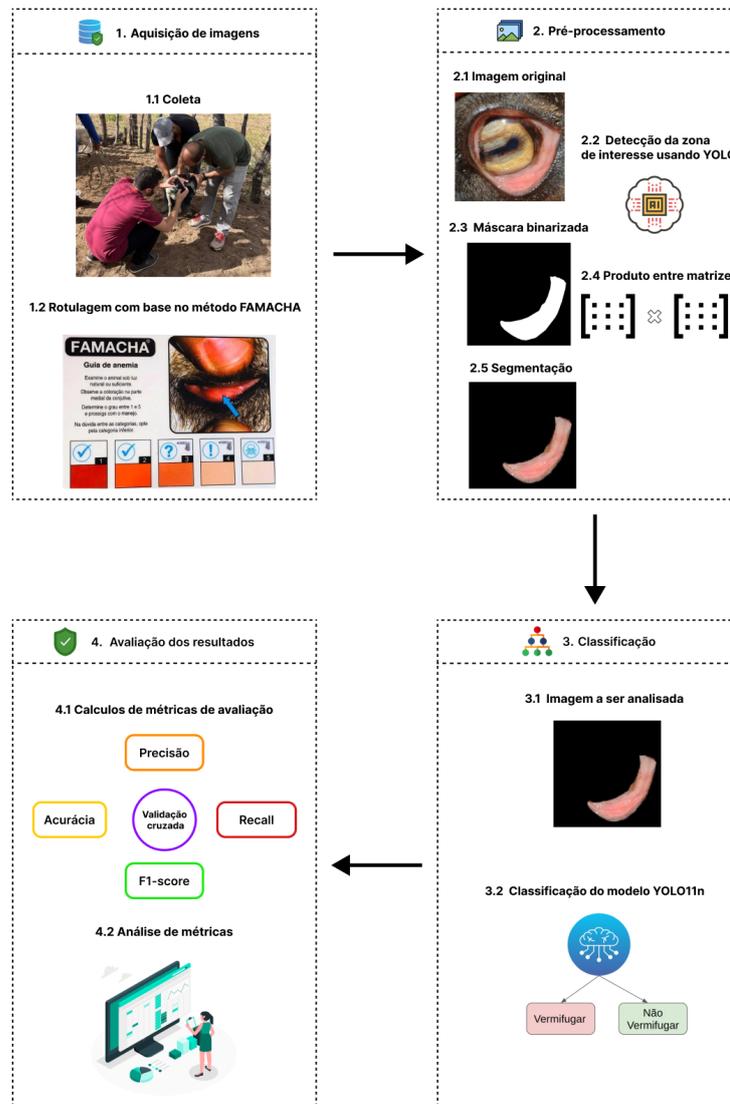


Figura 6 – Metodologia adotada

4.1 Aquisição de dados

A etapa inicial da metodologia, onde a necessidade por dados se tornou um desafio, devido à ausência de bases de imagens públicas contendo imagens da conjuntiva ocular de cabras e ovelhas. Foram realizadas viagens de campo para diversas fazendas nos arredores da cidade de Picos-PI e Teresina-PI, visando adquirir imagens válidas para o trabalho usando o cartão FAMACHA, como apresentado na Figura 7. Após a coleta das imagens, foi necessária a colaboração com um especialista da área de zootecnia para anotação precisa do grau FAMACHA para cada indivíduo, com base nas imagens obtidas.



Figura 7 – Coleta de imagens em fazendas da região

As imagens foram agrupadas em duas novas categorias: Vermifuga e Não Vermifuga. A classe Vermifuga 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 Vermifuga 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 4 apresenta a distribuição dos dados juntamente com o referido agrupamento.

Tabela 4 – Distribuição dos dados entre classes do cartão e agrupando

Classe	1	2	3	4	5	Vermífuga	Não Vermífuga
Quantidade	60	143	221	112	12	345	203
Percentual (%)	10.95	26.09	40.33	20.44	2.19	62.96	37.04

4.2 Pré-processamento

Após a etapa de aquisição de imagens, o processo de pré-processamento teve como principal objetivo preparar os dados para a fase de classificação, assegurando maior qualidade na entrada do modelo. As imagens coletadas apresentavam variações significativas em iluminação, posicionamento e fundo, características comuns em ambientes de campo. Para reduzir esses fatores de ruído e focar a análise na região de interesse, adotouse uma etapa de segmentação automática.

Utilizou-se para isso um modelo leve de segmentação baseado no yolo11n-seg, treinado com todas as 548 imagens da base de dados coletada, com o objetivo de detectar e isolar a conjuntiva ocular nas imagens. O Treinamento foi realizado ao separar 80% dos dados para treino e 20% para validação. Esse modelo permitiu extrair apenas a área relevante para o diagnóstico de anemia, descartando partes irrelevantes da imagem, como pelos, sombras ou elementos do ambiente. A segmentação contribuiu não apenas para melhorar a precisão do classificador, mas também para padronizar visualmente as amostras.

As regiões segmentadas foram posteriormente redimensionadas para uma resolução uniforme de 640x640 pixels (padrão para algoritmos YOLO) e salvas em um novo conjunto de dados pronto para a etapa de classificação. O fluxo de segmentação está ilustrado na Figura 8, representando o método adotado neste trabalho. Essa abordagem permitiu maior consistência entre as amostras e reduziu o impacto de variações externas, aumentando a robustez do modelo final treinado (BOATENG; OTOO; ABAYE, 2020).

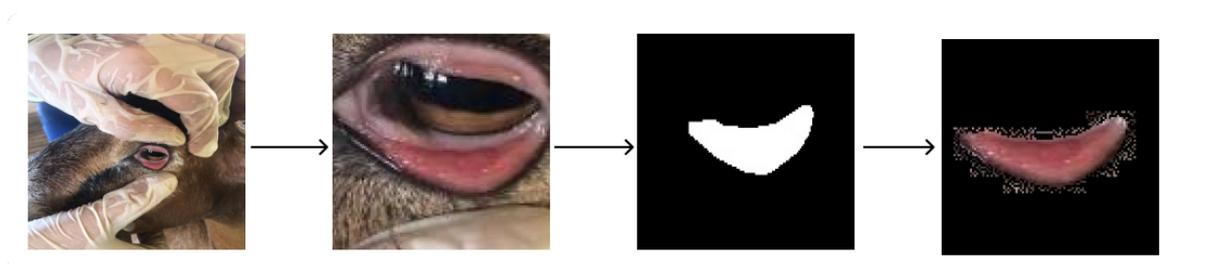


Figura 8 – Exemplo do processo segmentação da mucosa ocular com YOLOv11n

4.3 Classificação

A etapa de classificação foi essencial para o desenvolvimento do método proposto, pois permite identificar automaticamente, a partir de imagens da mucosa ocular, se um animal

deve ou não ser vermifugado. Para isso, foram empregados dois modelos de natureza distinta: um baseado em redes neurais profundas, o YOLOv11n-cls, e outro de aprendizado supervisionado clássico, o RF.

O modelo YOLOv11n-cls, derivado da arquitetura YOLO adaptada para classificação de imagens, foi pré-treinado no conjunto de dados *ImageNet*, contendo milhões de imagens de diversas categorias. Para adequá-lo à tarefa específica deste trabalho, ele foi refinado (*fine-tuned*) com as imagens da mucosa ocular de caprinos e ovinos, previamente segmentadas e padronizadas. O treinamento foi realizado ao longo de 100 épocas, visando distinguir duas classes: animais que necessitam de vermifugação e os que não necessitam, de acordo com a escala FAMACHA. Os parâmetros de Treino se encontram na Tabela 5.

Paralelamente, foi desenvolvido um segundo classificador utilizando o algoritmo RF, reconhecido por sua robustez e interpretabilidade. Diferente do YOLOv11n, que aprende diretamente a partir das imagens, o RF depende de atributos manuais extraídos de cada imagem. Para isso, foram computadas três estatísticas (média, mediana e desvio padrão) em cada um dos três canais de cor RGB (vermelho, verde e azul), totalizando nove características por imagem. Essas informações serviram como entrada para o modelo, que então aprendeu padrões discriminativos baseados nessas métricas simples, porém relevantes.

Ambos os modelos foram avaliados de forma equitativa por meio da técnica de validação cruzada. Ao invés de uma divisão única entre treino e teste, essa abordagem garante que cada imagem participe de uma etapa de teste exatamente uma vez, enquanto as demais compõem os subconjuntos de treino. Esse processo reduz o risco de viés e fornece estimativas mais confiáveis do desempenho real dos modelos, além de permitir o cálculo do desvio padrão das métricas, refletindo a consistência das predições.

A Tabela 5 resume os principais parâmetros de configuração utilizados durante o treinamento e avaliação dos modelos.

Tabela 5 – Configuração de treinamento dos modelos

Parâmetro	Valor
Total de Imagens	548
Número de Épocas (YOLOv11n-cls)	100
Técnica de Avaliação (ambos)	Validação Cruzada com $k = 5$
Atributos Usados (RF)	Média, Mediana e Desvio Padrão (R, G, B)
Classes	Vermífuga / Não Vermífuga

4.4 Avaliação dos Resultados

A avaliação dos modelos desenvolvidos neste trabalho foi conduzida por meio de métricas consagradas para tarefas de classificação e segmentação, com o objetivo de mensurar o desempenho preditivo e a robustez dos métodos aplicados.

Para os modelos de classificação YOLOv11n-cls, KNN, SVM, MLP RF e *Naive Bayes* foram utilizadas as métricas de acurácia, precisão, recall e F1-score. Já para a tarefa de segmentação com o modelo YOLOv11n-seg, foram aplicadas métricas específicas como IoU, precisão, recall e mAP@0.5. A Figura 9 apresenta visualmente as métricas adotadas para avaliar este trabalho.



Figura 9 – Métricas selecionadas para segmentação e classificação

5 Resultados

Neste capítulo, são apresentados os resultados obtidos por meio do método proposto, onde foi realizada a tarefa de segmentação da zona de interesse nas imagens, especificamente a mucosa ocular utilizando o modelo YOLOv11n-seg (versão focada em segmentação do modelo YOLOv11n). Para isso, a mesma base de dados utilizada na classificação foi reaproveitada, com a adição de anotações manuais delimitando a região relevante em cada uma das 548 imagens. Essas marcações foram realizadas seguindo um orientações de um veterinário especializado, garantindo consistência nas regiões de referência para o treinamento supervisionado. A Tabela 6 apresenta os resultados obtidos para o modelo de segmentação.

Tabela 6 – Métricas de desempenho na segmentação da mucosa ocular com YOLOv11n

Métrica	Valor Obtido
Precisão (%)	85,3
Recall (%)	87,1
IoU Média	0,76
mAP@0.5	82,4

Os resultados indicam que o modelo foi capaz de localizar com boa precisão a região da mucosa ocular nas imagens, mesmo em condições visuais variadas, como diferenças de iluminação, ângulo ou foco. A métrica IoU média de 0.76 demonstra uma sobreposição consistente entre as predições do modelo e as marcações manuais, enquanto o mAP@0.5 acima de 80% reforça a efetividade do treinamento. Isso valida o uso do YOLOv11n como uma etapa anterior à classificação automática, permitindo isolar automaticamente a região relevante da imagem, o que pode ser útil tanto para aplicações futuras quanto para aprimorar modelos baseados em recorte da zona de interesse.

A Tabela 7 apresenta os resultados obtidos na tarefa de classificação utilizando as imagens originais, sem a aplicação da etapa de segmentação da mucosa ocular. Os valores foram obtidos a partir de validação cruzada com $k = 5$, considerando as principais métricas de desempenho. Observa-se que o modelo YOLOv11n-cls obteve o melhor resultado geral, com acurácia de 71,45% e F1-score de 69,06%, superando os demais classificadores tradicionais avaliados. Ainda que os resultados sejam satisfatórios, nota-se que todas as métricas apresentaram valores inferiores em relação ao cenário com segmentação apresentado na Tabela 8, sugerindo que a ausência de foco na região de interesse pode comprometer a efetividade do diagnóstico. Os demais modelos, como MLP, SVM e RF, também tiveram desempenhos razoáveis, mas com variações maiores entre as métricas, refletindo uma maior sensibilidade à presença de ruídos e regiões irrelevantes nas imagens.

Tabela 7 – Desempenho dos modelos com validação cruzada ($k = 5$) e imagens sem segmentação

Modelo	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)
YOLOModel	71,45 ± 2,12	68,99 ± 3,19	69,45 ± 3,52	69,06 ± 2,11
MLPModel	68,06 ± 6,42	67,18 ± 7,47	68,06 ± 6,42	65,54 ± 7,10
SVMModel	65,87 ± 2,91	64,03 ± 3,59	65,87 ± 2,91	61,22 ± 5,08
RFModel	64,41 ± 3,44	63,37 ± 3,33	64,41 ± 3,44	63,15 ± 3,13
NBModel	63,68 ± 5,21	63,51 ± 4,93	63,68 ± 5,21	63,53 ± 5,06
KNNModel	63,86 ± 3,75	62,46 ± 3,91	63,86 ± 3,75	62,14 ± 3,39

A comparação dos resultados obtidos com e sem segmentação reforça a importância dessa etapa no processo de classificação. Conforme apresentado na Tabela 8, o uso da segmentação prévia da mucosa ocular contribuiu para um desempenho significativamente superior em todos os modelos, em especial no YOLOv11n-cls. Este modelo, ao receber como entrada imagens previamente recortadas da região relevante, obteve acurácia de 78,61% e F1-score de 71,04%, superando com folga os mesmos indicadores obtidos em imagens sem segmentação.

Tabela 8 – Resultados obtidos com validação cruzada usando $k = 5$ e imagens segmentadas

Modelo	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)
YOLOv11n-cls	78,61 ± 2,48	71,11 ± 3,55	71,55 ± 7,58	71,04 ± 4,15
RF	68,25 ± 2,12	67,23 ± 2,30	68,25 ± 2,12	66,48 ± 3,04
SVM	71,35 ± 3,55	70,71 ± 3,81	71,35 ± 3,55	70,79 ± 3,76
MLP	70,98 ± 4,20	70,10 ± 4,63	70,98 ± 4,20	69,65 ± 5,10
KNN	64,96 ± 3,25	64,07 ± 3,00	64,96 ± 3,25	63,75 ± 3,14
Naive Bayes	61,88 ± 5,14	64,18 ± 4,76	61,88 ± 5,14	62,43 ± 5,04

As variações observadas entre as métricas, particularmente no *recall*, evidenciam que os modelos são sensíveis a fatores externos como iluminação, foco e composição da cena. Ao isolar a região de interesse, reduz-se a interferência de ruídos contextuais e se melhora a consistência das representações aprendidas pelo classificador. Isso indica que a etapa de segmentação não apenas contribui para uma entrada mais limpa e objetiva, mas também fortalece a capacidade do modelo em generalizar o diagnóstico sob diferentes condições.

Adicionalmente, é importante considerar o desequilíbrio na base de dados, evidenciado na Tabela 4, em que há predominância de amostras da classe “vermífuga”. Tal desbalanceamento pode favorecer modelos como o YOLOv11n-cls, que ajustam fortemente seus parâmetros com base na distribuição de classes, potencialmente explicando parte de seu alto desempenho em acurácia. Ainda assim, os resultados obtidos com segmentação demonstram que a técnica oferece uma vantagem clara, não apenas por aumentar a precisão, mas também por reduzir a dependência de correlações entre fundo e classe, frequentemente presentes em imagens não processadas.

Visando auxiliar na visualização dos resultados fornecidos pelo modelo YOLOv11n-cls, a Figura 10 apresenta exemplos dos acertos e erros cometidos pelo modelo durante a

validação. Observa-se que, nos casos em que o modelo acertou a classificação, a imagem apresentava boa iluminação, foco nítido e contraste adequado entre a mucosa ocular e os demais elementos da cena. Por outro lado, os erros de classificação ocorreram, em sua maioria, em imagens com baixa qualidade visual, presença de sombras, reflexos ou variações bruscas de luz, o que dificulta a detecção precisa das características relevantes para o diagnóstico.



Figura 10 – Exemplos de acertos e erros durante a validação do modelo

Esses resultados reforçam a importância do controle de qualidade na etapa de aquisição das imagens, indicando que melhorias no pré-processamento ou o uso de técnicas de aumento de dados (*data augmentation*) podem contribuir para maior robustez do modelo em ambientes não controlados. Além disso, sugerem que, embora o modelo tenha bom desempenho geral, sua eficácia pode ser sensivelmente impactada por ruídos visuais presentes no campo.

6 Conclusão

Este estudo apresentou uma solução prática baseada em visão computacional e aprendizado profundo para automatizar a seleção dos ruminantes para a vermifugação. Os resultados obtidos, com acurácia média de 78,61% e F1-score de 71,04%, demonstram que o método proposto possui desempenho competitivo quando comparado a abordagens da literatura, com a vantagem de integrar segmentação e classificação de forma automatizada e eficiente. A etapa de segmentação da mucosa ocular, realizada com o modelo YOLOv11n-seg, também se mostrou eficaz, atingindo métricas expressivas como IoU médio de 0,76, precisão de 85,3%, recall de 87,1% e mAP@0.5 de 82,4%, o que contribuiu significativamente para o desempenho geral da solução, garantindo recortes mais consistentes e reduzindo interferências visuais indesejadas.

A comparação com outros modelos, como o RF, SVM, MPL e KNN, reforça o potencial do YOLOv11n como uma alternativa robusta para diagnósticos em campo, com baixo custo computacional e operacional. Além disso, a redução da subjetividade inerente ao método tradicional FAMACHA representa um avanço significativo para o manejo sanitário em propriedades rurais, possibilitando decisões mais objetivas e racionalizando o uso de vermífugos. O agrupamento binário (vermífuga/não vermífuga) também simplificou a implementação prática do modelo e está alinhado com recomendações zootécnicas.

No entanto, é importante destacar algumas limitações do trabalho, como a base de dados relativamente pequena e a variabilidade das condições de iluminação e foco nas imagens capturadas. Esses fatores podem ter impactado o desempenho do modelo, especialmente nos casos-limite de classificação. Estudos futuros devem buscar a ampliação e diversificação do conjunto de dados, bem como a aplicação de técnicas de aumento de dados (data augmentation) e normalização de iluminação para tornar o modelo ainda mais robusto.

Como perspectivas futuras, pretende-se validar o modelo em dispositivos móveis reais, implementar uma interface amigável para uso direto por produtores rurais, e explorar o uso do modelo em outras espécies ou condições clínicas. Também há espaço para a criação de um banco de dados colaborativo entre instituições, que possibilite o treinamento contínuo e colaborativo do sistema proposto.

Dessa forma, este trabalho não apenas demonstra a viabilidade da automatização do diagnóstico de anemia em ruminantes de pequeno e médio porte, como também reforça o papel da tecnologia como ferramenta de inclusão e apoio à pecuária familiar, promovendo saúde animal e sustentabilidade.

7 Publicações

Durante o desenvolvimento deste trabalho, duas publicações científicas foram realizadas em eventos acadêmicos relevantes na área de Computação:

ERCEMAPI 2024 – Método Computacional para Automação do FAMACHA em Cabras e Ovelhas ([ROCHA et al., 2024b](#)).

SINFO 2024 – Metodologia Fundamentada em Visão Computacional para Classificação do FAMACHA em Cabras e Ovelhas ([ROCHA et al., 2024a](#)).

Referências

- ALMEIDA, A. M. A. Detecção de anemia em ovinos através de aprendizagem profunda em imagens de mucosa ocular. *PPGEEC - SOBRAL - Dissertações defendidas na UFC*, Universidade Federal do Ceará, May 2021. Disponível em: <<https://repositorio.ufc.br/handle/riufc/73133>>. Citado 3 vezes nas páginas 26, 28 e 29.
- ARSHAD, M. F. et al. The groundbreaking impact of digitalization and artificial intelligence in sheep farming. *Research in Veterinary Science*, Elsevier, p. 105197, 2024. Citado na página 11.
- BERRAR, D. et al. *Cross-validation*. 2019. Citado na página 23.
- BOATENG, E. Y.; OTOO, J.; ABAYE, D. A. 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*, Scientific Research Publishing, v. 8, n. 4, p. 341–357, 2020. Citado 2 vezes nas páginas 17 e 32.
- COMPUTACIONAL, V. *Como funciona o algoritmo YOLO: You Only Look Once*. 2023. Accessed: 2025-07-03. Disponível em: <<https://www.visaocomputacional.com.br/como-funciona-o-algoritmo-yolo/>>. Citado 2 vezes nas páginas 6 e 19.
- DAVID, R. et al. Tensorflow lite micro: Embedded machine learning for tinymml systems. *Proceedings of Machine Learning and Systems*, v. 3, p. 800–811, 2021. Citado na página 20.
- DEMOSTHENOUS, G.; VASSILIADES, V. Continual learning on the edge with tensorflow lite. *arXiv preprint arXiv:2105.01946*, 2021. Citado na página 21.
- DINIZ, V. A. de O. et al. Utilização do método famacha como auxílio no controle de verminose em ovinos. *Pubvet, PUBVET*, v. 16, p. 195, 2022. Citado na página 11.
- EMBRAPA. *FAMACHA - Método de controle seletivo de verminoses em caprinos e ovinos*. 2024. <https://www.embrapa.br/paratec-controle-integrado-verminoses/vermes/caprinos-ovinos/famacha>. Accessed: 2025-07-03. Citado 2 vezes nas páginas 6 e 15.
- FADLILAH, U.; HANDAGA, B. et al. The development of android for indonesian sign language using tensorflow lite and cnn: an initial study. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2021. v. 1858, n. 1, p. 012085. Citado na página 22.
- FERREIRA, B. B. Práticas extensionistas na agroecologia para agropecuária. Universidade Federal de Campina Grande, 2023. Citado na página 16.
- FILHO, J. L. d. S. et al. Desenvolvimento de api para aprendizado profundo de imagens de pequenos ruminantes. *Graduação*, 2022. Citado 3 vezes nas páginas 27, 28 e 29.
- FREITAS, L. A. et al. Image analysis to automatically classify anemia based on famacha score in sheep using ocular conjunctiva images. *Translational Animal Science*, Oxford University Press US, v. 7, n. 1, p. txad118, 2023. Citado 3 vezes nas páginas 26, 28 e 29.

- FREITAS, L. A. et al. Sheepeye: a based-web app for real-time diagnosis of sheep anemia. *Translational Animal Science*, Oxford University Press US, v. 8, p. txae144, 2024. Citado 2 vezes nas páginas 27 e 28.
- GONÇALVES, N. C. Uso de visão computacional para classificação de frutos de acerola em imagens rgb. 2021. Citado na página 16.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. [S.l.]: Editora Blucher, 2000. Citado na página 16.
- HU, J.; SZYMCZAK, S. A review on longitudinal data analysis with random forest. *Briefings in bioinformatics*, Oxford University Press, v. 24, n. 2, p. bbad002, 2023. Citado na página 17.
- JIANG, P. et al. A review of yolo algorithm developments. *Procedia Computer Science*, Elsevier, v. 199, p. 1066–1073, 2022. Citado na página 19.
- JOCHER, G.; QIU, J. Ultralytics yolo11. In: . [s.n.], 2024. Disponível em: <<https://github.com/ultralytics/ultralytics>>. Citado na página 20.
- LEAL, T.; HASSUM, I. Algumas considerações sobre a verminose em pequenos ruminantes. 2021. Citado na página 14.
- MAGALHÃES, K. A.; FILHO, Z. F. H.; MARTINS, E. C. Pesquisa pecuária municipal 2020: rebanhos de caprinos e ovinos. *Boletim do Centro de Inteligência e Mercado de Caprinos e Ovinos*, v. 1, n. 16, 2021. Citado na página 11.
- MARTINS, E. C. et al. Cenários mundial e nacional da caprinocultura e da ovinocultura. *Boletim ativos de ovinos e caprinos*, v. 3, n. 2, p. 1–6, 2016. Citado na página 11.
- MAXWELL, A. E.; WARNER, T. A.; GUILLÉN, L. A. Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—part 1: Literature review. *Remote Sensing*, MDPI, v. 13, n. 13, p. 2450, 2021. Citado 2 vezes nas páginas 23 e 24.
- MAXWELL, A. E.; WARNER, T. A.; GUILLÉN, L. A. Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—part 2: Recommendations and best practices. *Remote Sensing*, MDPI, v. 13, n. 13, p. 2591, 2021. Citado na página 23.
- MINAEE, S. et al. Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 44, n. 7, p. 3523–3542, 2021. Citado na página 24.
- MINHO, A. et al. Método famacha: uma técnica para prevenir o aparecimento da resistência parasitária. 2014. Citado na página 15.
- NASCIMENTO, M. I. d. S. S. *Produção, comercialização e consumo dos produtos e subprodutos caprinos e ovinos no Nordeste do Brasil*. Tese (Doutorado) — Universidade Federal Rural de Pernambuco, 2022. Citado na página 11.
- PANAHI, O. Deep learning in diagnostics. *Journal of Medical Discoveries*, v. 2, n. 1, p. 1–6, 2025. Citado na página 18.

- PRANEETH, R. S. et al. Scaling object detection to the edge with yolov4, tensorflow lite. In: IEEE. *2023 7th International Conference on Computing Methodologies and Communication (ICCMC)*. [S.l.], 2023. p. 1547–1552. Citado na página 21.
- REDA, M. et al. Agroaid: A mobile app system for visual classification of plant species and diseases using deep learning and tensorflow lite. In: MDPI. *Informatics*. [S.l.], 2022. v. 9, n. 3, p. 55. Citado na página 22.
- REDMON, J. et al. You only look once: Unified, real-time object detection. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 779–788. Citado 3 vezes nas páginas 16, 19 e 20.
- RIBEIRO, W. F. Uma metodologia para detectar anemia em pequenos ruminantes. *Graduação*, Universidade Federal do Maranhão, 2018. Citado 4 vezes nas páginas 12, 26, 27 e 29.
- ROCHA, M. B. da et al. Metodologia fundamentada em visão computacional para classificação do famacha em cabras e ovelhas. In: *Anais do Simpósio de Informática (SINFO)*. Picos, PI, Brasil: [s.n.], 2024. Citado na página 39.
- ROCHA, M. B. da et al. Método computacional para automação do famacha em cabras e ovelhas. In: SBC. *Escola Regional de Computação do Ceará, Maranhão e Piauí (ERCEMAPI)*. [S.l.], 2024. p. 31–40. Citado na página 39.
- RUSK, N. Deep learning. *Nature Methods*, Nature Publishing Group, v. 13, n. 1, p. 35–35, 2016. Citado na página 19.
- SOUZA, L. F. de; COSTA, M. H.; RIET-CORREA, B. Mobile app for targeted selective treatment of haemonchosis in sheep. *Veterinary Parasitology*, Elsevier, v. 316, p. 109902, 2023. Citado 4 vezes nas páginas 12, 27, 28 e 29.
- SOUZA, L. F. de et al. Sistema para classificação de infestação parasitária em pequenos ruminantes. *Anais do XXXIX Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT)*, p. 1–5, 2021. Citado na página 14.
- TEIXEIRA, M. et al. 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*, IFSertãoPE, 2023. Citado na página 11.
- TENSORFLOW. *TensorFlow Lite Documentation*. 2023. Accessed: 2025-07-03. Disponível em: <<https://www.tensorflow.org/lite/>>. Citado 2 vezes nas páginas 6 e 21.
- ULTRALYTICS. Test trained yolo model on coco dataset. In: . [s.n.], 2024. Acesso em: 9 jun. 2025. Disponível em: <<https://github.com/orgs/ultralytics/discussions/17167>>. Citado na página 19.



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA “JOSÉ ALBANO DE MACEDO”

Identificação do Tipo de Documento

- () Tese
- () Dissertação
- (X) Monografia
- () Artigo

Eu, **Mauricio Benjamin da Rocha**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Classificação Automatizada de Pequenos Ruminantes para Vermifugação com YOLOv11n e Análise Ocular Baseada no Método FAMACHA** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI, 08 de julho de 2025.

Documento assinado digitalmente
gov.br MAURICIO BENJAMIN DA ROCHA
Data: 08/07/2025 23:43:53-0300
Verifique em <https://validar.iti.gov.br>

Assinatura