

Artur Hildegardo de Moura Silva
Orientador: Dr. Flávio Henrique Duarte de Araújo

**Criação de um algoritmo de baixo custo
computacional para a detecção do grau
FAMACHA em caprinos e ovinos.**

Picos - PI
21 de janeiro de 2023

Artur Hildegardo de Moura Silva
Orientador: Dr. Flávio Henrique Duarte de Araújo

**Criação de um algoritmo de baixo custo computacional
para a detecção do grau FAMACHA em caprinos e
ovinos.**

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
21 de janeiro de 2023

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

S586c Silva, Artur Hildegardo de Moura.
Criação de um algoritmo de baixo computacional para a detecção do grau FAMACHA em caprinos e ovinos./ Artur Hildegardo de Moura Silva. – 2023.
39 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, 2023.
“Orientadora: Prof. Flávio Henrique Duarte de Araújo”

1. Famacha-método. 2. Tecnologia-agricultura. 3. Caprinos-ovinos.
I. Silva, Artur Hildegardo de Moura. II. Araújo, Flávio Henrique Duarte de.
III. Título.

CDD 658.406 3

Elaborado por Sérvulo Fernandes da Silva Neto CRB 15/603

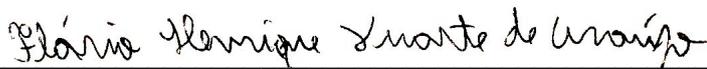
CRIAÇÃO DE UM ALGORITMO DE BAIXO CUSTO COMPUTACIONAL PARA A
DETECÇÃO DO GRAU FAMACHA EM CAPRINOS E OVINOS

ARTUR HILDEGARDO DE MOURA SILVA

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

Data de Aprovação

Picos – PI, 01 de fevereiro de 2024



Prof. Flávio Henrique Duarte de Araújo



Prof. Daniel de Sousa Luz



Prof. Thiago José Barbosa Lima

Agradecimentos

Neste momento de conclusão, quero expressar minha profunda gratidão a todas as pessoas que desempenharam papéis cruciais e significativos ao longo deste desafiador percurso acadêmico.

À minha querida mãe, Edinalva de Araujo Moura Da Silva, e à minha amada avó, Marlinda de Araujo Moura, dedico um agradecimento especial. Seu apoio incondicional não apenas me sustentou, mas também foi a força motriz por trás da minha jornada educacional. Nos momentos de dúvida, foram suas palavras de encorajamento que me impulsionaram a seguir adiante. Sou profundamente grato por tudo que fizeram por mim, por serem os pilares que sustentaram meu caminho educacional e por terem acreditado em cada passo que dei.

Ao meu respeitado orientador, o professor Dr. Flávio Henrique Duarte de Araújo, expressei minha sincera gratidão. Sua orientação habilidosa, correções minuciosas e ensinamentos valiosos não apenas moldaram este trabalho, mas também influenciaram diretamente meu crescimento acadêmico. Seu apoio constante foi crucial para que eu continuasse a trilhar o caminho do conhecimento, e por isso, estendo minha profunda gratidão. Aos amigos que compartilharam comigo os desafios e sucessos desta jornada, em especial, Bryan Martins Silva, Gerson de Sousa Santos Junior, José Maria dos Santos Leal e Pablo Duarte da Silva, agradeço por estarem presentes. Seu apoio constante, as palavras de incentivo e a colaboração foram fundamentais. Cada um de vocês contribuiu para tornar esta experiência acadêmica mais enriquecedora e significativa.

Este trabalho e a conclusão bem-sucedida desta etapa acadêmica não teriam sido possíveis sem o apoio generoso e a presença essencial de cada um de vocês. Agradeço por serem parte integrante da minha jornada, por sempre me encorajarem a continuar estudando e por serem fundamentais em minha trajetória educacional. Vocês têm minha mais profunda gratidão.

Robert Collier

O sucesso é a soma de pequenos esforços repetidos dia após dia.

Resumo

A criação de caprinos e ovinos é uma prática tradicional na agricultura brasileira, e sua relevância econômica tem experimentado um aumento significativo nos últimos anos. No entanto, a presença do parasita *Haemonchus contortus*, que se alimenta do sangue desses animais, tem representado um desafio constante para os criadores, resultando em prejuízos consideráveis e gastos regulares com vermifugação. Para lidar com esse problema, foi desenvolvido o método FAMACHA, uma abordagem essencial para a gestão da saúde desses rebanhos. O FAMACHA é especialmente indicado para o controle seletivo em regiões onde o *Haemonchus contortus* é predominante. Esse método utiliza um prático cartão colorido para avaliar o nível de anemia nas mucosas oculares dos animais, permitindo que os criadores identifiquem rapidamente aqueles que necessitam de vermifugação. Com o objetivo de aprimorar ainda mais a saúde dos rebanhos, a pesquisa propõe a aplicação de técnicas de visão computacional para identificar o grau de FAMACHA por meio de imagens da mucosa abomasal dos animais. Essa abordagem oferece uma maneira mais eficiente e precisa de gerenciar a saúde dos caprinos e ovinos, economizando tempo e recursos para os produtores e assegurando o bem-estar desses animais. A pesquisa abordou a integração de diversas técnicas de visão computacional com o objetivo de analisar, interpretar e extrair informações relevantes para uma futura aplicação em animais. O processo foi dividido em quatro etapas essenciais. A primeira fase envolveu a aquisição de imagens, que serviram como dados de treinamento e teste. Em seguida, na segunda etapa, aplicou-se o pré-processamento, que incluiu o uso de um algoritmo para aumentar o conjunto de imagens disponíveis e a aplicação de um método de afiação (sharpening) para melhorar a nitidez das imagens, facilitando a extração de informações. A terceira etapa consistiu na segmentação, na qual a imagem foi dividida em segmentos para aprimorar o reconhecimento da área de interesse. Para isso, empregou-se o método de segmentação Otsu, que separa a imagem em duas classes distintas com base no histograma de intensidades de pixel. Por fim, na quarta e última etapa, a classificação, foram testados diversos classificadores de baixo poder computacional, incluindo SVM, KNN, Naive Bayes e Random Forest. Notavelmente, o Random Forest demonstrou o melhor desempenho, alcançando uma acurácia de 0.9629 e um kappa score de 0.9201. Esses resultados evidenciam a capacidade do método em identificar os níveis de FAMACHA de acordo com o cartão, indicando sua eficácia na aplicação proposta.

Palavras-chaves: FAMACHA, visão computacional, caprinos, ovinos.

Abstract

Goat and sheep farming is a traditional practice in Brazilian agriculture, and its economic relevance has experienced a significant increase in recent years. However, the presence of the parasite *Haemonchus contortus*, which feeds on the blood of these animals, has represented a constant challenge for breeders, resulting in considerable losses and regular expenses with deworming. To deal with this problem, the FAMACHA method was developed, an essential approach to managing the health of these herds. FAMACHA is especially indicated for selective control in regions where *Haemonchus contortus* is predominant. This method uses a practical colored card to assess the level of anemia in the animals' ocular mucous membranes, allowing breeders to quickly identify those that require deworming. With the aim of further improving the health of livestock, the research proposes the application of computer vision techniques to identify the degree of FAMACHA through images of the animals' abomasal mucosa. This approach offers a more efficient and accurate way to manage the health of goats and sheep, saving producers time and resources and ensuring the welfare of these animals. The research addressed the integration of several computer vision techniques with the aim of analyzing, interpreting and extracting relevant information for future application in animals. The process was divided into four essential steps. The first phase involved the acquisition of images, which served as training and testing data. Then, in the second stage, pre-processing was applied, which included the use of an algorithm to increase the set of available images and the application of a sharpening method to improve the sharpness of the images, facilitating extraction of information. The third step consisted of segmentation, in which the image was divided into segments to improve recognition of the area of interest. For this, the Otsu segmentation method was used, which separates the image into two distinct classes based on the histogram of pixel intensities. Finally, in the fourth and final stage, classification, several classifiers with low computational power were tested, including SVM, KNN, Naive Bayes and Random Forest. Notably, Random Forest demonstrated the best performance, achieving an accuracy of 0.9629 and a kappa score of 0.9201. These results demonstrate the method's ability to identify FAMACHA levels according to the card, indicating its effectiveness in the proposed application.

Lista de ilustrações

Figura 1 – Avaliação clínica pelo cartão FAMACHA. Fonte: (VIEIRA, 2008) . . .	17
Figura 2 – Fluxograma representando o processo metodológico adotado no estudo.	25
Figura 3 – Imagens originais sem nenhum tratamento.	26
Figura 4 – Imagens originais e imagens redimensionadas para 100x100.	26
Figura 5 – Imagens após aplicação do aumento de dados (data augmentation). . .	27
Figura 6 – Imagens após redimensionamento e imagens após a aplicação do método Macenko.	27
Figura 7 – Imagens após redimensionamento e aplicação do método Macenko, combinado com a técnica de sharpening para realce de detalhes.	28

Lista de tabelas

Tabela 1 – Comparação dos trabalhos.	23
Tabela 2 – Todos as métricas sem as etapas de segmentação	33
Tabela 3 – Todos as métricas sem a etapa de Macenko	34
Tabela 4 – Todos as métricas sem a etapa de Sharpening	34
Tabela 5 – Com todas as etapas	34

Lista de abreviaturas e siglas

KNN	K-nearest neighbors
SVM	Support Vector Machines
BIC	Border/Interior Classification
PDI	Processamento Digital de Imagens

Lista de símbolos

=	Igualdade
*	Multiplicação
+	Soma
-	Subtração

Sumário

1	Introdução	14
1.1	Objetivos	14
1.1.1	Objetivos específicos	15
2	Referencial Teórico	16
2.1	Famacha e a Saúde de Caprinos e Ovinos	16
2.2	Visão Computacional	17
2.3	Classificadores	18
2.3.1	Naive Bayes	18
2.3.2	SVM (Support Vector Machine)	18
2.3.3	KNN (K-Nearest Neighbors)	19
2.3.4	Random Forest	19
2.4	Método Macenko	19
2.5	Método Sharpening	20
2.6	Método OTSU	20
3	Trabalhos Relacionados	22
3.1	Considerações	23
3.1.1	Desafios na Classificação dos diferentes graus FAMACHA	23
3.1.2	Influência da Quantidade e Diversidade de Dados:	24
3.1.3	Potencial das Tecnologias de Monitoramento:	24
4	Método proposto	25
4.1	Aquisição das imagens	25
4.2	Pre-processamento	26
4.3	Segmentação	28
4.4	Classificadores	29
4.4.1	Random Forest	29
4.4.2	SVM (Support Vector Machine)	29
4.4.3	KNN (K-Nearest Neighbors)	30
4.4.4	Naive Bayes	30
4.4.5	Métricas de avaliação	30
5	Resultado Comparativo	33
6	Conclusão	36

Referências **37**

1 Introdução

A criação de caprinos e ovinos é uma prática tradicional na agricultura brasileira que ganhou crescente relevância econômica nos últimos anos. No entanto, a presença persistente do parasita *Haemonchus contortus*, que se alimenta do sangue desses animais, tem sido um desafio contínuo para os criadores, resultando em prejuízos consideráveis e despesas regulares com vermifugação (DINIZ et al., 2022).

Para enfrentar esse desafio, foi desenvolvido o método FAMACHA, uma abordagem fundamental para a gestão da saúde desses rebanhos, especialmente em regiões onde o *Haemonchus contortus* é prevalente (COSTA et al., 2018). O FAMACHA utiliza um prático cartão colorido para avaliar o nível de anemia nas mucosas oculares dos animais (NA, 2021), permitindo aos criadores identificar rapidamente aqueles que necessitam de vermifugação.

É importante ressaltar que o exame FAMACHA é subjetivo, e, portanto, é recomendado que um mesmo profissional realize a análise de todo o rebanho. Essa prática contribui para uma avaliação mais consistente e confiável, uma vez que a interpretação das cores no cartão pode variar entre diferentes observadores.

Com o objetivo de aprimorar ainda mais a saúde dos rebanhos, esta pesquisa propõe a aplicação de técnicas de visão computacional para identificar o grau de FAMACHA por meio de imagens da mucosa ocular dos animais. Essa abordagem oferece uma maneira mais eficiente e precisa de gerenciar a saúde dos caprinos e ovinos, economizando tempo e recursos para os produtores e assegurando o bem-estar desses animais.

Por essa razão, a adoção da análise de imagens por meio de técnicas de processamento de imagens e aprendizado de máquina tem se destacado como uma solução promissora para aprimorar a eficiência e a precisão na avaliação dos níveis de FAMACHA em animais. No entanto, é importante observar que a análise de imagens pode se tornar particularmente desafiadora em situações em que ocorrem problemas na captura das imagens, como iluminação inadequada, presença de sujeira na câmera, desfoco da área de interesse, entre outros.

1.1 Objetivos

Este estudo tem como objetivo principal desenvolver um método de visão computacional para identificar caprinos e ovinos que necessitam de vermifugação. A proposta visa criar uma solução eficaz e automatizada, utilizando técnicas de processamento de imagens e aprendizado de máquina para avaliar os níveis de FAMACHA nas imagens da mucosa ocular desses animais. Para alcançar esse propósito, delineamos objetivos específicos, que serão detalhados nas seções seguintes.

1.1.1 Objetivos específicos

Com o propósito de conduzir esta pesquisa, delineamos os seguintes objetivos específicos:

- Avaliar técnicas de normalização de cores para melhorar a qualidade das imagens.
- Utilizar modelos de aprendizado de máquina e avaliá-los com métricas como acurácia, kappa, F1 score, Recall e Precisão.
- Analisar o impacto das diferentes técnicas de segmentação na precisão da classificação para a decisão de vermifugar ou não, com base nas imagens da mucosa ocular.

2 Referencial Teórico

Este capítulo apresentará alguns temas, sendo eles FAMACHA e a saúde de caprinos e ovinos. A utilização de classificadores para realizar a identificação do grau de FAMACHA no animal está presente; os classificadores utilizados foram SVM, KNN, Random Forest e *Naive Bayes* na análise de imagens da conjuntiva ocular. Além disso, foram abordadas técnicas como o Método *Macenko* para normalização de cores, a Técnica de *Sharpening* para realce de detalhes e o Método de Otsu para segmentação de áreas de interesse. Esta introdução visa fornecer uma visão geral dos principais enfoques explorados neste capítulo.

2.1 Famacha e a Saúde de Caprinos e Ovinos

O método FAMACHA, desenvolvido na África do Sul pelos pesquisadores François Malan, Gareth Bath e Jan van Wyk, é amplamente reconhecido como uma abordagem crucial para o controle de infestações parasitárias em rebanhos de ovinos e caprinos (SOUZA et al., 2021). Este método visa um tratamento seletivo, permitindo a administração de vermifugantes apenas aos animais que apresentam traços visíveis de anemia na mucosa ocular.

O objetivo principal do método Famacha é identificar clinicamente animais com diferentes graus de anemia, frequentemente causados pela infecção do parasita hematófago *Haemonchus contortus* (LEAL; HASSUM, 2021). A avaliação ocorre indiretamente, utilizando a coloração da mucosa ocular do animal, com uma escala de cinco níveis de classificação:

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

A verificação da cor da mucosa é feita ao expor a conjuntiva do animal, pressionando a pálpebra superior, e comparando com um cartão de teste Famacha, ilustrado na Figura 1. A monitorização regular dos animais é essencial para evitar o desenvolvimento de resistência a anti-helmínticos.



Figura 1 – Avaliação clínica pelo cartão FAMACHA. Fonte: (VIEIRA, 2008)

O processamento de imagens é fundamental para a automação do método Famacha e divide-se em aquisição, pré-processamento, extração de características e classificação (GONÇALVES, 2021). A pesquisa explorou técnicas de processamento de imagens e aprendizado de máquina para automatizar a identificação dos níveis de Famacha a partir de imagens da mucosa ocular de caprinos e ovinos, contribuindo para uma gestão eficiente da saúde desses rebanhos.

Uma vantagem fundamental do método FAMACHA é a economia de recursos, permitindo o tratamento seletivo de ovinos com anemia (FERREIRA, 2023). Reduz os custos associados ao uso indiscriminado de antiparasitários, prolonga a eficácia desses medicamentos e contribui para a sustentabilidade da produção de ovinos. O uso excessivo e inadequado de antiparasitários tem contribuído para o desenvolvimento de resistência parasitária (MINHO; MOLENTO, 2014). O método FAMACHA desempenha um papel crucial na mitigação desse problema, reduzindo a pressão de seleção sobre os parasitas, atrasando o desenvolvimento de resistência e preservando a eficácia dos antiparasitários.

2.2 Visão Computacional

A área de visão computacional é uma área multidisciplinar que utiliza técnicas de computação e processamento de imagens para capacitar os computadores a interpretar e compreenderem informações visuais. No contexto do método FAMACHA em caprinos e ovinos, aplicamos métodos avançados de visão computacional para analisar imagens da conjuntiva ocular dos animais.

Essas técnicas envolvem diferentes etapas, como pré-processamento para melhorar a qualidade das imagens, normalização de cores e método sharpening para realçar caracte-

rísticas. Utilização da segmentação para identificar áreas específicas de interesse, como a conjuntiva ocular.

Algoritmos de aprendizado de máquina, como *Naive Bayes*, SVM, KNN e *Random Forest*, são utilizados para classificar e interpretar os padrões extraídos das imagens. Essas abordagens não apenas automatizam o processo de análise, mas também aprimoram a precisão do diagnóstico, fornecendo informações valiosas sobre os níveis de FAMACHA nos ovinos.

A aplicação de técnicas de visão computacional desempenha um papel crucial ao integrar métodos avançados de processamento de imagens e aprendizado de máquina. Essa integração proporciona uma abordagem eficaz e precisa para o controle do grau de FAMACHA em ovinos e caprinos, contribuindo significativamente para aprimorar a eficiência do diagnóstico do nível FAMACHA que o animal possui.

2.3 Classificadores

Neste contexto de controle de verminose em ovinos, a escolha e avaliação adequadas de algoritmos de aprendizado de máquina são de extrema importância. Os algoritmos selecionados para análise incluem o Naive Bayes, SVM (Support Vector Machine), KNN (K-Nearest Neighbors) e *Random Forest*, e as métricas de avaliação utilizadas para a comparação são a *acurácia*, *Kappa Score*, *recall*, *precision* e o *f1 score*.

2.3.1 Naive Bayes

O Naive Bayes, conhecido por sua simplicidade e eficiência computacional, pode ser uma escolha inteligente neste contexto (DEMOLINER; ALVES, 2017). Imagine classificar animais com base na coloração da conjuntiva ocular, avaliada pelo método FAMACHA. Aqui, o *Naive Bayes* pode ser usado para determinar se um animal precisa de tratamento ou não. Sua capacidade de processamento rápido e baixo consumo de recursos o torna uma opção atraente.

2.3.2 SVM (Support Vector Machine)

O SVM é um algoritmo amplamente utilizado na classificação de dados, especialmente em tarefas de classificação binária (SOUZA et al., 2021). No método FAMACHA, distinguir entre animais que necessitam de tratamento e aqueles que não precisam é uma tarefa clássica de classificação binária. O SVM é altamente eficaz nesse contexto e é conhecido por criar limites de decisão claros, tornando-o uma escolha lógica.

2.3.3 KNN (K-Nearest Neighbors)

O KNN é uma abordagem simples e intuitiva que pode ser valiosa na identificação de animais anêmicos baseado nos estudos do (RIBEIRO, 2018). Ele funciona com base na similaridade entre um animal e seus vizinhos mais próximos. No contexto do FAMACHA, em que a semelhança entre animais anêmicos pode ser explorada, o KNN brilha. Sua natureza intuitiva o torna acessível, mas sua eficácia também é notável.

2.3.4 Random Forest

O *Random Forest* é uma escolha robusta e versátil. Ele é frequentemente preferido devido ao seu bom desempenho em várias aplicações. Neste estudo, o *Random Forest* mostrou resultados superiores, sendo considerado um dos algoritmos mais eficazes. Além disso, é computacionalmente eficiente, tornando-o uma opção atraente para o controle de verminose em ovinos e caprinos.

A escolha dessas métricas de avaliação e algoritmos se baseou na necessidade de selecionar métodos que sejam eficazes e, ao mesmo tempo, eficientes em termos de poder computacional. A preferência pelo *Random Forest*, devido ao seu melhor desempenho, aponta para a relevância e a eficácia desse algoritmo no contexto do controle de verminose em ovinos e caprinos.

2.4 Método Macenko

O Método de Macenko é uma abordagem crucial na normalização de cores em imagens médicas, especialmente em campos como patologia e histologia. Desenvolvido para lidar com desafios relacionados à variação de cores em imagens histopatológicas, esse método desempenha um papel significativo na promoção da consistência e precisão na análise de imagens médicas (JUNIOR, 2023).

A técnica de Macenko concentra-se na criação de um perfil de cores de referência por meio da seleção de pixels representativos em regiões semelhantes a cores puras, comumente denominadas "pixels de fundo". Esses pixels fornecem uma base para a normalização das intensidades cromáticas em todas as imagens, permitindo a comparação e análise mais precisas, independentemente das variações originais nas condições de aquisição ou coloração (MACENKO et al., 2009).

A fórmula para a normalização de cores utilizando o Método de Macenko é expressa da seguinte maneira:

$$I_{norm}(x, y, c) = \frac{I(x, y, c) - \mu_c}{\sigma_c}, \quad (2.1)$$

onde:

- $I_{norm}(x, y, c)$ representa a intensidade normalizada do canal de cor c no ponto (x, y) ,
- $I(x, y, c)$ é a intensidade original do canal de cor c no ponto (x, y) ,
- μ_c é a média das intensidades do canal c nos pixels de fundo,
- σ_c é o desvio padrão das intensidades do canal c nos pixels de fundo.

Essa fórmula 2.1 calcula a diferença entre a intensidade original e a média da região de referência, normalizada pelo desvio padrão. Essencialmente, isso ajusta as intensidades de cada pixel com base na variação típica da região de referência.

O Método de *Macenko* contribuiu significativamente para o sucesso do estudo, mitigando os efeitos da variação de cores e assegurando resultados precisos na classificação dos níveis do grau de FAMACHA em ovinos e caprinos.

2.5 Método Sharpening

O método de afiação, também conhecido como *sharpening*, é uma técnica empregada no processamento de imagens para realçar detalhes e bordas, proporcionando uma melhoria perceptível na nitidez geral da imagem. Neste trabalho, utilizamos o método de afiação para destacar características da mucosa ocular presentes nas imagens adquiridas.

O processo de afiação consiste na aplicação de um filtro específico sobre a imagem original. Essa matriz é convolucionada com a imagem, promovendo o realce de detalhes e ressaltando as transições de intensidade, tornando as bordas mais proeminentes (GARCÍA, 2017). A convolução destaca as regiões em que há variação significativa de intensidade na imagem, enfatizando características importantes.

O método de afiação é uma etapa crucial na preparação das imagens para análise, contribuindo para a qualidade visual das mesmas. A escolha criteriosa desse método visa destacar elementos relevantes para a análise posterior no contexto do estudo.

2.6 Método OTSU

O método de Otsu, proposto por Nobuyuki Otsu em 1979, é uma técnica amplamente reconhecida na área de processamento de imagem e visão computacional. Esse método é especialmente eficaz na etapa de segmentação, onde o objetivo é dividir uma imagem em regiões distintas com base nas propriedades de intensidade dos pixels (TOROK, 2016).

A abordagem de Otsu fundamenta-se na análise do histograma da imagem, explorando as diferentes distribuições de intensidade presentes. O método busca automaticamente encontrar um valor limiar que maximize a variância entre as classes de pixels, tornando a segmentação mais precisa (NIÑO et al., 2021).

A aplicação do método de Otsu proporciona a determinação de um limiar ótimo, maximizando a variância entre as classes e, conseqüentemente, otimizando a qualidade da segmentação. Esse método é particularmente valioso em cenários nos quais não há conhecimento prévio sobre a distribuição das intensidades na imagem.

Ao incorporar o método de Otsu na análise de imagens, busca-se aprimorar a eficiência e precisão da segmentação, contribuindo para o sucesso de estudos que dependem fortemente da extração de informações visuais.

3 Trabalhos Relacionados

Foi apresentado no estudo de [Demoliner e Alves \(2017\)](#) um método para classificar o grau de anemia de caprinos e ovinos com base na análise da mucosa ocular. Para desenvolver esse método, empregaram técnicas de Processamento Digital de Imagens (PDI) com o objetivo de aprimorar a qualidade das imagens, corrigindo possíveis defeitos de aquisição e realçando áreas de interesse. O classificador adotado foi o *Naive Bayes*, destinado a determinar se os animais apresentavam indícios de anemia. No entanto, enfrentaram desafios na etapa de rotulagem, pois o algoritmo enfrentou dificuldades para distinguir entre os graus 3 e 4 de anemia.

No artigo de [RIBEIRO \(2018\)](#), foi proposto um método para a detecção de anemia em pequenos ruminantes. Para criar essa abordagem, empregaram o método de Classificação de Fronteira/Interior (BIC). Dois classificadores, o *K-nearest neighbors* (KNN) e as *Support Vector Machines* (SVM), foram utilizados devido à sua facilidade de aplicação e baixa demanda computacional. No entanto, a principal limitação desse trabalho residiu na etapa de segmentação, que consumiu considerável capacidade de processamento do dispositivo.

No artigo de [Montout et al. \(2020\)](#), é apresentado um estudo que demonstra a eficácia do monitoramento de animais por meio de biologgers de baixo custo, resultando na redução dos custos de mão de obra, melhoria do bem-estar animal e viabilização de tratamentos seletivos. A classificação do conteúdo foi realizada utilizando *Support Vector Machines* (SVM), alcançando uma precisão impressionante de até 80%. Este estudo ressalta a praticidade e eficiência dessas tecnologias para enfrentar os desafios na pecuária global, especialmente em comunidades com recursos limitados.

Em [Souza et al. \(2021\)](#), foi proposto um método para classificar os diferentes graus da escala FAMACHA, empregando uma Rede Neural Artificial. Para criar esse método, adotaram técnicas que redimensionaram as imagens para uma matriz de 256x256 pixels e, posteriormente, as vetorizaram. A classificação das imagens foi realizada por meio de um classificador *Support Vector Machines* (SVM). No entanto, é importante notar uma limitação significativa deste trabalho, que se relaciona à ausência de animais classificados com grau 5 na base de dados utilizada.

No artigo de [Nascimento e Teixeira \(2021\)](#), foi desenvolvido um método para determinar o grau de anemia em ovinos e caprinos. As imagens coletadas foram organizadas em cinco categorias que correspondiam aos níveis de anemia, conforme estabelecido pelo teste FAMACHA. O classificador *K-nearest neighbors* (KNN) foi empregado para a classificação, baseando-se na similaridade entre as imagens. No entanto, o trabalho obteve uma acurácia de 0,594%, o que se deveu principalmente à escassez de imagens disponíveis no banco de dados, especialmente nas categorias mais anêmicas.

Pode ser notado a baixa acurácia obtida, principalmente nas categorias mais anê-

micar, destaca a influência direta da quantidade e diversidade de dados disponíveis. A falta de imagens para treinamento em categorias críticas pode afetar significativamente o desempenho do classificador.

No trabalho conduzido por [Januário \(2023\)](#), foram apresentados métodos para a avaliação e análise de imagens da conjuntiva ocular, visando classificar os níveis de anemia com base nos escores do método FAMACHA. O estudo empregou técnicas de aprendizado de máquina e análise de imagens. O método random forest foi utilizado para segmentar as imagens, selecionando os pixels que pertencem a conjuntiva ocular do animal. Além disso, o algoritmo Random Forest foi utilizado para realizar a classificação das imagens, considerando diversos atributos do rebanho, como classe de idade, fazenda, peso corporal e o sexo.

A Tabela 1 resume um comparativo dos trabalhos relacionados sob três aspectos: se foi realizada segmentação, qual o classificador utilizado e qual a acurácia obtida.

Autor	Segmentação	Classificador	Acurácia (Média)
Demoliner e Alves (2017)	Não	Naive Bayes	0,506%
RIBEIRO (2018)	Limiarização	KNN e SVM	0,897% e 0,862%
Montout et al. (2020)	Não	SVM	0,800%
Souza et al. (2021)	Não	SVM	0,751%
Nascimento e Teixeira (2021)	Não	KNN	0,594%
Januário (2023)	Random Forest	Random Forest	0,793%

Tabela 1 – Comparação dos trabalhos.

3.1 Considerações

Ao revisar os estudos abordados, algumas considerações importantes sobre os desafios na classificação de anemia emergem:

3.1.1 Desafios na Classificação dos diferentes graus FAMACHA

- No estudo de ([DEMOLINER; ALVES, 2017](#)), a dificuldade na distinção entre os graus 3 e 4 de anemia destacou a complexidade da rotulagem, indicando a necessidade de aprimoramentos nessa etapa crítica.

- O método proposto por ([RIBEIRO, 2018](#)) enfrentou limitações na etapa de segmentação, evidenciando a importância de otimizações para garantir eficiência computacional.

- A ausência de animais classificados com grau 5 na base de dados utilizada em ([SOUZA et al., 2021](#)) ressalta a importância da representatividade abrangente para treinamento de modelos.

3.1.2 Influência da Quantidade e Diversidade de Dados:

- O estudo de (NASCIMENTO; TEIXEIRA, 2021) destaca a influência direta da quantidade e diversidade de dados disponíveis na acurácia do classificador, especialmente em categorias críticas de anemia.

3.1.3 Potencial das Tecnologias de Monitoramento:

- O estudo de (JANUÁRIO, 2023) destaca o potencial das tecnologias de *biologgers*, que são dispositivos de monitoramento biológico de baixo custo. Esses *biologgers* oferecem eficácia na redução de custos de mão de obra e melhoram o bem-estar animal. A precisão de até 80%, alcançada pelo uso de *Support Vector Machines* (SVM), ressalta a viabilidade dessas tecnologias, especialmente em comunidades com recursos limitados.

Em conjunto, essas considerações ressaltam a importância contínua da pesquisa e desenvolvimento na área de avaliação de anemia em pequenos ruminantes, destacando desafios específicos. Além disso, é relevante notar que, até o momento, nenhum trabalho investigou o uso de normalização de cores, aspecto que pode ser fundamental para aprimorar os métodos existentes e explorar novas abordagens inovadoras. Essa lacuna destaca a necessidade de investigações adicionais nesse campo, visando contribuir significativamente para o avanço das técnicas de avaliação do método FAMACHA nos caprinos e ovinos.

4 Método proposto

Este capítulo descreve o método proposto neste trabalho, organizado em quatro etapas distintas: aquisição de dados, pré-processamento, segmentação e classificação, conforme ilustrado na Figura 2.

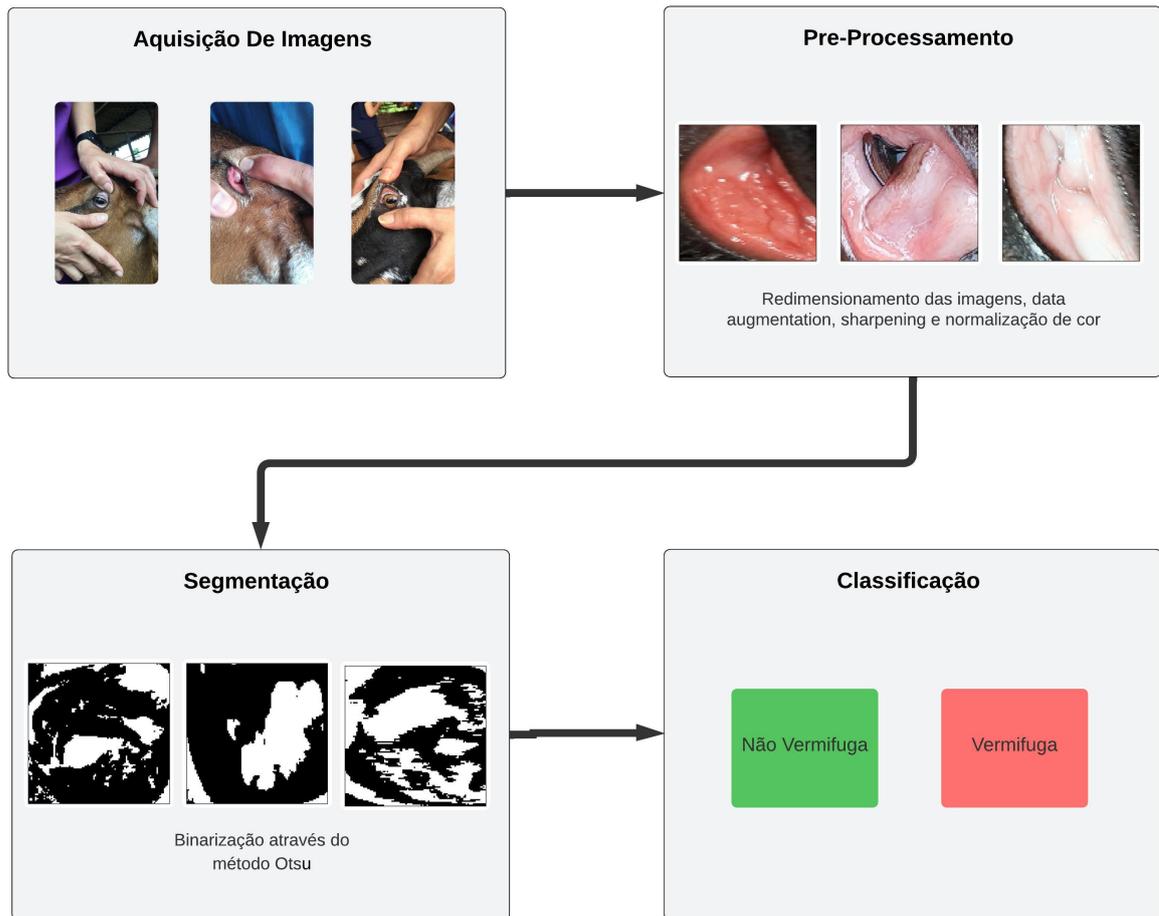


Figura 2 – Fluxograma representando o processo metodológico adotado no estudo.

4.1 Aquisição das imagens

As coletas foram realizadas em uma propriedade rural localizada na cidade de Teresina. Utilizamos diversos modelos de *smartphones* com o sistema operacional *Android* para capturar as 138 imagens que compõem o conjunto de dados. É importante ressaltar que essas imagens apresentam uma considerável variação de tamanho, com dimensões que variam desde uma altura mínima de 26 pixels e largura mínima de 28 pixels até uma

altura máxima de 1194 pixels e largura máxima de 674 pixels. Uma prévia dessas imagens pode ser visualizada na Figura 3.

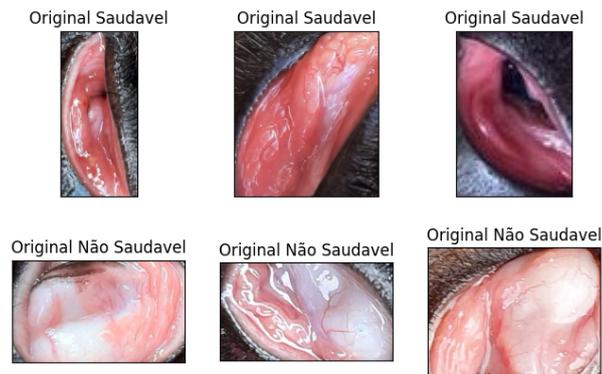


Figura 3 – Imagens originais sem nenhum tratamento.

4.2 Pre-processamento

Durante a fase de pré-processamento, uma etapa essencial consistiu na padronização das dimensões das imagens. Todas as amostras foram ajustadas para o tamanho de 100x100, conforme o exemplo ilustrado na Figura 4, com o propósito de assegurar uniformidade e consistência em todo o conjunto de dados. Essa ação de redimensionamento foi empreendida com o intuito de estabelecer um padrão que simplificasse as etapas subsequentes de análise e processamento.

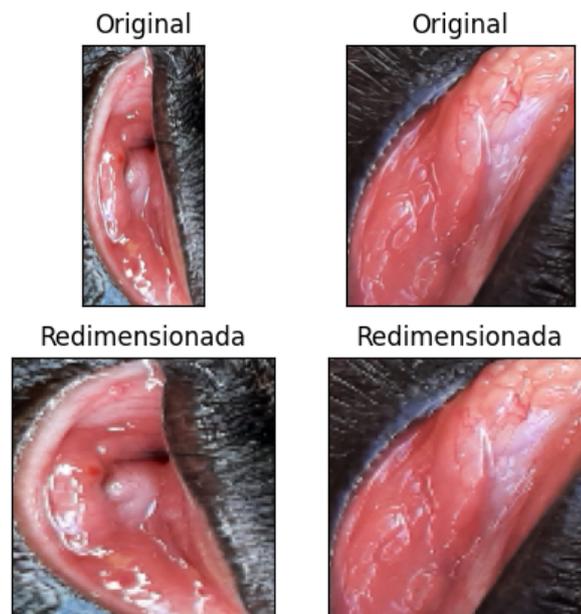


Figura 4 – Imagens originais e imagens redimensionadas para 100x100.

Após os recortes das imagens, foi adotada uma estratégia para lidar com a limitação do tamanho da base de dados. A técnica de *data augmentation* foi aplicada de forma abrangente, promovendo deslocamentos de um pixel da direita para a esquerda em todas as imagens, assim como movimentos de um pixel de cima para baixo, conforme evidenciado na figura 5. Essa abordagem resultou em um substancial aumento na base de dados, passando de 138 para 414 imagens. O *data augmentation* revelou-se uma técnica valiosa para melhorar a representatividade e diversidade do conjunto de dados, aspectos cruciais para o desempenho do método.



Figura 5 – Imagens após aplicação do aumento de dados (*data augmentation*).

Adicionalmente, no processo de pré-processamento, foi empregado o método Macenko para normalização de cores. Essa técnica foi selecionada para lidar com a variação de cor presente nas imagens, buscando garantir consistência na análise independentemente das condições de iluminação e captura. O método Macenko atua no espaço de cores RGB, equilibrando as intensidades de cor em cada canal e preservando a informação cromática relevante como pode ser visto na Figura 6. Essa etapa de normalização contribuiu para mitigar variações indesejadas, mantendo a fidelidade das características das imagens e aprimorando a robustez do método proposto para a classificação FAMACHA.

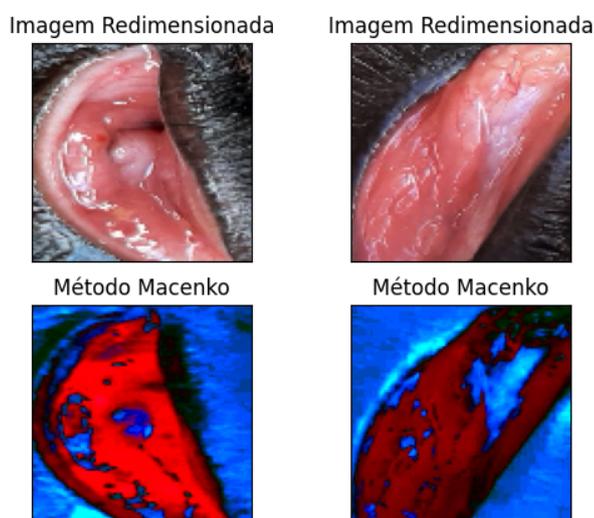


Figura 6 – Imagens após redimensionamento e imagens após a aplicação do método Macenko.

Além disso, para otimizar a qualidade visual das imagens após o processo de redimensionamento e *data augmentation*, foi aplicado o método de *sharpening*. Essa técnica realça bordas e detalhes, contribuindo para uma percepção mais clara e definida das características-chave, como a coloração da conjuntiva ocular como pode ser visto na Figura 7, que contem o método *sharpening* com o macenko. O *sharpening* desempenha um papel crucial na distinção nítida dessas características, fortalecendo a eficácia do método no diagnóstico preciso da condição de anemia em ovinos e caprinos.

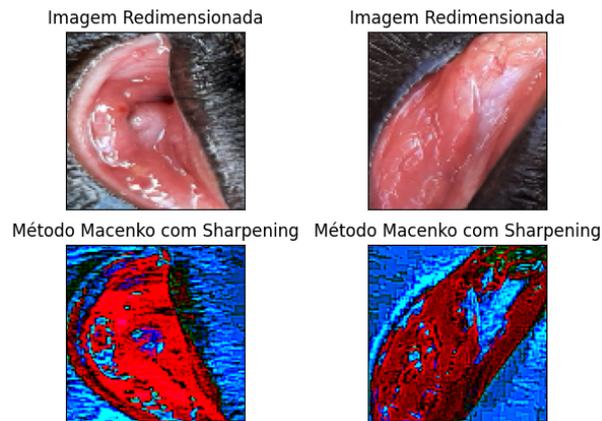


Figura 7 – Imagens após redimensionamento e aplicação do método Macenko, combinado com a técnica de *sharpening* para realce de detalhes.

4.3 Segmentação

No estágio de segmentação, todas as imagens foram convertidas para o espaço de cores cinza, simplificando o processo de análise e destacando as características relevantes para a classificação FAMACHA. A escolha de trabalhar com imagens em escala de cinza visa facilitar a identificação de variações de intensidade luminosa, uma vez que a coloração da conjuntiva ocular é um indicador crítico no método FAMACHA.

Para realizar a segmentação, foi empregado o método de Otsu, uma técnica amplamente utilizada na binarização de imagens. O método de Otsu busca encontrar um limiar ideal que maximize a variância entre as classes de pixels, considerando que a imagem pode ser dividida em duas classes distintas: a primeira relacionada às regiões escuras e a segunda às regiões claras. Dessa forma, o limiar obtido por meio do método de Otsu otimiza a separação entre áreas de interesse e o fundo da imagem, realçando as características relevantes.

A escolha do método de Otsu é respaldada por sua eficácia em situações em que a distribuição dos níveis de intensidade na imagem não é conhecida a priori. Ele se adapta automaticamente às características específicas de cada imagem, tornando-o uma escolha sólida para lidar com a variabilidade nas condições de captura das imagens utilizadas no contexto do diagnóstico FAMACHA.

Após a aplicação do método de Otsu, as imagens foram readaptadas para o modelo RGB. Esse processo foi necessário para reintroduzir as informações de cor às imagens segmentadas, possibilitando uma análise mais completa e preservando a riqueza cromática associada à conjuntiva ocular. A etapa de reajuste para o modelo RGB representa um passo crucial para assegurar que a segmentação não comprometa as características essenciais utilizadas no método FAMACHA, garantindo, assim, a fidedignidade das análises subsequentes.

4.4 Classificadores

Os pixels das imagens foram utilizados como entrada nos classificadores, permitindo uma análise eficaz para a detecção do método FAMACHA em caprinos e ovinos.

4.4.1 Random Forest

O algoritmo *Random Forest* é uma técnica que constrói várias árvores de decisão durante o treinamento. Cada árvore contribui para a decisão final, proporcionando robustez e reduzindo o risco de *overfitting*. No contexto FAMACHA, o *Random Forest* obteve uma acurácia impressionante de 97,6% no cenário completo. O Kappa Score de 94,9% evidencia sua capacidade de lidar com a complexidade do conjunto de dados, destacando-se como o classificador mais robusto em todas as etapas.

Além disso, o *Random Forest* apresentou resultados notáveis nas métricas adicionais. O Precision, indicando a precisão das previsões positivas, manteve-se elevado em 93,1%. O Recall, representando a habilidade do modelo em encontrar todos os casos relevantes, foi de 93,2%. O F1 Score, que equilibra Precision e Recall, alcançou 93,2%, refletindo um desempenho equilibrado em todas as etapas do processamento de imagens.

4.4.2 SVM (Support Vector Machine)

O SVM é um classificador que busca encontrar o hiperplano ótimo de separação entre classes em um espaço multidimensional. No entanto, o SVM mostrou desafios significativos na tarefa de classificação FAMACHA. Sua acurácia de 62,4% no cenário completo e um Kappa Score de 9,7% indicam limitações, especialmente em termos de precisão. A sensibilidade do SVM a estruturas de dados complexas pode ter contribuído para seu desempenho menos satisfatório.

Ao explorar outras métricas, o SVM revela limitações adicionais. O Precision, indicando a precisão das previsões positivas, foi de apenas 11,3%. O Recall, representando a habilidade do modelo em encontrar todos os casos relevantes, alcançou 0,0%, indicando dificuldades em identificar corretamente os casos positivos. O F1 Score, equilibrando Pre-

cision e Recall, foi de 20,4%, refletindo um desempenho geralmente baixo nas diferentes etapas do processamento.

4.4.3 KNN (K-Nearest Neighbors)

O KNN é um algoritmo intuitivo que classifica com base na classe predominante dos vizinhos mais próximos. No contexto FAMACHA, o KNN apresentou uma acurácia sólida de 91,2% no cenário completo. Seu Kappa Score de 82,0% reflete sua capacidade de lidar eficazmente com a complexidade do problema, especialmente após a segmentação da conjuntiva ocular.

Analisando outras métricas, o KNN mantém um desempenho consistente. O Precision, indicando a precisão das previsões positivas, variou de 38,6% a 56,1%. O Recall, representando a habilidade do modelo em encontrar todos os casos relevantes, variou de 67,0% a 94,4%. O F1 Score, equilibrando Precision e Recall, variou de 54,8% a 63,9%, destacando sua habilidade em manter um equilíbrio entre as diferentes etapas do processamento de imagens.

4.4.4 Naive Bayes

O Naive Bayes é um classificador probabilístico que se baseia na independência condicional entre características. Sua simplicidade e eficiência computacional são vantajosas, mas a ingenuidade na modelagem da dependência entre características pode limitar seu desempenho. No cenário FAMACHA, o Naive Bayes alcançou uma acurácia de 68,0% e um Kappa Score de 31,2%, destacando sua adequação em situações onde a simplicidade é crucial. Após a segmentação, o Naive Bayes demonstrou sua capacidade de lidar com as características extraídas da conjuntiva ocular.

Explorando outras métricas, o Naive Bayes apresenta um desempenho moderado. O Precision, indicando a precisão das previsões positivas, variou de 35,0% a 56,0%. O Recall, representando a habilidade do modelo em encontrar todos os casos relevantes, variou de 36,5% a 65,7%. O F1 Score, equilibrando Precision e Recall, variou de 42,4% a 60,5%, destacando sua capacidade de manter um equilíbrio entre diferentes etapas do processamento de imagens.

Esses resultados detalhados fornecem uma compreensão mais aprofundada do desempenho de cada classificador, considerando múltiplas métricas em diversas etapas de processamento de imagens.

4.4.5 Métricas de avaliação

Para validar os resultados deste estudo, foram empregadas métricas essenciais, sendo elas a acurácia e o coeficiente de Cohen (Kappa).

A acurácia é uma métrica fundamental que avalia a precisão global do modelo de classificação. Ela é calculada como a razão entre o número total de previsões corretas (verdadeiros positivos e verdadeiros negativos) e o número total de exemplos. Essa definição é citada por (SILVA, 2023) em seu respectivo estudo. A fórmula para a acurácia é dada pela fórmula 4.1:

$$\text{Acurácia} = \frac{\text{Verdadeiros Positivos} + \text{Verdadeiros Negativos}}{\text{Total de Exemplos}} \quad (4.1)$$

O coeficiente Kappa é uma métrica que leva em consideração a concordância além do acaso entre as previsões do modelo e as classes reais. Ele corrige a acurácia pela chance de acerto aleatório e é especialmente útil quando há desequilíbrios nas classes. Essa definição é citada por (SANTOS, 2021) em seu respectivo estudo. O coeficiente Kappa é calculado pela fórmula 4.2:

$$\text{Kappa} = \frac{\text{Acurácia Observada} - \text{Acurácia Esperada}}{1 - \text{acurácia Esperada}} \quad (4.2)$$

Precision é uma métrica fundamental que avalia a precisão das previsões positivas do modelo. A fórmula 4.3 destaca a relação entre os verdadeiros positivos (instâncias corretamente identificadas como positivas) e o total de instâncias previstas como positivas (que incluem tanto verdadeiros positivos quanto falsos positivos). *Precision* é particularmente relevante em cenários nos quais identificar corretamente os positivos é crucial, pois mensura a confiabilidade das predições positivas, evitando a inclusão de instâncias negativas incorretamente classificadas como positivas (SILVA, 2023).

$$\text{Precision} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}} \quad (4.3)$$

O F1 Score é uma métrica que busca harmonizar *Precision* e *Recall* em uma única pontuação, proporcionando um equilíbrio entre essas duas dimensões. Ao multiplicar *Precision* e *Recall* e dividir pelo somatório de ambas, o F1 Score busca uma medida que penaliza desequilíbrios entre essas duas métricas. Isso é particularmente útil quando se lida com conjuntos de dados nos quais há uma assimetria nas classes. O F1 Score atinge seu valor máximo de 1 quando tanto *Precision* quanto *Recall* são 1, indicando um modelo que consegue tanto prever positivos corretamente quanto identificar todas as instâncias positivas. Essa definição é citada por (SILVA, 2023) em seu respectivo estudo e pode ser visto na fórmula 4.4.

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4.4)$$

Recall, também conhecido como Sensibilidade ou Taxa de Verdadeiros Positivos, é uma métrica que avalia a capacidade do modelo de identificar todas as instâncias positivas. A fórmula destaca a relação entre os verdadeiros positivos (instâncias corretamente identificadas como positivas) e o total de instâncias que são realmente positivas (a soma

de verdadeiros positivos e falsos negativos). Recall é crucial em cenários nos quais a identificação de todos os positivos é de alta importância, pois minimiza a quantidade de positivos que passam despercebidos. Essa definição é citada por (MACHADO, 2023) em seu respectivo estudo e pode ser visto na fórmula 4.5.

$$\text{Recall} = \frac{\text{Verdadeiro Positivo}}{\text{Verdadeiro Positivo} + \text{Falsos Negativos}} \quad (4.5)$$

Essas métricas são cruciais para avaliar a qualidade das previsões do modelo, proporcionando uma compreensão mais completa e robusta do desempenho do sistema de classificação.

5 Resultado Comparativo

Os testes foram conduzidos em uma máquina com uma capacidade total 16GB de memória DDR4, processador AMD Ryzen R5 5400x de arquitetura x64 de frequência base de 3.6GHz e máxima de 4.1GHz, além de uma GPU modelo GTX 1660 Super 6600 com 6GB de memória GDDR6. Todos os experimentos foram realizados em um sistema operacional da Microsoft, especificamente a edição *Windows 11 Pro*. Os testes foram conduzidos utilizando a linguagem de programação Python e foram aplicadas as seguintes bibliotecas de código aberto no desenvolvimento do método proposto: NumPy, Pandas, OpenCV-Python e Matplotlib foram aplicadas no desenvolvimento do método proposto.

Ao analisar os resultados apresentados nas tabelas abaixo, observamos o desempenho de diferentes classificadores em cenários variados de processamento de imagens para a tarefa em questão. Os classificadores considerados são Random Forest, SVM (Support Vector Machine), KNN (K-Nearest Neighbors) e Naive Bayes.

Tabela 2 – Todas as métricas sem as etapas de segmentação

Método	Random Forest	SVM	KNN	Naive Bayes
Acurácia	90.40	62.40	91.20	68.00
Kappa	79.40	0.00	82.00	31.20
Precisão	93.10	11.30	38.60	52.20
F1 Score	93.20	20.40	54.80	47.90
Recall	67.00	100.00	83.30	53.80

A aplicação dos classificadores sem a etapa de segmentação, revela que o *Random Forest* se destaca, alcançando a maior acurácia 90,4% em comparação com os outros métodos. O KNN também apresenta um desempenho robusto, atingindo uma acurácia de 91,2%. No entanto, o SVM enfrenta dificuldades, registrando a menor acurácia 62,4%, sugerindo limitações nesse contexto.

Ao avaliar outras métricas, como kappa, precision, F1 Score e recall, o Random Forest continua demonstrando um desempenho impressionante, mantendo um equilíbrio notável entre precisão e recall.

Para garantir a validade dos resultados, 70% das imagens foram utilizadas para treinamento dos modelos, enquanto os 30% restantes foram reservados para teste. Essa abordagem padrão permite uma avaliação robusta da capacidade de generalização dos algoritmos desenvolvidos, minimizando o risco de sobreajuste aos dados de treinamento.

Na ausência da etapa de Macenko, os resultados indicam que o *Random Forest* mantém sua posição como o classificador mais eficaz, com a maior acurácia 95,2% e kappa 89,3%. O SVM, mais uma vez, apresenta desafios, destacando-se pela menor acurácia 65,6% e baixo kappa 9,1%.

Tabela 3 – Todos as métricas sem a etapa de Macenko

Método	Random Forest	SVM	KNN	Naive Bayes
Acurácia	95.20	65.60	92.00	67.20
Kappa	89.30	9.10	83.10	22.00
Precisão	85.30	19.50	56.10	56.10
F1 Score	92.10	29.10	63.90	60.50
Recall	100.00	57.10	74.20	65.70

O *Random Forest* exibe consistência ao manter altos valores de precision, F1 Score e recall, destacando sua robustez em diversas métricas. Por outro lado, o SVM enfrenta limitações, refletidas em valores mais baixos nessas métricas.

Tabela 4 – Todos as métricas sem a etapa de Sharpening

Método	Random Forest	SVM	KNN	Naive Bayes
Acurácia	92.80	63.20	81.60	49.60
Kappa	84.30	0.00	62.30	0.14
Precisão	68.30	0.00	23.20	53.40
F1 Score	57.40	0.00	34.50	43.40
Recall	58.60	0.00	66.70	36.50

A exclusão da etapa de *sharpening* resulta em um desempenho notável do *Random Forest*, que mantém a maior acurácia 92,% e kappa 84,3%. Mais uma vez, o SVM enfrenta desafios significativos, registrando 0,0% em kappa e apresentando a menor acurácia 63,2%.

O *Random Forest* destaca-se pela capacidade de manter uma precisão notável, mesmo sem a aplicação de *sharpening*, enquanto o SVM e o KNN registram valores mais baixos nessas métricas.

Tabela 5 – Com todas as etapas

Método	Random Forest	SVM	KNN	Naive Bayes
Acurácia	97.60	62.40	91.20	68.00
Kappa	94.90	9.70	82.00	31.20
Precisão	93.10	11.30	38.60	52.20
F1 Score	93.20	20.40	54.80	47.90
Recall	93.20	100.00	83.30	44.20

Considerando todas as etapas de processamento, o *Random Forest* continua a ser o classificador mais eficiente, alcançando uma acurácia de 97,6% e um kappa de 94,9%. O SVM, no entanto, mantém um desempenho desafiador, evidenciado por sua menor acurácia 62,4% e kappa 9,7%.

A análise abrangente das métricas, incluindo *recision*, F1 Score e *recall*, reforça a superioridade do *Random Forest*, que mantém um equilíbrio notável entre a precisão das predições positivas, a capacidade de encontrar casos relevantes e a harmonia geral entre precision e recall.

Ao examinar os resultados nas tabelas, fica evidente que o *Random Forest* sobressaiu de maneira significativa em comparação aos demais, especialmente quando a segmentação e as técnicas de normalização de cores foram aplicadas. Estas estratégias resultaram em melhorias substanciais nos resultados. Tanto o *Random Forest* quanto o KNN exibiram desempenho consistente em diversas etapas de processamento de imagens. Por outro lado, o SVM e o Naive Bayes enfrentaram limitações em certas condições de processamento, ressaltando a importância de uma escolha cuidadosa do classificador, alinhada às características específicas do conjunto de dados e à natureza da tarefa em questão. Em síntese, a decisão sobre o classificador ideal deve considerar a complexidade do processamento de imagens e as exigências particulares do problema em foco.

6 Conclusão

Este estudo abordou uma extensa gama de técnicas com o propósito de alcançar eficiência computacional no contexto da identificação de níveis de Famacha em caprinos e ovinos. Diversas arquiteturas pré-treinadas, como VGG-16, VGG-19 e Xception, foram inicialmente consideradas, mas restrições de custo computacional, bem como o conjunto de dados de tamanho reduzido levaram à sua exclusão. O desafio crítico de superar limitações na quantidade inicial de imagens coletadas, totalizando apenas 89 amostras, foi enfrentado e vencido na fase de pré-processamento, elevando esse número para 267 e contribuindo substancialmente para aprimorar os resultados.

A segmentação de imagens desempenhou um papel crucial no processo, envolvendo a aplicação da técnica de binarização para simplificar a extração de características relevantes. A conversão para formatos de pixels preto e branco facilitou a identificação das áreas de interesse, tornando o processo de classificação mais eficaz. Posteriormente, as imagens foram revertidas ao formato original, preservando apenas as partes essenciais para a classificação.

A análise aprofundada dos resultados destacou o alto desempenho do Random Forest, especialmente quando beneficiado pela aplicação da segmentação e técnicas de normalização de cores. A segmentação foi crucial ao remover regiões indesejadas, como pelos ao redor dos olhos, enquanto a normalização contribuiu para mitigar variações na iluminação. Essas estratégias impulsionaram significativamente a eficácia do modelo. Em contraste, o SVM enfrentou desafios específicos. A inclusão de métricas como precision, F1 score e recall enriqueceu a avaliação do modelo, proporcionando uma compreensão mais detalhada de seu desempenho em diversos cenários de processamento de imagens.

Portanto, este estudo não apenas contribui para o entendimento aprofundado do método Famacha, mas também oferece uma abordagem prática e eficiente, integrando conhecimentos clínicos, processamento de imagens e técnicas de aprendizado de máquina. A combinação de estratégias abrangentes dessas áreas forma uma base sólida para a gestão eficaz da saúde em rebanhos de caprinos e ovinos, com implicações práticas significativas para profissionais e pesquisadores interessados na implementação de tecnologias inovadoras na área de saúde animal.

Para projetos futuros, é recomendado explorar técnicas avançadas de aprendizado de máquina, como redes neurais convolucionais (CNNs) e outros algoritmos de aprendizado profundo, visando aprimorar a precisão e a eficácia dos modelos de classificação. Além disso, ampliar o tamanho e a diversidade do conjunto de dados pode fortalecer a generalização e a robustez do modelo. A coleta de amostras de diferentes origens geográficas e condições ambientais pode enriquecer a análise e proporcionar uma visão mais abrangente do sistema.

Referências

- COSTA, C. V. V. et al. Identificação dos graus famacha[©] em caprinos e ovinos do município de tauá, estado do ceará. In: IN: ENCONTRO DE INICIAÇÃO CIENTÍFICA DA EMBRAPA CAPRINOS E OVINOS, 7., 2018 *Embrapa Caprinos e Ovinos-Resumo em anais de congresso (ALICE)*. [S.l.], 2018. Citado na página 14.
- DEMOLINER, G.; ALVES, R. J. F. Anemimetro: app móvel para implementação do método famacha. *Unoesc & Ciência-ACET*, v. 8, n. 1, p. 25–32, 2017. Citado 3 vezes nas páginas 18, 22 e 23.
- 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 14.
- FERREIRA, B. B. Práticas extensionistas na agroecologia para agropecuária. Universidade Federal de Campina Grande, 2023. Citado na página 17.
- GARCÍA, R. F. tónico, es en la que obtenemos la mejor deteccion de bordes de nuestro estímulo (figura 6). • el tiempo de detección de bordes del estímulo se reduce a medida que el potencial de membrana de las células de relevo e interneuronas es más tónico. • cuando las células de relevo e interneuronas se comportan simultaneamente en modo. *MODELO DINÁMICO DE LA CIRCUITERÍA PUSH PULL DEL dNGL*, p. 21, 2017. Citado na página 20.
- GONÇALVES, N. C. Uso de visão computacional para classificação de frutos de acerola em imagens rgb. 2021. Citado na página 17.
- JANUÁRIO, L. A. d. F. *Optimization of resistance to gastrointestinal nematodes in Santa Inês sheep: a genomic selection, machine learning and image analysis approach*. Tese (Doutorado) — Universidade de São Paulo, 2023. Citado 2 vezes nas páginas 23 e 24.
- JUNIOR, J. R. D. R. Estudo de deep fine tuning aplicado à classificação de imagens histológicas. UFMA, 2023. Citado na página 19.
- LEAL, T. M.; HASSUM, I. C. Algumas considerações sobre a verminose em pequenos ruminantes. 2021. Citado na página 16.
- MACENKO, M. et al. A method for normalizing histology slides for quantitative analysis. In: IEEE. *2009 IEEE international symposium on biomedical imaging: from nano to macro*. [S.l.], 2009. p. 1107–1110. Citado na página 19.
- MACHADO, T. V. Aplicação de técnicas de visão computacional para identificação de ferrugem em folhas de café. Universidade Federal de Uberlândia, 2023. Citado na página 32.
- MINHO, A.; MOLENTO, M. Método famacha: uma técnica para prevenir o aparecimento da resistência parasitária. Bagé: Embrapa Pecuária Sul, 2014., 2014. Citado na página 17.

- MONTOUT, A. X. et al. Accurate and interpretable prediction of poor health in small ruminants with accelerometers and machine learning. *bioRxiv*, Cold Spring Harbor Laboratory, p. 2020–08, 2020. Citado 2 vezes nas páginas 22 e 23.
- NA, S. D. P. G. Sistema famacha© em ovelhas da raça morada nova 41. *JOSIEL BORGES FERREIRA*, Universidade Federal Rural do Semiárido, p. 18, 2021. Citado na página 14.
- NASCIMENTO, L. T.; TEIXEIRA, M. Processamento digital de imagens da mucosa ocular de ovinos para determinação do grau de anemia durante a infecção por *haemonchus contortus*. In: IN: ENCONTRO DE INICIAÇÃO CIENTÍFICA DA EMBRAPA CAPRINOS E OVINOS, 9., 2020 *Embrapa Caprinos e Ovinos-Resumo em anais de congresso (ALICE)*. [S.l.], 2021. Citado 3 vezes nas páginas 22, 23 e 24.
- NIÑO, C. et al. Comparativa entre la técnica de umbralización binaria y el método de otsu para la detección de personas. *Revista UIS ingenierías*, Revista UIS Ingenierías, v. 20, n. 2 (2021), p. 65–74, 2021. Citado na página 20.
- RIBEIRO, W. F. Uma metodologia para detectar anemia em pequenos ruminantes. Universidade Federal do Maranhão, 2018. Citado 3 vezes nas páginas 19, 22 e 23.
- SANTOS, E. F. dos. *Avaliação da cobertura de gordura de novilhas e vacas usando visão computacional*. Tese (Doutorado) — Universidade Federal de Mato Grosso, 2021. Citado na página 31.
- SILVA, K. P. d. Análise de aplicação de visão computacional e redes neurais, em conjunto com o uso de técnicas de aumento de dados, na tradução automática de libras. 2023. Citado na página 31.
- SOUZA, L. F. de et al. Sistema para classificação de infestação parasitária em pequenos ruminantes. 2021. Citado 4 vezes nas páginas 16, 18, 22 e 23.
- TOROK, L. Método de otsu. *Instituto de Computação (UFF)*, 2016. Citado na página 20.
- VIEIRA, L. d. S. Métodos alternativos de controle de nematóides gastrintestinais em caprinos e ovinos. *Tecnologia & Ciência Agropecuária*, João Pessoa, v. 2, n. 2, p. 49-56, jun. 2008., 2008. Citado 2 vezes nas páginas 8 e 17.



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

Identificação do Tipo de Documento

- Tese
 Dissertação
 Monografia
 Artigo

Eu, **Artur Hildegardo de Moura Silva**, 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 **Criação de um algoritmo de baixo custo computacional para a detecção do grau FAMACHA em caprinos e ovinos**, 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 Fevereiro de 2024.


Assinatura