



UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL
UNIDADE UNIVERSITÁRIA DE AQUIDAUANA PROGRAMA DE
PÓS-GRADUAÇÃO EM ZOOTECNIA

**RECONHECIMENTO FACIAL DE BOVINOS DA
RAÇA NELORE POR MEIO DE VISÃO
COMPUTACIONAL**

Acadêmico: Pietro Navarro R Claire

Orientadora: Dra. Vanessa Aparecida de
Moraes Weber

Co-Orientador: Prof. Dr. Urbano Gomes
Pinto de Abreu

Aquidauana-MS

2023

RECONHECIMENTO FACIAL DE BOVINOS DA RAÇA NELORE POR MEIO DE VISÃO COMPUTACIONAL

Acadêmico: Pietro Navarro R. Claire

Orientadora: Dra. Vanessa Aparecida de
Moraes Weber

Co-Orientador: Prof. Dr. Urbano Gomes
Pinto de Abreu

Dissertação apresentada ao Programa de Pós-graduação em Zootecnia,
área de concentração em Produção Animal no Cerrado-Pantanal, da
Universidade Estadual de Mato Grosso do Sul, como parte das exigências para
a obtenção do título de Mestre em Zootecnia

Aquidauana-MS

2023

C553r Claire, Pietro Navarro Rodrigues

Reconhecimento facial de bovinos da raça Nelore por meio de visão computacional / Pietro Navarro Rodrigues Claire. – Aquidauana, MS: UEMS, 2023. 36 f.

Dissertação (Mestrado) – Zootecnia – Universidade Estadual de Mato Grosso do Sul, 2024.

Orientadora: Profa. Dra. Vanessa Aparecida de Moraes Weber.

1. Inteligência artificial 2. Aprendizado de máquina 3. Nelore 4. Reconhecimento facial 5. Pecuária de precisão I. Weber, Vanessa Aparecida de Moraes II. Título

CDD 23. ed. - 636.2

**UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
UNIDADE UNIVERSITÁRIA DE AQUIDAUANA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA
ÁREA DE CONCENTRAÇÃO EM PRODUÇÃO ANIMAL**

PIETRO NAVARRO RODRIGUES CLAURE

Dissertação submetida ao Programa de Pós-Graduação em Zootecnia, área de concentração em Produção Animal, como requisito para obtenção do grau de Mestre em Zootecnia.

DISSERTAÇÃO APROVADA EM 20/11/2023.

Documento assinado digitalmente
 **VANESSA APARECIDA DE MORAES WEBER**
Data: 18/04/2024 10:41:12-0300
Verifique em <https://validar.iti.gov.br>

Dra. Vanessa Aparecida de Moraes Weber (Orientadora)

Documento assinado digitalmente
 **ANDRE ROZEMBERG PEIXOTO SIMOES**
Data: 18/04/2024 11:57:19-0300
Verifique em <https://validar.iti.gov.br>

(participação via videoconferência)
Dr. Andre Rozemberg Peixoto Simões, UEMS

Documento assinado digitalmente
 **ALEXANDRE DE OLIVEIRA BEZERRA**
Data: 18/04/2024 11:46:24-0300
Verifique em <https://validar.iti.gov.br>

Dr. Alexandre de Oliveira Bezerra, UCDB

DEDICATÓRIA

Dedico este trabalho aos familiares e amigos, que contribuíram com palavras de motivação e foram compreensivos com os momentos de ausência. Essa vitória também é de vocês.

AGRADECIMENTOS

Neste momento tão especial, claro que gostaria de agradecer aos amigos e orientadores Prof. Dra. Vanessa e Prof. Dr. Urbano, por acreditarem em mim como seu orientando e por me acompanharem neste caminho árduo.

Claro que não posso esquecer da minha família e minha esposa Renata que por muitas vezes teve que assumir a responsabilidade da casa enquanto eu me dirigia para Aquidauana para fazer as aulas e me reunir com os professores.

Agradeço também aos meus coordenadores da G4F que entenderam as ausências e compreenderam minha dedicação a este mestrado.

E não poderia deixar de agradecer aos meus colegas da Mais Code Tecnologia, que tiveram que assumir mais funções enquanto eu me ausentar para realizar este estudo de pesquisa, dentre eles quero destacar a Amizade de Marcus, Inara e Thaynara, que acreditaram em mim.

E por fim a meus pais que indiretamente sempre me deram força para enfrentar novos desafios.

Meus sinceros agradecimentos.

LISTA DE TABELAS

Tabela 1- Métricas de algoritmos de aprendizagem de máquina, demonstrando métricas diferenciais entre eles.	16
--	----

LISTA DE FIGURAS

Figura 1 - Exemplo da segmentação das faces dos animais.	12
Figura 2 - Workflow da extração de embedding da Inception e teste de algoritmos de aprendizado de máquina.	13
Figura 3 - Matriz de confusão gerada por SVM.	17
Figura 4 - Matriz de confusão gerada por KNN.	17
Figura 5 - matriz de confusão gerada por Árvore de decisão.	18
Figura 6 - Classificação incorreta do SVM.	19
Figura 7 - Classificação incorretas do KNN.	19
Figura 8 - Classificação incorretas do TREE.	20

SUMÁRIO

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS.....	2
<u>1.1</u> Introdução	2
<u>1.2</u> Revisão da Literatura	4
REFERÊNCIAS	6
CAPÍTULO 2 – RECONHECIMENTO FACIAL DE BOVINOS DA RAÇA NELORE POR MEIO DE VISÃO COMPUTACIONAL - RBZ	8
<u>Resumo</u>	8
<u>Abstract.....</u>	9
<u>1-Introdução.....</u>	10
<u>2-Materiais e métodos.....</u>	11
<u>2.1 Segmentação</u>	12
<u>2.2 Embedding</u>	13
<u>2.3 Aprendizado de Máquina e métricas</u>	14
<u>3- Resultados</u>	16
<u>4- Discussões</u>	20
<u>5- Conclusão</u>	21
<u>6 - REFERÊNCIAS.....</u>	22
CAPÍTULO 3 – Considerações Finais	26

RESUMO

Os benefícios do Reconhecimento Facial de bovinos incluem a redução do trabalho manual e estresse nos animais, otimização do monitoramento de saúde e bem-estar, rastreamento de histórico individual para tomada de decisões, e até mesmo a seleção precisa para programas de melhoramento genético. O objetivo geral deste estudo é investigar a possibilidade de reconhecer bovinos da raça Nelore por meio de imagens de sua face. Os objetivos específicos constituem a construção de um banco de imagens contendo as faces dos bovinos Nelore juntamente com as anotações de identificação de cada indivíduo e de segmentação da face; Segmentação de face de Nelore no banco de imagens gerado; extração de característica de imagens segmentadas; Análise de algoritmos de aprendizado de máquina, experimento com extração automática via aprendizado profundo. Essas técnicas foram adaptadas e ajustadas para o contexto particular dos bovinos da raça Nelore. Com uma acurácia de 0,999 o algoritmo SVM demonstra que o uso de aprendizado de máquina aplicado a embedding extraídas com Inception de um conjunto de dados previamente segmentado, é um método eficiente para o reconhecimento de bovinos da raça Nelore por imagens de suas faces.

Palavras-chave: Aprendizado de máquina, Inteligência artificial, Nelore, Pecuária de precisão, Reconhecimento facial.

ABSTRACT

The benefits of bovine Facial Recognition include the reduction of manual labor and stress on animals, optimization of health and well-being monitoring, tracking of individual histories for decision-making, and even precise selection for genetic improvement programs. The general objective of this study is to investigate the feasibility of recognizing Nelore cattle through images of their faces. The specific objectives consist of building an image database containing the faces of Nelore cattle along with identification annotations for each individual and face segmentation; Nelore face segmentation in the generated image database; feature extraction from segmented images; Machine learning algorithm analysis, and experimentation with automatic extraction via deep learning. These techniques were adapted and adjusted for the specific context of Nelore cattle. With an accuracy of 0.999, the SVM algorithm demonstrates that the use of machine learning applied to embeddings extracted with Inception from a previously segmented dataset can be a relevant methodology for the recognition of Nelore cattle through images of their faces.

Keywords: Artificial Intelligence, Facial Recognition, Livestock Precision, Machine Learning, Nelore.

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS

1.1 Introdução

Segundo a Food Agriculture Organization of the United Nation (FAO), cerca de 1,3 bilhão de pessoas tem suas vidas sustentadas pela produção animal, e essas proteínas constituem parte fundamental de dietas saudáveis para pessoas em todo o mundo. Em 2022, o número de pessoas que enfrentavam a fome no mundo era estimado entre 691 e 783 milhões. A insegurança alimentar atinge, hoje, 900 milhões de pessoas globalmente. Até 2050, como o crescimento populacional teremos 2 bilhões de habitantes a mais no mundo, especialmente em países em desenvolvimento. (ABIEC cap 6, 2023)

Nesse sentido, a produção de bovinos no Brasil é relevante para o subsídio de proteínas, tanto no mercado nacional como mundial e para a economia deste país. No relatório anual da ABIEC, em 2018, a pecuária brasileira foi responsável por uma geração de riquezas de R\$ 597,22 bilhões, representando um crescimento de 8,3% em relação a 2017. Ainda segundo o mesmo relatório, o movimento do agronegócio da pecuária de corte, em 2018, gastou com insumos e serviços para produção, o montante de R\$66,17 bilhões e um faturamento total na pecuária de R\$104 bilhões (ABIEC, 2019).

Os dados do Ministério da Agricultura, Pecuária e Abastecimento, que apontou que o PIB do agronegócio foi responsável por 26,6% do Produto Interno Bruto (PIB) em 2020, sendo de 2,0% o crescimento do PIB da agropecuária, que engloba toda a cadeia produtiva (insumos, agropecuária, indústria e serviços). Por conta disso, as projeções de crescimento para esse mercado são animadoras. Já o Departamento de Agricultura dos Estados Unidos (USDA, 2020) projeta acréscimo de 4,0% de aumento das exportações de carne bovina e classifica o Brasil, até 2029, como primeiro exportador de carne bovina, com 28,7% das exportações totais.

A atividade da pecuária é de importância para economia de muitos estados brasileiros. Em comparação entre 2019 com 2018, houve um crescimento de 0,4% no rebanho de bovinos brasileiro (PPM-2019, IBGE, 2019). Esse cenário de aumento de produção vem colocando o Brasil entre os 4 maiores produtores do mundo de gado de corte. Ainda segundo o IBGE, o Brasil

em 2020 possuía 216,9 milhões de bonivos, sendo que dessas, foram abatidos 32,4 milhões. O Mato Grosso (17,4%), Mato Grosso do Sul (11,1%), Goiás (9,3%), São Paulo (10,3%), Minas Gerais (8,8), Pará (7,4%), Rondônia (7,4%) e Rio Grande do Sul (6,1%), lideram os abates, com 77,6% dos abates no país (CONAB, 2020)

Nos últimos dez anos, considerando os maiores produtores de carne bovina do mundo, foi justamente no Brasil onde a produção mais cresceu – aumento de 1,7 milhão de toneladas neste período. Estados Unidos ficaram em segundo, com aumento de 1,05 milhão de TEC na sua produção de carne no mesmo período. Mas é nas exportações que o Brasil mais se destaca. É o maior exportador de carne bovina do mundo, com 27,7 % das exportações mundiais em 2022. (ABEIC cap. 3, 2023).

Considerando esse cenário de expansão e valorização do agronegócio, investir em tecnologias para controle e rastreio de bovinos, atendendo aos critérios internacionais de exportação, expandindo o mercado e aquecendo a economia desse setor, trará aumento no lucro e a redução de perdas na produção e desenvolvimento desse animal.

Sendo assim, a análise dos dados supracitados é relevante para entender a importância de desenvolver um método baseado em visão computacional com o intuito de identificar individualmente os bovinos. O intuito da identificação individual é viabilizar o rastreamento e o registro do histórico de dados referente ao manejo sanitário de cada animal, desde seu nascimento até o abate, e conseqüentemente, atender às exigências de rastreabilidade exigida por mercados importadores, assim como, atender nichos de mercados mais exigentes que estão preocupados com a certificação de origem da carne bovina.

Assim objetivou-se investigar a viabilidade de desenvolver um modelo baseado em visão computacional para identificar bovinos da raça Nelore pela imagem da sua face.

Os objetivos específicos foram: criar um banco de imagens da face de bovinos da raça Nelore e aplicar as principais técnicas de identificação de indivíduos, por meio de visão computacional e aprendizado de máquina.

1.2 Revisão da Literatura

A revisão da literatura nesta pesquisa aborda diversos aspectos relacionados à reconhecimento de plantas, identificação e rastreamento de bovinos e ovinos, destacando a importância do uso de tecnologias avançadas, como visão computacional e aprendizado de máquina, para aprimorar a gestão de rebanhos. Além disso, explora as aplicações dessas tecnologias em contextos pecuários e ressalta a relevância da rastreabilidade para atender às exigências de mercados internacionais e garantir a qualidade da carne bovina.

O estudo de Bambil et al., (2020), se concentra na identificação de espécies de plantas usando visão computacional e aprendizado de máquina. Os resultados mostraram que a visão computacional foi eficiente na identificação de espécies, com uma taxa de precisão superior a 93%. Além disso, algoritmos como SVM, floresta aleatória e aprendizado profundo superaram o desempenho do AdaBoost. O modelo SVM assim como este trabalho foi o modelo que obteve melhor resultado.

Quanto ao estudo de Bateni et al., (2020), o mesmo concentra-se na classificação visual com poucas amostras. Eles desenvolveram uma nova arquitetura chamada "Simple CNAPS" que teve um desempenho superior ao estado da arte em conjuntos de dados de classificação de imagens com poucas amostras. Isso é importante porque demonstra que é possível obter resultados significativamente melhores com menos parâmetros, o que pode ter implicações na eficiência do treinamento de modelos de aprendizado profundo.

Buller et al., (2018) discutem políticas de bem-estar animal e sua sustentabilidade, argumentando que tais políticas podem provocar mudanças significativas na compreensão e resposta ao bem-estar dos animais. Embora o estudo não apresente resultados experimentais, destaca a importância desse debate e oferece recomendações para políticas sustentáveis de bem-estar animal.

Gong et al., (2022) concentram-se no reconhecimento facial de bovinos e introduzem um modelo baseado em SK-ResNet que atingiu taxas de precisão excepcionalmente altas. Isso é crucial para a aplicação prática da tecnologia de reconhecimento facial de animais na criação de gado, melhorando o monitoramento e a gestão do gado.

Li et al., (2022) apresentam um modelo leve para o reconhecimento facial de bovinos com alta precisão. Além disso, eles demonstram a viabilidade do modelo ao transplantá-lo para um dispositivo Raspberry Pi, reduzindo o custo computacional. Isso tem implicações práticas para a implementação de sistemas de reconhecimento facial em fazendas de gado.

Santos (2017) concentra-se no reconhecimento de marcas de gado usando redes neurais convolucionais e máquinas de vetores de suporte. Os resultados mostraram que o método CNN superou o método Bag-of-Features em precisão e velocidade, sendo relevante para a identificação e rastreamento de gado, melhorando a gestão do rebanho.

Bakhshayeshi, Ivan et al., (2023) demonstrou que a capacidade de treinamento da IA pode não depender somente da quantidade de fotos, coletadas no período de implantação, mas evidencia um bom uso dos algoritmos utilizados nesse trabalho, como os da família YOLO, para identificar e recortar a imagem em tempo real, obtendo os resultados de que com apenas 20 imagens por bovino o modelo atinge 95,13% de precisão.

Em resumo, esses estudos demonstram a eficácia de técnicas de visão computacional, aprendizado de máquina e redes neurais em várias aplicações, desde a identificação de espécies de plantas até o reconhecimento facial de animais e a análise fenotípica de raças de gado. Além disso, ressaltam a importância da sustentabilidade e do bem-estar animal nas práticas agrícolas modernas.

Em resumo, esses estudos demonstram a eficácia de técnicas de visão computacional, aprendizado de máquina e redes neurais em várias aplicações, desde a identificação de espécies de plantas até o reconhecimento facial de animais e a análise fenotípica de raças de gado. Além disso, ressaltam a importância da sustentabilidade e do bem-estar animal nas práticas agrícolas modernas.

REFERÊNCIAS

ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne (<https://abiec.com.br/wp-content/uploads/sumario2019portugues.pdf>)

ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne – BEEF Report 2023 – Capitulo 6 (https://www.abiec.com.br/publicacoes/beef-report-2023-capitulo-06-sustentabilidade/#dfliip-df_5621/7/)

ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne – BEEF Report 2023 – Capitulo 3(https://www.abiec.com.br/publicacoes/beef-report-2023-capitulo-03/#dfliip-df_5402/3/)

BAMBIL, Deborah et al. Plant species identification using color learning resources, shape, texture, through machine learning and artificial neural network. **Environment Systems and Decisions**, v. 40, n. 4, p. 480-484, 2020.

BATENI, P., GOYAL, R., MASRANI, V., WOOD, F., AND SIGAL, L. **Improved few-shot visual classification**. Conference on Computer Vision and Pattern Recognition (CVPR), 2020. Disponível em: <https://bibbase.org/network/publication/bateni-goyal-masrani-wood-sigal-improvedfewshotvisualclassification-2020>. Acesso em: 03 de ago. 2023.

BULLER, H.; BLOKHUIS, H.; JENSEN, P.; KEELING, L. Towards Farm Animal Welfare and Sustainability. **Animals** 2018, 8, 81. Disponível em: <https://www.mdpi.com/2076-2615/8/6/81>. Acesso em: 22 de abr. 2023.

GONG, He et al. Facial Recognition of Cattle Based on SK-ResNet. **Scientific Programming**, [S.l.], v. 2022, p. 5773721, 2022. Disponível em: <https://doi.org/10.1155/2022/5773721>. Acesso em: 10 de mai. 2023.

KIM, J., KIM, T., KIM, S., AND YOO, C. D. **Edge-labeling graph neural network for few-shot learning**. In CVPR, 2019.

LI, Zheng; LEI, Xuemei; LIU, Shuang. A lightweight deep learning model for cattle face recognition. **Computers and Electronics in Agriculture**, v. 195,

p. 106848, 2022. ISSN 0168-1699. Disponível em: <https://doi.org/10.1016/j.compag.2022.106848>. Acesso em: 01 de jun. 2023.

SANTOS, Carlos Alexandre Silva dos. **Reconhecimento de imagens de marcas de gado utilizando redes neurais convolucionais e máquinas de vetores de suporte**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Pampa, Alegrete, 2017.

Bakhshayeshi, Ivan & Erfani, Eila & Taghikhah, Firouzeh & Elbourn, Stephan & Beheshti, Amin & Asadnia, Mohsen. (2023). **An Intelligence Cattle Re-Identification System over Transport by Siamese Neural Networks and YOLO**. IEEE Internet of Things Journal. PP. 1-1. 10.1109/JIOT.2023.3294944.

WEBER, Fabricio de Lima. **SISTEMA PARA RECONHECIMENTO DE BOVINOS DA RAÇA PANTANEIRA BASEADO EM REDE NEURAL CONVOLUCIONAL**. Dissertação (Mestrado em Zootecnia) - Universidade Estadual de Mato Grosso do Sul, Aquidauana, 2020.

CAPÍTULO 2 – RECONHECIMENTO FACIAL DE BOVINOS DA RAÇA NELORE POR MEIO DE VISÃO COMPUTACIONAL - RBZ

Pietro Navarro Rodrigues Claire¹, Andre Rozemberg Peixoto Simões², Alexandre de Oliveira Bezerra³, Urbano Gomes Pinto de Abreu⁴, Vanessa Aparecida de Moraes Weber⁵

Resumo

Este artigo tem como objetivo desenvolver um modelo para o reconhecimento de bovinos da raça Nelore com base em imagens de seus rostos. O experimento emprega uma metodologia que envolve a criação de um banco de dados de imagens contendo 2.210 imagens de 47 bovinos Nelore, juntamente com anotações de identificação para cada animal e informações de segmentação facial usando a rede YoloV8. Para realizar o reconhecimento, o artigo utiliza extração de características por meio de embeddings com a rede Inception. Por fim, é realizada uma análise dos seguintes algoritmos de aprendizado de máquina: K-Nearest Neighbors (KNN), Support Vector Machine (SVM) e Decision Tree (TREE), com valores de precisão de 0,952, 0,987 e 0,635, respectivamente. Esta pesquisa é significativa no campo da zootecnia, pois propõe uma abordagem inovadora para o reconhecimento de bovinos Nelore usando tecnologias de visão computacional e aprendizado de máquina, contribuindo para um monitoramento e gerenciamento mais eficientes e precisos desses animais.

Keywords: Aprendizado de Máquina , Inteligência Artificial, Nelore, Precisão em Pecuária, Reconhecimento Facial.

¹ Programa de Pós-Graduação em Zootecnia, Universidade Estadual de Mato Grosso do Sul, Unidade Universitária de Aquidauana. 503 Rodovia Aquidauana-UEMS Km 12, Cx Postal 25- CEP 79200-000, Aquidauana- MS, Brazil.

² Universidade Estadual de Mato Grosso do Sul(UEMS), Unidade Universitária de Aquidauana, Aquidauana- MS, Brazil.

³ Universidade Católica Dom Bosco (UCDB) , Campo Grande-MS, Brazil.

⁴ Empresa Brasileira de Pesquisa Agropecuária, Embrapa Pantanal, Corumbá - MS, Brasil.

⁵ Kerow Soluções de precisão.

Abstract

This paper goal to develop a model for the recognition of Nelore cattle based on images of their faces. The experiment employs a methodology that involves the creation of an image database containing 2,210 images of 47 Nelore cattle, along with identification annotations for each animal and face segmentation information using the YoloV8 network. To perform recognition, the article utilizes feature extraction through embeddings with the Inception network. Finally, an analysis is conducted on the following machine learning algorithms: K-Nearest Neighbors (KNN), Support Vector Machine (SVM), and Decision Tree (TREE), with precision values of 0.952, 0.987, and 0.635, respectively. This research holds significance in the field of zootechnics, as it proposes an innovative approach to the recognition of Nelore cattle using computer vision and machine learning technologies, contributing to more efficient and precise monitoring and management of these animals.

Keywords: Artificial Intelligence, Facial Recognition, Livestock Precision, Machine Learning, Nelore.

1-Introdução

A exploração da atividade de pecuária de corte no Brasil é essencialmente baseada em bovinos da raça Nelore devido as suas características de adaptação às condições tropicais do país (ABIEC 2020). A gestão eficiente dos rebanhos, abrangendo desde o monitoramento individual até o controle de doenças e o melhoramento genético, é essencial para o sucesso dessa atividade. Nesse contexto, a identificação individual de bovinos Nelore é uma premissa da pecuária de precisão (WEBER et al., 2020). O reconhecimento de bovinos por meio de imagens de suas faces surge como uma solução inovadora, possibilitando o acompanhamento individualizado e o registro preciso das informações de cada animal.

Essa pesquisa propõe uma abordagem metodológica que combina tecnologias de visão computacional, aprendizado profundo para extração de características e aprendizado de máquina para classificação. A automação do processo de reconhecimento facial de bovinos Nelore pode trazer melhorias na gestão dos rebanhos na sua rastreabilidade e no processo de fiscalização para garantia da qualidade. Além disso, a identificação e rastreabilidade dos animais, está alinhada às exigências de mercados importadores e nichos que valorizam a certificação de origem da carne bovina.

O tema tem sido abordado por vários grupos de pesquisa (Gong et al., 2022 ; Santos,2017). O que revela a crescente importância das tecnologias de visão computacional, aprendizado de máquina e redes neurais nessas aplicações. Além disso, esses estudos destacam a relevância da sustentabilidade e do bem-estar animal nas práticas da pecuária modernas.

Apesar da dificuldade de aquisição de imagens de face na lida, essa é uma alternativa que pode ser empregada em situações específicas como animais de exposição e fiscalização ou o uso da tecnologia embarcada em equipamentos de manejo como bebedouros, comedouros, tronco e balanças.

Em resumo, este experimento representa uma contribuição para o setor agropecuário, fornecendo uma proposta de solução inovadora para o

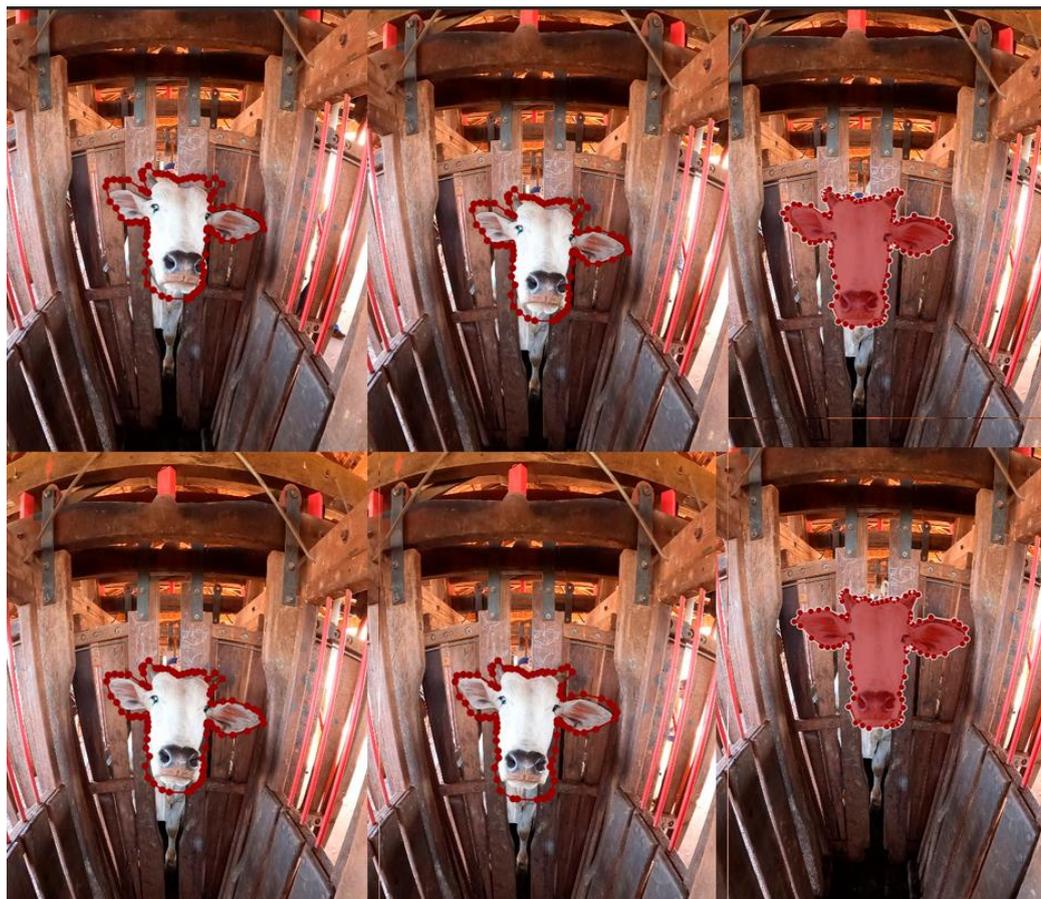
rastreamento e identificação individual de bovinos da raça Nelore. Com o potencial de aprimorar a gestão de rebanhos, otimizar o monitoramento dos animais e atender às exigências de mercados internacionais, essa pesquisa demonstra como a integração de tecnologias avançadas pode impulsionar o desenvolvimento sustentável da pecuária.

2-Materiais e métodos

A coleta de imagens das faces de bovinos da raça Nelore foi realizada no município de Campo Grande, no estado do Mato Grosso do Sul. Nas instalações da Embrapa Gado de Corte - CNPGC, foram filmadas as faces de 47 animais da raça Nelore por uma câmera GoPro5 fixada num tripé na lateral do tronco de contenção e pesagem. Foram filmados 20 bezerros e 27 fêmeas e obtidas aproximadamente 200 horas de vídeos das quais foram extraídos 2.210 frames para análise.

A segmentação das imagens foi feita utilizando o software Label-me e apenas a porção da face dos animais foi marcada (Figura 3).

Figura 1 - Exemplo da segmentação das faces dos animais.



Fonte: autor (2023).

2.1 Segmentação

A segmentação automática das imagens foi realizada por modelos pré-treinados da arquitetura YOLOv8, desenvolvidos e disponibilizados pela Ultralytics. Os modelos YOLOv8 pré-treinados têm sua base de aprendizado no conjunto de dados COCO (Common Objects in Context), abrangendo uma coleção de mais de 330.000 imagens. O modelo YOLOv8m-seg é o modelo mais complexo, mas também tem o melhor desempenho em termos de precisão, tem uma configuração de tamanho de 640Px, velocidade a 100 ONNX de 317,0 e a 100TensorRT de 2,18 o que o faz mais adequado para aplicações onde a precisão é mais importante do que a velocidade.

Um equilíbrio entre a simplicidade e a complexidade, constituindo-se como uma base apropriada para a elaboração de nosso próprio modelo de segmentação de faces de bovinos. Para o treinamento da rede, foram

empregadas 100 épocas e os hiperparâmetros padrão da arquitetura.

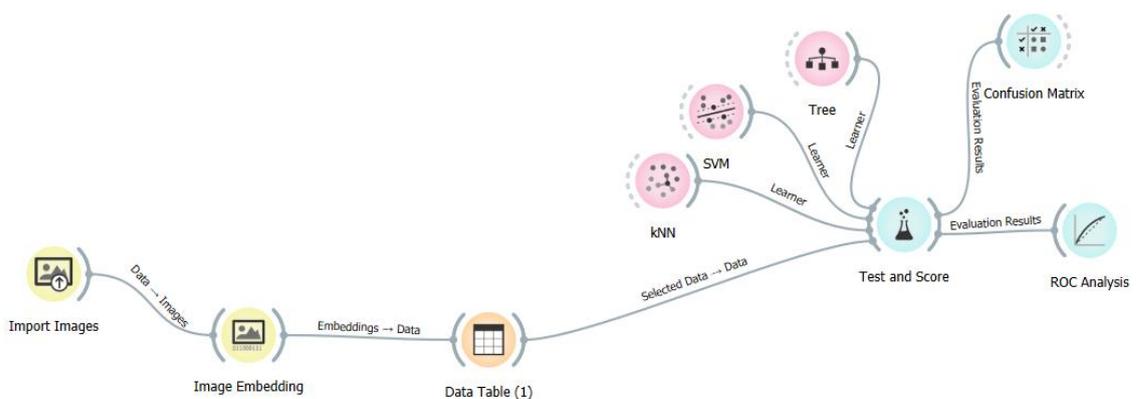
O treinamento do modelo de segmentação das faces de bovinos foi conduzido por meio da plataforma KeroW, que posteriormente disponibilizou o modelo de treinamento mais eficiente para este experimento.

O modelo YOLOv8n-seg é o modelo mais simples e rápido, por outro lado possui o pior desempenho em termos de precisão. Ele é adequado para aplicações onde a velocidade é mais importante do que a precisão. O modelo YOLOv8s-seg é um modelo intermediário em termos de simplicidade, velocidade e precisão. Ele é adequado para aplicações onde um equilíbrio entre esses fatores é necessário. O modelo YOLOv8m-seg é o modelo mais complexo, mas também tem o melhor desempenho em termos de precisão. Ele é adequado para aplicações onde a precisão é mais importante do que a velocidade. O modelo YOLOv8l-seg é o modelo mais complexo e lento, mas também tem o melhor desempenho em termos de precisão. Ele é adequado para aplicações onde a precisão é muito importante e a velocidade não é um fator crítico.

2.2 Embedding

Após a etapa de segmentação as imagens foram submetidas a um processo de extração de características utilizando o software Orange. As características relevantes das imagens foram extraídas por meio da rede neural Inception (Figura 4).

Figura 2 - Workflow da extração de embedding da Inception e teste de algoritmos de aprendizado de máquina.



Fonte: autor (2023).

O emprego da rede Inception (Goodfellow, Bengio e Courville ,2016). para a extração de *embeddings* é justificado por sua habilidade de capturar informações complexas e hierárquicas em imagens. A rede Inception, com sua arquitetura diversificada de convoluções, é capaz de extrair representações significativas das características das imagens, o que a torna uma escolha apropriada para este contexto sendo que foi aplicada no reconhecimento de bovinos (Weber et. al, 2020). O objetivo desta etapa é capturar as características essenciais e semânticas do objeto em um espaço vetorial, de forma a preservar relações entre eles. Essa técnica é amplamente usada em aprendizado de máquina e mineração de dados para aumentar a eficiência dos algoritmos, ao transformar dados complexos em formatos mais adequados para análises quantitativas e computacionais. O que permite que as características distintivas de cada face bovina sejam capturadas e codificadas de maneira eficaz. Os *embeddings* resultantes foram posteriormente utilizados como entradas para análises por algoritmos de aprendizado de máquina.

2.3 Aprendizado de Máquina e métricas

No processo de treinamento dos algoritmos de aprendizado de máquina, adotou-se a estratégia de *Cross Validation* de 10 *folds* estratificados. Essa abordagem é amplamente reconhecida por sua capacidade de avaliar a robustez e o desempenho dos modelos, ao mesmo tempo em que controla o risco de viés na avaliação dos resultados. O processo de *Cross Validation* foi conduzido em 10 partições estratificadas do conjunto de dados, garantindo que cada partição preservasse a proporção das diferentes classes de forma consistente.

Foram utilizados três algoritmos de aprendizado de máquina para testes: o *K-Nearest Neighbors* (KNN), o *Support Vector Machine* (SVM) e o *Decision Tree* (TREE) todos com a configurações padrão do software Orange (citação). A escolha desses algoritmos baseou-se na diversificação das abordagens de modelagem e também em outros artigos de pecuária de precisão. Cada algoritmo possui suas próprias características, vantagens e desafios.

Para comparar e avaliar os modelos foram mensuradas a acurácia a partir

de uma matriz de confusão e o desempenho global do modelo (AUC) que vai nos indicar o quanto as probabilidades de precisão serão assertivas. A curva AUC é uma métrica abrangente que avalia o desempenho de um modelo em diferentes limites e são particularmente úteis para classes desequilibradas.

Além disso, foi utilizada a métrica F1-score que é uma medida da precisão que leva em consideração tanto a precisão quanto o *recall*, com o objetivo de classificar as instâncias corretamente como positivas ou negativas. A métrica F1 equilibra precisão e recall, no entanto, não deve ser usada isoladamente, pois não leva em conta verdadeiros negativos. Por ser uma métrica simples, a F1 deve ser usada com cautela, especialmente para classes desequilibradas.

Apresenta-se também a matriz de confusão, destinada a compreender melhor a massa de dados e os acertos e erros que o algoritmo sofre, uma comparação gráfica que demonstra qual algoritmo ou técnica foi mais assertiva. A precisão produzirá resultados enganosos se o conjunto de dados estiver desequilibrado; isto é, quando o número de observações em diferentes classes varia muito.

3- Resultados

A análise comparativa entre os três modelos mostra que o modelo SVM foi o mais eficiente, com o algoritmo mais preciso e robusto para o conjunto de dados neste estudo. O modelo KNN também é eficiente, mas não tão preciso quanto o modelo SVM. O modelo TREE é o algoritmo menos preciso e robusto dos três modelos e por isso não é uma boa escolha para este conjunto de dados.

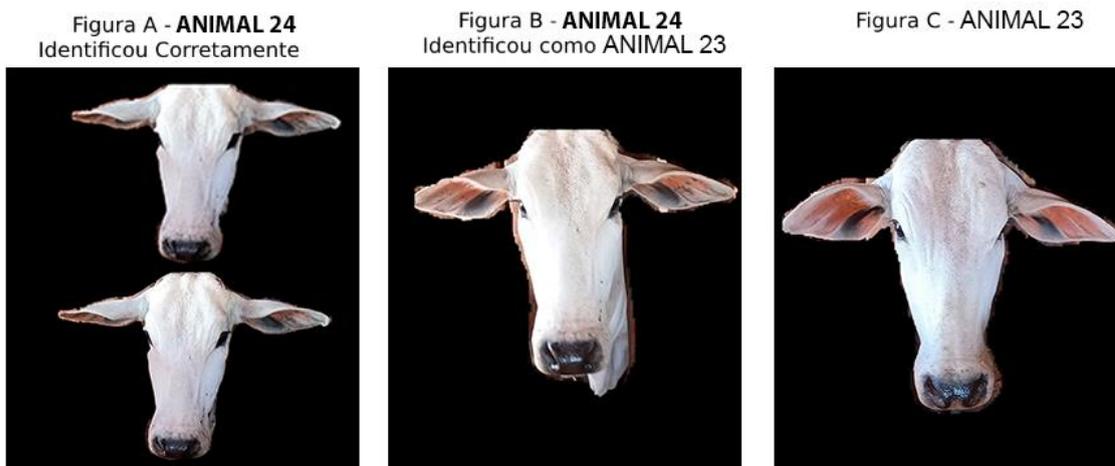
Os resultados da Tabela 4 mostra as métricas dos modelos selecionados, as métricas de Precisão, recall e MCC, não vão ser utilizados neste estudo, já que a Acurácia, a AUC e F1, representam todas as demais métricas. Analisando então essas métricas podemos notar um número superior de AUC, acurácia e F1 no SVM, modelo que por este motivo foi selecionado como melhor para se desenvolver o estudo.

Tabela 1- Métricas de algoritmos de aprendizagem de máquina, demonstrando métricas diferenciais entre eles.

Model	AUC	CA	F1	Prec	Recall	MCC
kNN	0,991	0,949	0,949	0,952	0,949	0,948
SVM	0,999	0,987	0,987	0,987	0,987	0,987
Tree	0,822	0,626	0,627	0,635	0,626	0,616

Fonte: autor (2023).

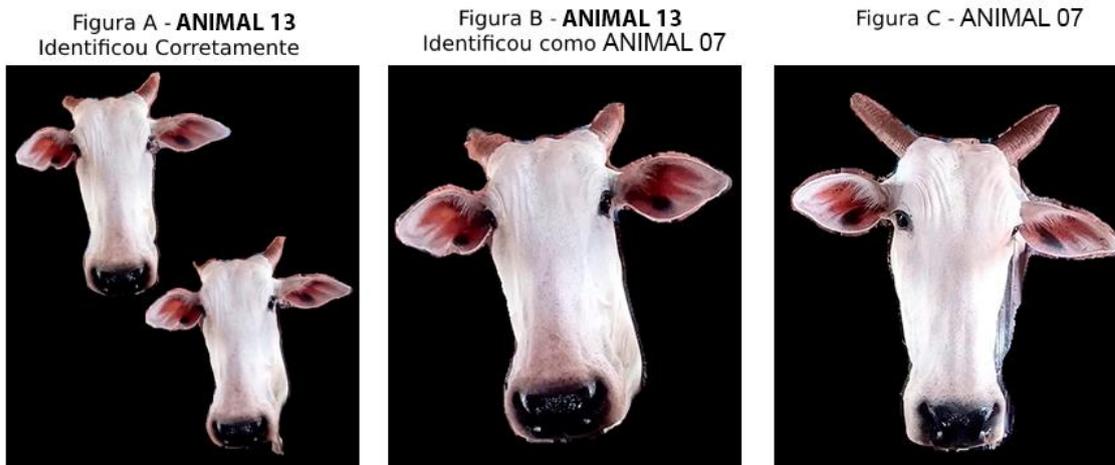
Figura 6 - Classificação incorreta do SVM.



Fonte: autor (2023).

As três imagens da esquerda são do animal 24, porém a figura B foi identificada como animal 23, e a figura C é um exemplo de imagem do animal 23.

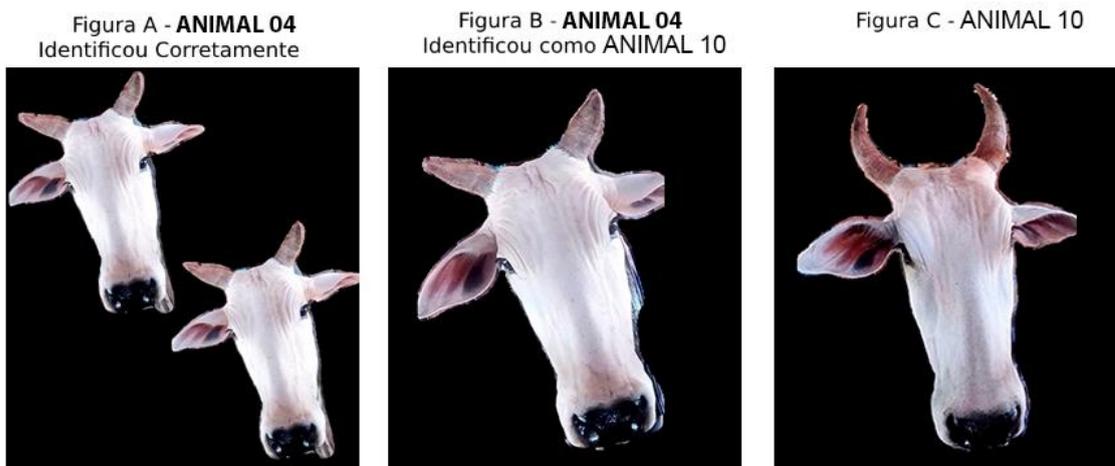
Figura 7 - Classificação incorretas do KNN



Fonte: autor (2023).

As três imagens da esquerda são do animal 13, porém a figura B foi identificada como o animal 07, e a Figura C é um exemplo de imagem do animal 07.

Figura 8 - Classificação incorretas do TREE



Fonte: autor (2023).

As três imagens da esquerda (Figura A e B) são do animal 04, porém a Figura B foi identificada como o animal 10, e a Figura C é um exemplo de imagem do animal 10.

4- Discussões

Assim como Bambil et al., (2020), que relatam identificação de espécies de plantas usando visão computacional e aprendizado de máquina, os resultados mostraram que os algoritmos como SVM e floresta aleatória superaram o desempenho do AdaBoost semelhante aos objetivos nesse experimento. Nossos resultados colaboram com Gong et al., (2022) que se concentram no reconhecimento facial de ovinos e introduzem um modelo baseado em ResNet-50 que atingiu taxas de alta precisão.

Mesmo obtendo bons resultados, sabe-se que Santos (2017) concentra-se no reconhecimento de marcas de gado usando redes neurais convolucionais e máquinas de vetores de suporte. Os resultados mostraram que o método CNN superou o método Bag-of-Features em precisão e velocidade, sendo relevante para a identificação e rastreamento de gado, melhorando a gestão do rebanho. Porém, sabe-se que o problema é complexo para generalização e ainda merece estudos devido a inexistência do software para este uso no mercado com alta acurácia.

Recentemente Bakhshayeshi et al.,(2023), publicaram resumo o que pode

ser um caminho para continuar o experimento que relatamos visto que apesar de um número grande de imagens a generalização é prejudicada pelo número pequeno de animais.

Por fim, a correlação entre os estudos apresentados e o experimento realizado, revela a crescente importância das tecnologias de visão computacional, aprendizado de máquina e redes neurais em diversas aplicações, desde a identificação de espécies de plantas até o reconhecimento facial de animais.

5- Conclusão

O uso de Visão Computacional e Machine Learning aplicados a um conjunto de imagens previamente segmentadas mostrou-se relevante para o reconhecimento facial de bovinos da raça Nelore. Recomenda-se em futuros trabalhos replicar o experimento usando outras tecnologias e ferramentas de IA para reconhecimento de face, tais como a técnica de Few Shot Learning (Aprendizado rápido) que refere-se a alimentar modelos com dados mínimos.

6 - REFERÊNCIAS

ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne(<https://abiec.com.br/wp-content/uploads/sumario2019portugues.pdf>)

ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne – BEEF Report 2023 – Capitulo 6 (https://www.abiec.com.br/publicacoes/beef-report-2023-capitulo-06-sustentabilidade/#dfliip-df_5621/7/)

ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne – BEEF Report 2023 – Capitulo 3(https://www.abiec.com.br/publicacoes/beef-report-2023-capitulo-03/#dfliip-df_5402/3/)

EUCLIDES FILHO, K. **Melhoramento genético animal no Brasil:** fundamentos, história e importância. Campo Grande: Embrapa Gado de Corte, 1999. 63p. (Embrapa Gado de Corte. Documentos, 75). Disponível em: < <https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/323391>> acesso em 03 de ago. 2023.

FARIA, C. U. et. al. **Utilização de escores visuais de características morfológicas de bovinos nelore como ferramenta para o melhoramento genético animal.** Planaltina, DF: Embrapa Cerrados, 2007.40 p. (Documentos / Embrapa Cerrados) Disponível em: < <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/571967> > Acesso em 02 de ago. 2023.

FINN, C., ABBEEL, P., AND LEVINE, S. **Model-agnostic metalearning for fast adaptation of deep networks.** In ICML, 2017.

GONG, He et al. Facial Recognition of Cattle Based on SK-ResNet. **Scientific Programming**, [S.l.], v. 2022, p. 5773721, 2022. Disponível em: <https://doi.org/10.1155/2022/5773721>. Acesso em: 10 de mai. 2023.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens.** 3. ed. São Paulo: Pearson, 2013. ISBN 978-85-8143-586-2.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Book in preparation for MIT Press, 2016. Disponível em: <www.deeplearningbook.org>. Acesso em: 20 de abr. 2023.

HOU, R.; CHANG, H.; MA, B.; SHAN, S.; CHEN, X. **Cross attention network for few-shot classification**. In: NeurIPS, 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), Vancouver, Canada, 2019. Disponível em: <https://proceedings.neurips.cc/paper/2019/file/01894d6f048493d2cacde3c579c315a3-Paper.pdf>. Acesso em: 04 ago. 2023.

DHILLON, G. S., CHAUDHARI, P., RAVICHANDRAN, A., AND SOATTO, S. **A baseline for few-shot image classification**. In ICLR, University of California, Los Angeles, 2020. Disponível em: <https://openreview.net/pdf?id=rylXBkrYDS>. Acesso em: 03 de ago. 2023.

KIM, J., KIM, T., KIM, S., AND YOO, C. D. **Edge-labeling graph neural network for few-shot learning**. In CVPR, 2019.

B. C. Russell, A. Torralba, K. P. Murphy, W. T. Freeman. LabelMe: a Database and Web-based Tool for Image Annotation. International Journal of Computer Vision, 77(1-3):157-173, 2008. <http://labelme.csail.mit.edu/>. Acesso em 21 de agosto de 2023.

LI, Zheng; LEI, Xuemei; LIU, Shuang. A lightweight deep learning model for cattle face recognition. **Computers and Electronics in Agriculture**, v. 195, p. 106848, 2022. ISSN 0168-1699. Disponível em: <https://doi.org/10.1016/j.compag.2022.106848>. Acesso em: 01 de jun. 2023.

LIU, Y., LEE, J., PARK, M., KIM, S., YANG, E., HWANG, S., AND YANG, Y. Learning to propagate labels: Transductive propagation network for few-shot learning. In ICLR, 2019

SANTOS, Carlos Alexandre Silva dos. **Reconhecimento de imagens de marcas de gado utilizando redes neurais convolucionais e máquinas de vetores de suporte**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Pampa, Alegrete, 2017.

SANTOS, Eulanda Miranda dos. **Teoria e Aplicação de Support Vector Machines à Aprendizagem e Reconhecimento de Objetos Baseados na Aparência**. Dissertação (Mestrado em Informática) - Universidade Federal da Paraíba, Campus II, Campina Grande, 2002.

Bakhshayeshi, Ivan & Erfani, Eila & Taghikhah, Firouzeh & Elbourn, Stephan & Beheshti, Amin & Asadnia, Mohsen. (2023). **An Intelligence Cattle Re-Identification System over Transport by Siamese Neural Networks and YOLO**. IEEE Internet of Things Journal. PP. 1-1. 10.1109/JIOT.2023.3294944.

WEBER, Vanessa Ap. de Moraes, et al. **Viable Yeast Identification using Bag of Visual Words in Colored images**. In: Anais do XVI Workshop de Visão Computacional. SBC, 2020. p. 129-133.

WEBER, Vanessa Ap. de Moraes, et al. **Deep learning techniques for beef cattle body weight prediction**. In: 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020a. p. 1-8.

WEBER, Fabricio de Lima. **SISTEMA PARA RECONHECIMENTO DE BOVINOS DA RAÇA PANTANEIRA BASEADO EM REDE NEURAL CONVOLUCIONAL**. Dissertação (Mestrado em Zootecnia) - Universidade Estadual de Mato Grosso do Sul, Aquidauana, 2020.

YANG, L., LI, L., ZHANG, Z., ZHOU, X., ZHOU, E., AND LIU, Y. **Dpgn: Distribution propagation graph network for few-shot learning**. In CVPR, 2020. Disponível em: <http://proceedings.mlr.press/v139/cui21a/cui21a.pdf>. Acesso em: 04 de ago. 2023.

ZEILER, M.; FERGUS, R. Visualizing and Understanding Convolutional Networks. **Springer International Publishing**, p. 818 – 833, 2014.

ZIKO, I., DOLZ, J., GRANGER, E., AND AYED, I. B. **Laplacian regularized few-shot learning**. In ICML, 2020.

Demsar J, Curk T, Erjavec A, Gorup C, Hocevar T, Milutinovic M, Mozina M, Polajnar M, Toplak M, Staric A, Stajdohar M, Umek L, Zagar L, Zbontar J, Zitnik M, Zupan B (2013) **Orange: Data Mining Toolbox in Python**

(<http://jmlr.org/papers/volume14/demsar13a/demsar13a.pdf>), Journal of Machine Learning Research 14(Aug): 2349–2353.

CAPÍTULO 3 – Considerações Finais

O experimento conduzido ao longo desta dissertação buscou responder ao objetivo principal estabelecido, que consiste em investigar a viabilidade do reconhecimento de faces de bovinos por meio da utilização de técnicas de Visão Computacional e Inteligência Artificial. Em vista dos resultados alcançados e das perspectivas identificadas, algumas direções para trabalhos futuros podem ser apontadas. Dentre elas, recomenda-se a realização de experimentos adicionais, utilizando técnicas como o Aprendizado de Poucos Exemplo (Few-Shot Learning), assim sendo com o auxílio dessas outras técnicas, o reconhecimento da raça nelore pela face é totalmente possível.

Quanto aos resultados encontrados no Experimento, na fase inicial, a coleta de imagens de bovinos da raça Nelore foi realizada em duas etapas diferentes, visando capturar uma variedade de ângulos e condições de iluminação. Isso é crucial para a robustez do sistema de reconhecimento, já que as condições de campo podem variar amplamente. Além disso, o uso de uma GoPro 5 para captura das imagens resultou em uma grande quantidade de dados, o que é positivo para treinar modelos de aprendizado de máquina. Existe ainda a necessidade de criação um banco de imagens maior e mais representativo, contendo imagens de diversas propriedades, e diversos equipamentos, isso teria um papel fundamental nesse processo, permitindo que o sistema de reconhecimento fosse mais abrangente e capaz de lidar com a diversidade de contextos encontrados em diferentes propriedades rurais.

Por fim, a correlação entre os estudos apresentados e o experimento realizado, apresenta confirmação de alguns caminhos já utilizados por outros autores, mas também a possibilidade de construir uma rede iniciando o aprendizado com poucas imagens de cada animal, através das técnicas evoluídas e utilizadas no estado da arte. Além disso, revela a crescente importância das tecnologias de visão computacional, aprendizado de máquina e redes neurais em diversas aplicações, desde a identificação de espécies de plantas até o reconhecimento facial de animais e análise fenotípica de raças de gado. Além disso, esses estudos destacam a relevância da sustentabilidade e do bem-estar animal nas práticas agrícolas modernas.