

RECONHECIMENTO FACIAL DE ANIMAIS: UM ESTUDO PRÁTICO

Data de submissão: 08/02/2023

Data de aceite: 01/03/2023

Kaio Felipe Barbosa Garcia

Universidade Estadual do Norte do Paraná
Bandeirantes-Paraná
<http://lattes.cnpq.br/9138353086453679>

Daniela de Freitas Guilhermino Trindade

Universidade Estadual do Norte do Paraná
Bandeirantes-Paraná
<http://lattes.cnpq.br/0712611341649155>

Ederson Marcos Sgarbi

Universidade Estadual do Norte do Paraná
Bandeirantes-Paraná
<http://lattes.cnpq.br/4999862994006825>

José Reinaldo Merlin

Universidade Estadual do Norte do Paraná
Bandeirantes-Paraná
<http://lattes.cnpq.br/0840048221330827>

RESUMO: Reconhecimento facial é uma tecnologia muito utilizada pelo mundo. É uma técnica em que algoritmos utilizam análise profunda de imagem para identificar um indivíduo. Essa tecnologia é usada em fazendas para substituir métodos tradicionais e invasivos de identificação. O objetivo deste trabalho é estudar a tecnologia de reconhecimento facial de animais e aplicar um algoritmo para estudar seu processo de

aplicação e seus resultados. Para treinar o algoritmo escolhido foi preciso ir a campo a fim de capturar dados dos animais de uma fazenda e realizar testes. Após o treinamento, o algoritmo foi capaz de identificar os animais através de imagens. Porém, algumas variáveis encontradas durante a captura dos dados afetaram os resultados obtidos.

PALAVRAS-CHAVE: Reconhecimento Facial. Animais. Aprendizagem de Máquina. Visão Computacional.

ANIMAL FACE RECOGNITION: A PRACTICAL STUDY

ABSTRACT: Facial recognition is a widely used technology around the world. It is a technique in which algorithms use deep image analysis to identify an individual. This technology is used on farms to replace traditional and invasive methods of identification. The goal of this paper is to study animal facial recognition technology and apply an algorithm to study its application process and results. To train the chosen algorithm it was necessary to go into the field to capture animal data from a farm and perform tests. After training, the algorithm was able to identify the animals

through images. However, some variables encountered during the data capture affected the results obtained.

KEYWORDS: Facial Recognition. Animals. Machine Learning. Computer Vision.

1 | INTRODUÇÃO

Reconhecimento facial é uma tecnologia utilizada em grande escala pelo mundo. Trata-se de uma técnica em que algoritmos de visão computacional utilizam análise profunda de imagem para identificar um indivíduo. Essa técnica, por exemplo, é utilizada pela polícia para monitoramento e os celulares modernos utilizam para identificação do proprietário. Há diversas outras aplicações, incluindo a utilização com animais. Atualmente essa tecnologia é usada apenas nas grandes fazendas de gado, devido a diversos fatores ela não chegou às pequenas fazendas.

O uso dessa tecnologia inovadora nas fazendas surgiu da necessidade de substituir métodos tradicionais e invasivos de identificação e controle dos animais, como marcação corporal e brincos identificadores. O reconhecimento facial, por se tratar de um método não invasivo e automatizado, possibilita o registro automático de informações dos animais.

1.1 Delimitação e formulação do problema

No trabalho aqui relatado foi feito um estudo prático sobre reconhecimento facial de animais, aplicando um algoritmo e analisando a sua aplicação, resultados e as variáveis encontradas que podem alterar o resultado encontrado.

O estudo dessa tecnologia pode facilitar seu uso, pois se trata de um processo complexo que engloba várias etapas. Um estudo que documenta seu processo de aplicação ajuda a disseminar o conhecimento dessa tecnologia que ainda não é utilizada em larga escala.

1.2 Objetivos

O objetivo do trabalho é utilizar um algoritmo de reconhecimento facial de animais selecionado a partir de pesquisa, com o propósito principal de estudar suas características, vantagens e limitações, desde a aplicação em campo até seus resultados encontrados.

1.3 Metodologia

Os passos que seguidos no trabalho foram:

- Revisão Bibliográfica: foram pesquisados e documentados os algoritmos e estudos que auxiliaram no entendimento da tecnologia para as etapas seguintes;
- Estudo da Tecnologia: foi realizado um estudo sobre a tecnologia de reconhecimento facial em animais e seu contexto, vantagens, desvantagens, dificuldades e formas ideais de uso;

- Análise dos Algoritmos: com os algoritmos e trabalhos documentado foi possível passar para a análise dos mesmos e das tecnologias (como as CNN e as bibliotecas);
- Aplicação do Algoritmo: após o entendimento do algoritmo e de como usá-lo, foi possível aplicá-lo para tentar obter alguns resultados; e
- Análise dos Resultados: os resultados dos testes foram analisados, junto com as variáveis que causaram variações nos resultados.

1.4 Justificativa

O método do reconhecimento de animais surgiu como uma alternativa não invasiva para os métodos comuns, como brincos ou ferro quente, porém seus algoritmos são complexos e de difícil entendimento. Por isso deve-se estudá-los e documentar seu uso para que essa tecnologia, que traz tantos benefícios, torne-se mais conhecida e possa ser utilizada em maior escala, especialmente em pequenas propriedades.

2 | FUNDAMENTAÇÃO TEÓRICA

Nesta seção é apresentada uma revisão da literatura sobre os temas relativos ao trabalho, em que será mostrado o que é reconhecimento facial e suas fases, mostrando a relação do reconhecimento facial com os animais, algumas características dos algoritmos desse reconhecimento e mostrando alguns outros métodos de reconhecimento e identificação dos animais.

2.1 Reconhecimento facial

Segundo Orvalho (2019), a tecnologia conhecida por Reconhecimento Facial é capaz de identificar uma pessoa a partir de uma imagem digital ou de um vídeo e essa tecnologia já está presente em diversos campos da sociedade, como o das Ciências Forenses. Haralick (1992) afirma que os algoritmos de visão computacional, como o de reconhecimento facial, são compostos de diferentes subalgoritmos, muitas vezes aplicados em sequência.

Schmidt (2017) apresenta a tecnologia de reconhecimento facial como sendo composta por três etapas, seguidas sequencialmente. São elas: detecção da face, extração de características e reconhecimento da face.

A detecção é a fase em que a imagem é analisada e o algoritmo de detecção encontra o rosto e os pontos de referência nas imagens, que podem ser coisas como os olhos, o nariz, o queixo e as orelhas (SCHMIDT, 2017). *Data augmentation*, ou aumento de dados, é um processo capaz de aumentar artificialmente a quantidade de dados a partir dos dados existentes. Uma de suas estratégias é a adição de pequenas alterações dos originais para amplificar o conjunto de dados (TENSORFLOW, 2022).

A extração de características é a etapa em que um algoritmo realiza a análise da

imagem que já teve um rosto encontrado e extrai as características dele as armazenando para a próxima fase. Se for um treino ela será guardada e se for para um teste será comparada com aquelas que foram armazenadas durante os treinamentos. Segundo Damasceno (2017):

A etapa de extração de características desempenha um papel importante no processo de reconhecimento, pois seleciona as melhores características discriminantes menos sensíveis a variação na pose, expressões faciais e variações de iluminação, reunindo-as em um vetor de características para a sua representação.

A etapa final é chamada de reconhecimento da face. É a fase em que o vetor das características, encontrado na fase anterior, é comparado com o conjunto dos vetores de treino que também foram gerados pela fase de extração de características em busca de características semelhantes.

2.2 Reconhecimento de animais

O uso da tecnologia de reconhecimento em animais, de acordo com Billah (2022), é um passo importante para auxiliar no manejo animal e para a obtenção de dados significativos precisos para gerenciar a reprodução do gado em fazendas. Hansen (2018) relata que essa tecnologia foi proposta como um método não invasivo para suprir a necessidade da identificação e controle individual dos animais.

Indo além das fazendas, seu uso na natureza traz uma revolução na maneira de coletar dados dos animais selvagens. Segundo Clapham et al. (2020), as novas tecnologias de reconhecimento de animais apoiam uma nova era de pesquisas sobre a vida selvagem, gerando dados sobre escalas de indivíduos e suas populações. Os autores ainda afirmam que não existem métodos visuais objetivos de identificação individual para espécies que carecem de marcações corporais únicas e consistentes. Isso os motivou a aplicar técnicas de reconhecimento facial e *deep learning* para identificar e classificar ursos pardos (*Ursus arctos*). Sua aplicação *open-source* foi chamada de *BearID*.

2.3 Métodos de reconhecimento

O reconhecimento surgiu como uma alternativa às técnicas tradicionais de identificação e reconhecimento. Hansen (2018) afirma que o método de identificação de gado mais utilizado são as *tags rfid* de identificação por radiofrequência, que apesar de terem baixo custo sua colocação consome tempo e é angustiante para os animais, pois essas *tags* são colocadas em forma de brinco na orelha do animal.

As técnicas como tatuagem, marcação dos ouvidos ou implante de microchips são técnicas invasivas de identificação populares que deixam uma marca permanente no corpo do animal, porém esses métodos trazem muitos desafios, como infecções animais, septicemia leve e hemorragia (BELLO. et al, 2020).

2.4 Obstáculos e dificuldades no reconhecimento

Xue, Chen e He (2020) afirmam que a postura e a posição do rosto das ovelhas, que foram o foco do reconhecimento, são as variáveis que afetam o resultado. Segundo Kumar e Singh (2015), além do posicionamento do animal na imagem, a iluminação e o fundo também afetam o resultado, principalmente variando com as imagens tiradas *indoor* ou *outdoor*. A face dos animais nem sempre estão limpas. Porcos, por exemplo, tendem a se sujar. Xue, Chen e He (2020) contam que, em alguns chiqueiros em que o algoritmo foi aplicado, as faces dos animais não eram limpas por um longo período e isso tornou difícil obter um bom resultado do reconhecimento.

O principal desafio encontrado por Clapham et al. (2020) foi que o *deep learning* requer grandes conjuntos de dados rotulados para treino e testes. Estes dados são difíceis de se adquirir quando se trata de populações selvagens como os ursos pardos estudados, especialmente a nível individual. Matkowski (2019) mostram as dificuldades encontradas no reconhecimento de espécies como os panda, em que seus *datasets* são poucos e pequenos, por causa do número de indivíduos e a pouca qualidade das imagens.

2.5 Tecnologias

Diversas tecnologias são utilizadas para construção dos algoritmos de reconhecimento facial. As redes neurais convolucionais (*convolutional neural network-cnn*), aplicadas nas etapas do reconhecimento, foram usadas por Hansen et al. (2018) e foram treinadas utilizando-se um conjunto de dados capturados por meio de uma *webcam* posicionada no bebedouro dos animais. Segundo Data Science Academy (2022), a CNN se trata de uma rede neural artificial do tipo *feedforward* que costuma ser aplicada no processamento, análise e classificação de imagens digitais.

A linguagem de programação Python é utilizada em Marsot et al. (2020), acompanhado da biblioteca *opencv*, uma biblioteca *open source* multiplataforma de visão computacional e aprendizado de máquina, escrita em C/C++, que foi utilizado para treinar o algoritmo de classificação. A biblioteca fornece dois programas para formar um classificador em cascata *haar*, *opencv-createsamples* e *opencv-traincascade*.

2.6 Estratégias

O reconhecimento da face não é a única estratégia na construção dos algoritmos. Bello et al. (2020) apresentam um sistema de reconhecimento individual de vacas da raça *Holstein-Frisia*, conhecida popularmente como Gado Holandês, que realiza o reconhecimento por meio dos padrões das manchas corporais. Já em Bello et al. (2020b), o sistema de reconhecimento e identificação se dá por meio da aprendizagem do padrão de imagem do nariz, semelhante às impressões digitais humanas.

3 | DESENVOLVIMENTO

Este capítulo trata de como foi escolhido um algoritmo de reconhecimento facial, como foi feita a aquisição e tratamento dos dados, os resultados da aplicação e as conclusões.

3.1 Materiais e métodos

Para o estudo da aplicação da tecnologia de reconhecimento facial em animais foi preciso selecionar um algoritmo de código aberto, sendo ele o *Cattle Recognition* (BLANCO, 2019). A escolha foi feita com base nos seguintes critérios: 1) Ser código aberto, para ser possível alterá-lo e disponibilizá-lo após as alterações; 2) Ser voltado para gado bovino, animais que foram o foco deste trabalho; 3) Ser um trabalho recente, para manter o estudo voltado para a tecnologia atual; 4) Estar disponível para consulta e comparação de sua versão original e a alterada; e 5) Utilizar tecnologias conhecidas.

As modificações feitas no código do algoritmo foram a atualização das importações de bibliotecas e a remoção de funções extras que não seriam utilizadas, como os *templates* de páginas HTML e arquivos CSS, que não eram o foco deste trabalho. A versão modificada do algoritmo está disponível em um repositório público no GitHub, chamado Reconhecimento Facial Bovino (<https://github.com/kaiofbgarcia/Reconhecimento-Facial-Bovino>).

A tecnologia de reconhecimento facial é aplicada em etapas, iniciando com a aquisição das imagens dos animais para treinar o algoritmo, tratamento dos dados coletados, aplicação do algoritmo com as imagens adquiridas, análise dos resultados de treinamento, captura de imagens para testes, realização de testes e por análise dos resultados dos testes. Essas etapas devem ser seguidas de forma linear, com uma única exceção a aquisição das imagens de teste, que pode ser realizada junto com as anteriores.

3.1.1 Aquisição das imagens

Capturar as imagens dos animais é a etapa que deve-se ter maior atenção e cuidado pois há algumas escolhas de como será realizada a captura que evitam resultados negativos no decorrer da sequência de trabalho. Por exemplo, ao manter um fundo (*background*) padronizado, em que há poucas variações de elementos evitando que o treinamento seja comprometido. Assim torna-se possível que o algoritmo identifique as características marcantes apenas dos animais e não do fundo.

Para este trabalho, foram utilizados animais de uma pequena fazenda localizada na cidade de Fartura-SP, pois o estudo foi voltado a pequenas propriedades.

Foram selecionados nove animais mostrados na Figura 1. Sete deles foram escolhidos desejando algumas características marcantes diferentes entre eles, como variação de idade, tamanho, sexo, coloração de pelo, chifres. Outros dois animais foram escolhidos por serem parecidos com um dos sete anteriores para testar se causaria

confusão no algoritmo, o que será discutido na apresentação dos resultados. No Quadro 1 há uma lista dos animais e de suas características físicas, notáveis ao observá-los. Os nomes sublinhados são referentes aos dois animais escolhidos por serem parecidos uns com os outros.



Figura 1: Fotos dos Animais

Antes do início da captura foi feita a escolha de utilizar vídeos que seriam transformados em imagens para facilitar a aquisição de grandes quantidades de dados. Para fazer isso foi criado um programa simples em Python, chamado “*frames.py*”, que separa um vídeo em imagens, *frame* por *frame*. Para realizar as gravações foi utilizado um *smartphone*, modelo Xiaomi Redmi Note 9, cuja câmera grava em 30 fps (*frames* por segundo) e possui 48 MP (*megapixels*). As imagens obtidas devem ser armazenadas em pastas com o nome do animal para que durante o treinamento o algoritmo defina esses nomes para as classes que representam cada um dos animais. Quatro dos animais não tinham nomes, então receberam um apelido com base em seu número de brinco. As pastas nomeadas devem ser colocadas dentro de uma pasta chamada “*dataset*” para que o

algoritmo as encontre.

Nome	Sexo	Idade	Porte	Pelo	Chifre	Outros
Branquinha	Femêa	Adulta	Médio/grande	Branco	-	-
Barbosa	Femêa	Adulta	Médio/grande	Branco com parte da cabeça amarronzada	Médio/grande voltados para cima	-
Chifrinho10	Femêa	Adulta	Médio/grande	Preto com mancha branca no centro dos chifres	Pequenos voltados para baixo	-
Jove	Macho	Filhote	Pequeno	Manchado de preto e branco	-	-
Inocência	Femêa	Filhote	Pequeno	Branco com parte da cabeça amarronzada	-	Orelhas grandes
Novilha03	Femêa	Filhote	Pequeno	Branco	-	Orelhas grandes
Novilha43	Femêa	Adulta	Médio/grande	Preto	Médio/grande voltados para cima	-
Princesa	Femêa	Adulta	Médio/grande	Branco com boa parte da cabeça amarronzada	-	-
Tufão	Macho	Adulto	Grande	Manchado de preto e branco	Pequenas pontas	Cupim localizado atrás do pescoço

Quadro 1: Animais Selecionados

Inicialmente, a ideia era capturar as imagens de cada animal de forma individual enquanto ele estivesse se alimentando em um cocho sozinho. No entanto, essa estratégia se mostrou bastante difícil, pois não se pode controlar totalmente o comportamento do animal, o que dificulta a realização das gravações. Para os animais mais calmos foi mais fácil obter uma maior quantidade de imagens utilizáveis. No total foram dezessete 17.013 imagens de teste e treino obtidas dos animais. Os filhotes foram os indivíduos que apresentaram maior dificuldade de se gravar porque sempre estavam juntos de outros animais ou muito agitados. A Inocência foi uma exceção, pois era recém-nascida e estava separada dos demais.

As imagens de teste tiveram que passar por um tratamento manual. Utilizando-se uma ferramenta de corte foi possível ajustar a imagem para focar apenas no animal, removendo partes indesejadas. Para esse experimento a quantidade de dados obtida foi suficiente, porém, para uma aplicação real seria necessária uma maior quantidade de imagens para se treinar o algoritmo.

3.1.2 Algoritmo e treinamento

O algoritmo criado por Blanco (2019) foi escrito na linguagem Python e recomenda-se utilizar o Python 3.9, ou inferior, por questão de compatibilidade de suas bibliotecas. Esse algoritmo suporta três modelos de rede neural: VGG16, ResNet50 e SeNet50. O que foi utilizado é o ResNet-50, um modelo de rede neural convolucional de 50 camadas. O repositório conta com um README descritivo com os comandos necessários para execução e uma sequência de passos.

Com as imagens devidamente organizadas em pastas dentro de uma pasta *dataset* pode-se realizar a limpeza dos dados, uma etapa opcional e que não apresentou um

funcionamento correto com grandes quantidades de imagens. O primeiro passo é utilizar o comando `python training.py --granja test --model resnet50 --epochs 20 --batch_size 30` para executar o arquivo `training.py` que começará o treinamento.

No comando, o termo `test` refere-se ao nome escolhido para o treinamento (opcional), `resnet50` refere-se modelo de rede neural escolhido (resnet50, vgg16 e senet50), `20` refere-se número de ciclos de treinamento que serão realizados (valor recomendado) e `30` refere-se ao número de exemplos de formação utilizados numa iteração (valor recomendado).

A execução final realizada foi nomeada de *TCCTestF*, o modelo e os valores se mantiveram como recomendado, seu treinamento durou aproximadamente doze horas e após cada um dos vinte ciclos exibia um valor de *Accuracy* e *Loss* do treino e da validação, que representam a exatidão e perda de um modelo de classificação, respectivamente, esses dados são mostrados em forma de gráficos (Figura 3), feitos automaticamente com a ferramenta TensorBoard.

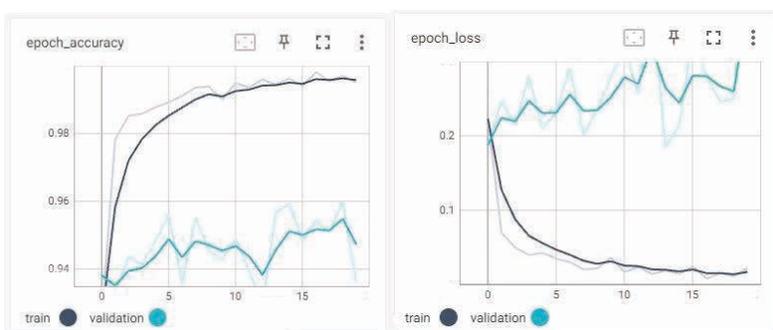


Figura 3: Curva de Precisão e Perda

3.2 Resultados e discussão

Os primeiros resultados obtidos foram durante a fase de treino, como mostrado nos gráficos da Figura 3. No primeiro gráfico vemos que o modelo treinado apresentou uma boa acurácia no treinamento, mas na validação apresentou forte *overfitting*. Segundo Cárdenas-Montes (2006), *overfitting* significa que um modelo se ajusta muito bem ao conjunto de dados, mas apresenta dificuldade na previsão de novos resultados. Já no segundo gráfico é possível observar que se obteve uma boa taxa de aprendizagem no treinamento apesar da alta taxa de perda durante a validação, proporcional a acurácia.

3.2.1 Testes das imagens

Para realizar testes individuais com as imagens deve-se utilizar o comando `python testing.py --granja test --img "path/to/img"` para executar o arquivo `testing.py`. Nele há

a necessidade de informar qual o nome do treinamento que será testado e qual o caminho para imagem de teste, representados, respectivamente, pela parte em negrito no comando acima.

Os resultados dos testes individuais estão apresentados no Quadro 2. Durante esses testes foram obtidos resultados positivos, negativos, esperados e inesperados. Na Figura 5 é mostrado um exemplo de um caso de sucesso em que a imagem foi reconhecida pelo algoritmo. Todos os testes mostrados nas figuras apresentam à esquerda a imagem de teste que foi utilizada. Na Figura 6 pode-se notar que o Teste 2 da Inocência não correu como esperado, pois esse animal não possuía uma grande quantidade de dados de treinamento, o que pode ter causado essa confusão no resultado.

Nome	Teste 1	Teste 2	Teste 3	Teste 4
Branquinha	✓	✓	-	-
Barbosa	X	✓	X	-
Chifrinho10	X	X	✓	-
Jove	X	✓	-	-
Inocência	✓	X	✓	-
Novilha03	✓	✓/ X	-	-
Novilha43	✓	✓	-	-
Princesa	✓	✓	✓	✓
Tufão	✓	✓	-	-

Quadro 2: Resultados dos Testes Individuais



Figura 4: Teste 1 - Tufão

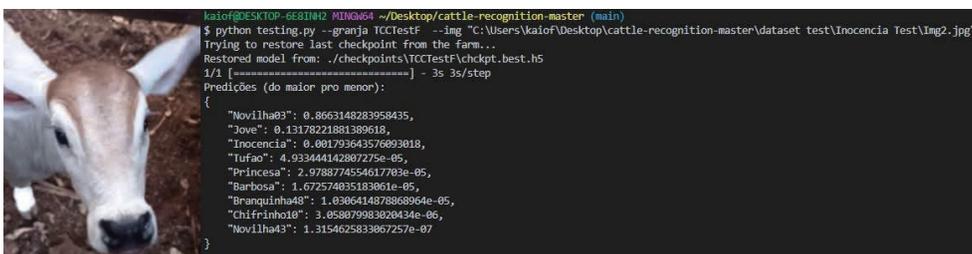


Figura 5: Teste 2 - Inocência

Um caso curioso ocorreu com o Chifrinho10, que apesar de ser o animal com maior número de imagens de treino, o reconhecimento falhou em duas das três imagens de teste.

Um exemplo é mostrado na Figura 6. Esse erro ocorreu devido a um erro na gravação das imagens deste animal, em que um grande número delas o animal não está localizado no centro da gravação.

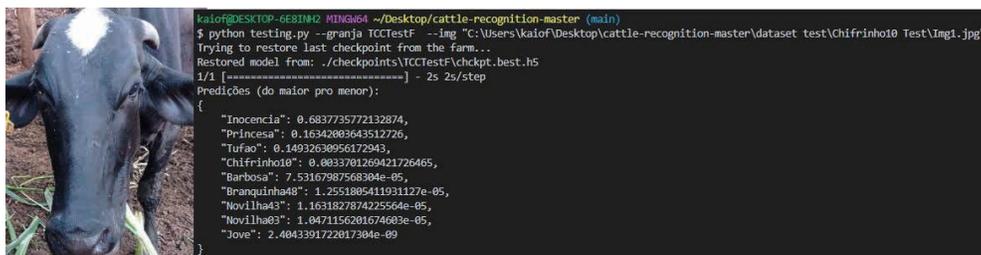


Figura 6: Teste 1 - Chifrinho10

Dois animais foram selecionados por serem parecidos uns com os outros. O Jove possui um padrão de manchas na pelagem muito semelhante ao seu pai Tufão e a Novilha03 tem o pelo parecido com a Branquinha, como mostrado na Figura 7. Na Figura 8 nota-se que a semelhança entre pai e filho confundiu o algoritmo que identificou a imagem de teste como Tufão. Durante o Teste 2 da Novilha03 o algoritmo mesmo acertando se confundiu na predição, ficando quase meio a meio entre as duas, como mostrado na Figura 9.



Figura 7: Jove, Tufão, Novilha03 e Branquinha

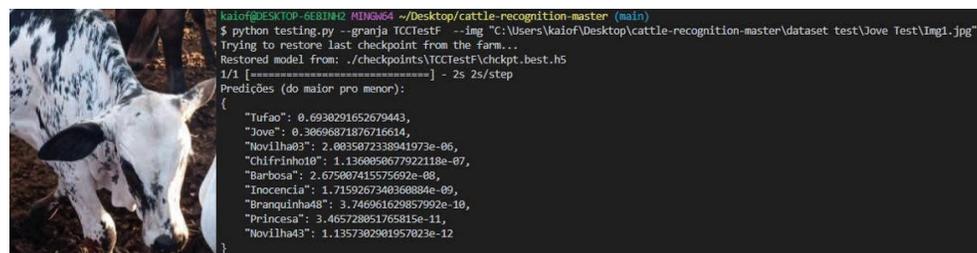


Figura 8: Teste 1 - Jove

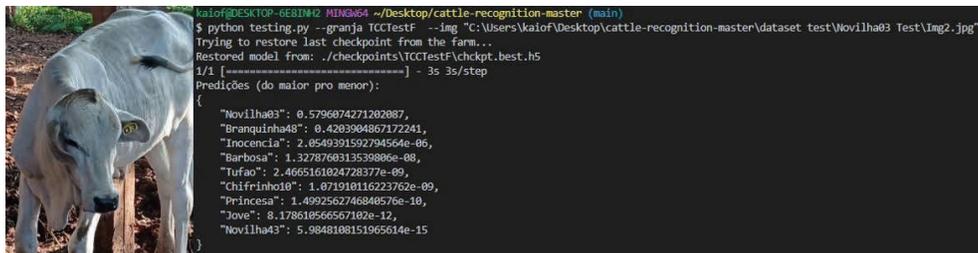


Figura 9: Teste 2 - Novilha03

4 | CONCLUSÃO

Durante o desenvolvimento do trabalho as maiores adversidades encontradas foram com relação ao comportamento dos animais e como isso afetou na quantidade e qualidade dos dados. Diversos autores apontam que esse é um dos principais obstáculos dessa tecnologia, principalmente os que a usam em ambientes selvagens. O *background* e iluminação foram outros fatores que também causaram empecilhos e falhas, como o caso já mostrado do Chifrinho10, porém são problemas contornáveis tomando cuidados na captura e tratando os dados.

A tecnologia de reconhecimento facial, apesar dos contratempos e dificuldades, foi funcional. Porém, para seu uso em uma fazenda real, seriam necessários investimentos que a tornam inviável para pequenos produtores. Para seu funcionamento é preciso câmeras bem posicionadas em locais estratégicos, tempo e capacitação para coleta de dados e treinamento, constante manutenção do equipamento e a capacidade de integrar essa tecnologia com outras e transformar em um sistema automatizado.

Esse método de identificação poderia ser usado em conjunto com outras tecnologias. Pode-se integrar o reconhecimento facial com os alimentadores e balanças que captam dados dos animais enquanto os alimenta e assim usar o reconhecimento do rosto para armazenar os dados de forma totalmente automática. Outra situação de uso da tecnologia é durante as vacinações. Posicionando a câmera no brete onde são aplicadas as vacinas para que os produtores e veterinários não precisem anotar quais animais já foram vacinados, o sistema faria isso de forma automática. Nesses sistemas ideais os dados de teste devem ser captados e analisados em forma de vídeo e o algoritmo deve, se possível, analisar em tempo real o rosto do animal.

Essa tecnologia inovadora e cheia de vantagens tem potencial para substituir métodos invasivos de identificação. Porém, é preciso focar em estudos para criar formas de tratar os dados e desenvolver novos algoritmos e técnicas visando melhorar a precisão do reconhecimento. De início, a prioridade deve ser dada aos dados e ao processo de captura. Criar um plano visando minimizar as influências externas evita que elas afetem o resultado do reconhecimento. As fazendas que querem utilizar essa tecnologia precisam

investir nesse método de identificação que fornece uma nova forma gerenciar os animais sem prejudicá-los.

AGRADECIMENTOS

Os autores agradecem à FUNDAÇÃO ARAUCÁRIA de Apoio ao Desenvolvimento Científico e Tecnológico do Estado do Paraná pelo apoio financeiro durante o desenvolvimento da pesquisa.

REFERÊNCIAS

BELLO, R-W.; TALIB, A. Z.; MOHAMED, A. S. A.; OLUBUMMO, D. A.; OTOBO, F. N. **Image-based individual cow recognition using body patterns**. International Journal of Advanced Computer Science and Applications, 2020.

BELLO, R-W.; TALIB, A. Z. H.; MOHAMED, A. S. A. B. **Deep learning-based architectures for recognition of cow using cow nose image pattern**. Gazi University, 2020b.

BILLAH, M.; WANG, X.; YU, J.; JIANG, Y. **Real time goat face recognition using convolutional neural network**. Computers and Electronics in Agriculture, 2022.

BLANCO, E. **Identificación de ganado con convolutional neural networks (enns)**. Repositório GitHub, 2019.

CÁRDENAS-MONTES, M. **Sobreajuste—overfitting**. Ciemat (Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas), 2006.

DAMASCENO, G. S. de S. **Reconhecimento facial com variações de iluminação utilizando pca e modificações da det associadas aos classificadores gmm, naive bayes e k-nn**. Programa de pós-graduação em ciência da computação da Universidade Estadual do Ceará, 2017.

CLAPHAM, M. et al. **Automated facial recognition for wildlife that lack unique markings: A deep learning approach for brown bears**. Ecology and evolution, 2020.

Data Augmentation. TensorFlow Core, 2022.

DATA SCIENCE ACADEMY. **Deep Learning Book**, 2022.

HANSEN, M. F.; SMITH, M. L.; SMITH, L. N.; SALTER, M. G.; BAXTER, E. M.; FARISH, M. GRIEVE, B. **Towards on-farm pig face recognition using convolutional neural networks**. Computer in Industry, 2018.

HARALICK, R. M. **Performance characterization in computer vision**. Springer London, 1992.

KUMAR, S; SINGH, S. **Face recognition of cattle**. 2015.

MATKOWSKI, W. M.; KONG, A. W. K.; SU, H.; CHEN, P.; HOU, R.; ZHANG, Z. **Giant panda face recognition using small dataset**. IEEE, 2019.

MARSOT, M.; MEI, J.; SHAN, X.; YE, L.; FENG, P.; YAN, X.; LI, C.; ZHAO, Y. **An adaptive pig face recognition approach using convolutional neural networks**. Computers and Electronics in Agriculture, 2020.

ORVALHO, V. **Reconhecimento facial**. Revista de Ciência Elementar, 2019.

SCHMIDT, A. E.; NOGUEIRA, E. C. **Estudo sobre métodos de reconhecimento facial em fotografias digitais**. IFC-Camboriú, 2017.

WANG, K; CHEN, C; HE, Y. **Research on pig face recognition model based on keras convolutional neural network**. IOP Conference, 2020.

XUE, H. et al. **Open set sheep face recognition based on euclidean space metric**. Mathematical Problems in Engineering, 2021.