



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

SISTEMA PARA RECONHECIMENTO DE BOVINOS DA RAÇA PANTANEIRA BASEADO EM REDE NEURAL CONVOLUCIONAL

Acadêmico: Fabricio de Lima Weber

Aquidauana-MS
03/2020



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

SISTEMA PARA RECONHECIMENTO DE BOVINOS DA RAÇA PANTANEIRA BASEADO EM REDE NEURAL CONVOLUCIONAL

Acadêmico: Fabricio de Lima Weber
Orientador: Prof. Dr. Urbano Gomes Pinto de Abreu
Co-orientador: Prof. Dr. Hemerson Pistori

“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
03/2020

W382s Weber, Fabricio de Lima

Sistema para Reconhecimento de Bovinos da Raça
Pantaneira Baseado em Rede Neural Convolucional/ Fabricio
de Lima Weber. Aquidauana: UEMS, 2020.
53p.

Dissertação (Mestrado) – Zootecnia – Universidade
Estadual de Mato Grosso do Sul, 2018.

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

1. Bovino pantaneiro 2. Reconhecimento 3. Visão
computacional I. Abreu, Urbano Gomes Pinto de II.
Título

CDD 23. ed. – 366.2




Universidade Estadual de Mato Grosso do Sul
Programa de Pós-Graduação em Zootecnia
Área de Concentração: Produção Animal



FABRÍCIO DE LIMA WEBER

Dissertação submetida ao Programa de Pós-Graduação em Zootecnia, área de concentração em Produção Animal no Cerrado-Pantanal, como requisito para obtenção do grau de Mestre em Zootecnia.

DISSERTAÇÃO APROVADA EM 04/03/2020.


Dr. Urbano Gomes Pinto de Abreu
Dr. Edson Takashi Matsubara
Dr. Marcus Vinícius Moraes de Oliveira

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

Primeiramente quero agradecer à Deus e a Nossa Senhora Aparecida, por terem me permitido concluir mais essa etapa dos meus estudos. Sei que foram eles que nos momentos difíceis iluminaram meus pensamentos e me deram força e fé para continuar a caminhada.

Agradeço à minha esposa Vanessa pela paciência de estar ao meu lado e pela força nos momentos mais difíceis. Ela é a pessoa na qual busco inspiração, de como ser um pesquisador.

Agradeço à minha mãe, por ter me dado apoio e incentivo.

Agradeço aos professores da UEMS, Campus Aquidauana, por terem me proporcionado aprendizado no curso de pós-graduação em Zootecnia, em especial ao Professor Urbano Gomes Pinto de Abreu por ser meu orientador, ter me dado apoio, e por ser não só um Professor, mas também um amigo.

Agradeço ao meu co-orientador, professor Hemerson Pistori, que me permitiu participar de suas aulas de Visão Computacional e nelas me motivou a seguir uma carreira científica.

Agradeço também aos colegas da pós-graduação, e aos amigos que me deram apoio nesta conquista: Pedro Henrique, Adair, Geazy, Roni, Hudson e Marcel.

Meus sinceros agradecimentos.

SUMÁRIO

RESUMO.....	ix
ABSTRACT.....	x
CAPÍTULO 1 - CONSIDERAÇÕES GERAIS.....	01
1 - INTRODUÇÃO.....	02
2 - REVISÃO DE LITERATURA.....	03
2.1 - BOVINO PANTANEIRO.....	03
2.2 - VISÃO COMPUTACIONAL.....	06
2.2.1 - Aprendizado de Máquina.....	07
2.2.2 - Redes Neurais Convolucionais	09
2.3 - IDENTIFICAÇÃO DE BOVINOS.....	12
3 - OBJETIVOS.....	16
3.1. - OBJETIVO GERAL.....	16
3.2. - OBJETIVOS ESPECÍFICOS.....	16
4 – REFERÊNCIAS.....	17
CAPÍTULO 2 - RECONHECIMENTO DE BOVINO PANTANEIRO UTILIZANDO VISÃO COMPUTACIONAL ATRAVÉS DA REDE NEURAL CONVOLUCIONAL	19
ABSTRACT.....	20
1 - INTRODUCTION.....	20
2 - MATERIALS AND METHODS.....	23
3 - RESULTS AND DISCUSSIONS.....	31
4 - CONCLUSION.....	37
REFERENCES.....	37
CAPÍTULO 3- CONSIDERAÇÕES FINAIS.....	42

LISTA DE TABELAS

Table 1 – Accuracy results in Training, Testing and Processing time.....	33
Table 2 – Accuracy with Cross-validation result and standard deviation by model.....	36
Table 3 - Result of precision, recall and F1-score with cross-validation.....	36

LISTA DE FIGURAS

Figura 1 - Bovino pantaneiro no NUBOPAN. Fonte: Arquivo Pessoal.....	3
Figura 2 - Bovino pantaneiro Touro Jagunço propriedade de Thomas Horton.....	5
Figura 3 - Exemplos de processamento de imagens, (a) imagem original, (b) imagem em tons de cinza, (c) imagem com threshold e (d) imagem com detecção de bordas. Fonte: Arquivo Pessoal.....	6
Figura 4 - <i>Exemplos de convolução utilizando Filtro de Sobel</i>	
Figura 5 - Ilustração do processo de classificação através da arquitetura LeNet, um modelo CNN. Fonte: Arquivo Pessoal.....	10
Figura 6 - <i>Ilustração da aplicação do Pooling em uma imagem. Fonte: Arquivo Pessoal.....</i>	11
Figura 7 - Exemplos de reconhecimento de objetos, pessoas e animais feitos por uma CNN. Adaptado de Ren et al. (2015).....	11
Figura 8 - Exemplos de identificação de bovinos. A) Utilização de brincos. B) Marcação a fogo.....	13
Figura 9 - Exemplos da aplicação da tatuagem em bovinos.....	13
Figura 10 - Exemplos de local para marcação a fogo em bovinos. A) Marcação incorretas. B) Marcações Corretas. Fonte: Arquivo Pessoal.....	14
Figura 11 - Exemplos de identificações eletrônicas. A) Transponder. B) Brincos. C) Colar. Fonte: Arquivo Pessoal.....	14
Figura 12 - Exemplos de identificações através do espelho nasal.....	15

RESUMO

O objetivo deste estudo foi aplicar Redes Neurais Convolucionais (CNN's) para identificação de bovinos da raça Pantaneira por meio de imagens. Estes animais estão perfeitamente adaptados às condições adversas do Pantanal e foram trazidos pelos espanhóis e portugueses durante a colonização dessa região. Atualmente o gado pantaneiro está quase extinto, sendo que alguns dos seus últimos exemplares estão sendo conservados no Núcleo de Conservação de Bovinos Pantaneiros de Aquidauana (NUBOPAN) pertencente à Universidade Estadual do Mato Grosso do Sul / Unidade Universitária de Aquidauana (UEMS/UUA), e na fazenda Nhumirim da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) Pantanal. Neste contexto, ferramentas que possam facilitar o reconhecimento por parte dos produtores de animais Pantaneiros criados extensivamente nas fazendas é fundamental, pois auxiliará na identificação, localização e resgate desses animais. Dessa forma, a aplicação de método de reconhecimento automático utilizando imagens dos animais será uma ferramenta que vem ao encontro do objetivo de conservação da raça. Para isso, foi executado um experimento onde foram aplicadas três arquiteturas de CNN: a DenseNet, a Resnet50 e Inception-Resnet-V ao banco de imagens RecBov51C a fim de classificar cada imagem do animal com sua respectiva identificação. Os resultados deste estudo demonstraram que a aplicação de uma CNN para reconhecimento de bovinos Pantaneiros é viável, visto que todas as redes do experimento apresentaram 99% de acurácia nos testes. Desta maneira, este estudo além de facilitar no resgate do gado Pantaneiro também poderá auxiliar nas demais raças de bovinos criados comercialmente favorecendo a implantação de aspectos da pecuária de precisão.

Palavras-chave: bovino Pantaneiro, pecuária de precisão, reconhecimento de bovinos, CNN, visão computacional.

ABSTRACT

The objective of this study was to apply a Convolutional Neural Network (CNN) to identify the cattle Pantaneira of breed through images. These animals are perfectly adapted to the adverse conditions of the Pantanal and were brought by the Spanish and Portuguese during the colonization of that region. Currently, Pantaneira cattle are being some of their last specimens preserved at the Center of Conservation the bovine Pantaneiro of the Aquidauana (NUBOPAN) on of the State University of Mato Grosso do Sul / Aquidauana University Unit (UEMS / UUA) and at the Nhumirim farm of the Brazilian Agricultural Research Corporation (EMBRAPA) Pantanal. In this context, the tools that allow the recognition of part of Pantaneiro animal producers are created extensively in fundamental farms, as they help in the identification, location and rescue of these animals. In this way, an automatic recognition method application using animal images will be a tool that meets the breed's conservation objective. For this, an experiment was carried out where three CNN architectures were applied: DenseNet, Resnet50 and Inception-Resnet-V to the RecBov51C image bank in order to classify each image of the animal with its respective identification. The results of this study demonstrated that the application of a CNN for the recognition of Pantaneira cattle is feasible, since all the networks in the experiment showed 99% accuracy in the tests. In this way, this study, in addition to facilitating the identify of Pantaneira cattle, may also assist in other breeds of cattle raised commercially, favoring the implantation of aspects of precision livestock.

Keywords: Pantaneiro cattle, precision livestock, individual cattle recognition, CNN, computer vision

CAPÍTULO 1

CONSIDERAÇÕES GERAIS

1. INTRODUÇÃO

No Brasil encontra-se um dos maiores territórios alagados de água doce do mundo denominado Pantanal, que possui um papel de extrema importância na conservação da biodiversidade (WWF, 2015). O Bioma Pantanal está distribuído em 65 por cento no Estado do Mato Grosso do Sul e 35 por cento no Estado de Mato Grosso, formando uma planície inundada no afluente do rio Paraguai (ABREU et al., 2010). A conservação do Pantanal está diretamente ligada ao fortalecimento da produção agropecuária (ABREU et al., 2010). Desta forma, esta região pode ser preservada e enriquecida com ajuda dos bovinos, bem como a agroindústria do Brasil (BARROS NETO, 1979).

No relatório anual da ABIEC (ABIEC, 2019) 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 relatório anual o movimento do agronegócio da pecuária de corte em 2018 gastou com insumo e serviços para produção o montante de R\$ 66,17 bilhões e com um faturamento total na pecuária de R\$ 104 bilhões.

Alguns mercados importadores, por sua vez, exigem a certificação da carne, processo este que requer que toda produção seja inserida em um programa de identificação e registro para acompanhar as informações inerentes ao animal, do nascimento ao consumo do produto final (CÁCERES et al., 2011).

O contexto de Pecuária de Precisão está diretamente inserido através da disponibilização da rastreabilidade bovina, que de acordo com Cáceres et al. (2011) é definida como uma prática de manejo de rebanhos bovinos em que as tecnologias de informação e comunicação (TICs) são usadas para garantir boas práticas de produção de carne. A Pecuária de Precisão proporciona a coleta de dados específicos do indivíduo, por exemplo, áreas de pastagens, histórico de pesagem e avaliação nutricional, de doenças e sanidade animal, como também, a aprovação em todas as etapas de produção da carne (CÁCERES et al., 2011). Dessa forma, com um controle individualizado e específico, é possível aumentar a produtividade minimizando os impactos ambientais e sociais.

Várias formas de rastreabilidade são utilizadas pelo setor pecuário, uma delas é o RFID (*Radio-Frequency IDentification*), uma tecnologia para controlar e

rastrear objetos por meio de sinais de rádio, possibilitando o armazenamento e recuperação de dados (LI; CHEN; LING, 2013). No entanto, o extravio da etiqueta anexada ao animal em forma de brinco e a necessidade de proximidade do animal para leitura dos dados são problemas que podem causar custo adicional e prejudicar a rastreabilidade.

Bowling et al. (2008) apresentam vários métodos que favorecem a rastreabilidade animal, por exemplo, tatuagens, marcas com ferro quente, métodos eletrônicos que implementam tecnologias de identificação por radiofrequência (como bolus do rúmen, marcas auriculares e transponders injetáveis) e métodos biométricos (como retina Digitalização, nariz). Apesar das técnicas serem eficazes dentro de contextos específicos, elas se mostram, em muitos casos, invasivas e podem prejudicar o manejo adequado dos animais contradizendo os princípios da Pecuária de Precisão.

Nesse contexto, propõe-se um método apoiado por visão computacional e algoritmos de aprendizado de máquinas com o intuito de permitir a identificação individual e rastreabilidade de bovinos registrando o histórico, desde seu nascimento até o seu abate.

Espera-se com os resultados deste estudo oferecer subsídios científicos que contribuam para o uso de uma nova tecnologia que possa trazer mais bem-estar aos animais, bem como facilitar a identificação e no futuro resgate de bovinos pantaneiros.

Desta forma, o objetivo deste estudo foi analisar o uso de técnicas de visão computacional para reconhecimento de bovinos Pantaneiros sem a necessidade do manejo dos animais, implantação de brincos ou bolus, ou ainda a marcação a ferro nos bovinos.

O trabalho desenvolvido está dividido em três capítulos: no Capítulo 1 são explanadas as considerações gerais, onde são abordados tópicos como a raça Pantaneira, visão computacional e a identificação de bovinos; no Capítulo 2, o manuscrito mostrando os resultados dos experimentos e finalmente no Capítulo 3 as conclusões obtidas neste estudo.

2. REVISÃO DE LITERATURA

2.1 BOVINO PANTANEIRO

O bovino Pantaneiro é um *Bos taurus taurus*, sendo originário do cruzamento de 11 raças de bovinos europeus no século XVII, sendo seis portuguesas (Alentejana, Algarvia, Barrosa, Mertolenga, Minhota, Mirandesa) e cinco espanholas (Arouquesa, Berrenda Negra/Vermelha, Negra Andaluza, Retinta, Rubia Gallega) (JULIANO et al., 2012). Trazidos pelos desbravadores espanhóis e portugueses que ocuparam a região central da América do Sul. No Pantanal, sob pressão das características ambientais peculiares do bioma, aconteceu ao longo das gerações um intenso processo de seleção natural onde o valor adaptativo dos animais direcionou maior taxa reprodutivas dos bovinos mais adaptados às condições ambientais. Segundo Mazza et al. (1992) os maiores efeitos ocorreram em função as adversidades das condições climáticas, especialmente das enchentes intermitentes, e a ciclicidade da oferta de forrageiras nativa do Pantanal (RODELA, 2007).

Ao longo do tempo, pesquisadores descrevem o gado Pantaneiro com características biotipos e pelagens diferentes. Citado por MAZZA et al., (1994) Lisboa, em 1909, cita como um animal pequeno, de pelagem curta, com coloração vermelha ou castanha, cauda longa, traseira pouco desenvolvida. Citado por MAZZA et al., (1992) Cotrim, em 1913, descreve como um animal pequeno e leve, com cabeça curta e fina, pelagem curta e orelhas pequenas, focinho perto circundado por uma coroa branca, conforme Figura 1.



Figura 1 - Bovino pantaneiro no NUBOPAN. Fonte: Arquivo Pessoal

Por muito anos esses bovinos foram criados livremente, pastoreando a vasta diversidade de pastagens naturais existente neste bioma, que possibilitou a adaptação dos animais mais resistentes (PRIMO, 1992). Posteriormente, a mistura com outras raças principalmente de origem zebuína por meio de cruzamentos absorventes, quase levou ao desaparecimento do gado Pantaneiro. Podem ser descritos como animais de menor estrutura, com o corpo robusto, pelagem multicolorida e chifres de diferentes formatos e tamanhos.

Atualmente, no Estado de Mato Grosso do Sul, a busca pela recuperação da raça está sob responsabilidade de pesquisadores do Núcleo de Conservação de Bovinos Pantaneiros de Aquidauana (NUBOPAN) da Universidade Estadual do Mato Grosso do Sul / Unidade Universitária de Aquidauana (UEMS/UUA), e da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) Pantanal, os quais tem efetuados estudos do potencial zootécnico e disponibilizado a pecuaristas materiais genéticos para continuidade da raça. Existem aproximadamente 500 animais puros da raça Pantaneira domesticados (DANI e OLIVEIRA, 2013), e algumas centenas ainda em estado feral (MARQUES JUNIOR et al., 2012).

Abreu et al. (2005), analisaram as características morfométricas dos bovinos Pantaneiros criados a pasto na região do Pantanal da Nhecolândia, que verificaram valores médios para vacas de $138,44 \pm 5,79$ cm de comprimento corporal, $47,26 \pm 2,33$ cm de comprimento de garupa, $122,67 \pm 3,91$ cm de altura de cernelha, $126,71 \pm 5,28$ cm de largura de garupa, $44,99 \pm 2,74$ cm de abertura do ísquio e $165,66 \pm 7,00$ cm de perímetro torácico. A pesquisa de Rezende et al. (2014) confirma estes números morfométricos adquiridos em novilhas pantaneiras.



Figura 2 – Bovino pantaneiro na propriedade de Thomas Horton.

O bovino pantaneiro possui inúmeras diferenças fenotípicas apresentando 17 tipos de chifres com 7 tipos de cores diferentes. A pelagem também possui grande variação com 47 cores diferentes e mais 14 particularidades, como padrões de listras e pintas. Todavia, a cor predominante baia e castanha, que possibilita a esses animais se esconderem de predadores na paisagem da região Pantaneira (CARVALHO, 2013). Na Figura 2 pode ser visualizado de um touro da raça Pantaneira.

2.2 VISÃO COMPUTACIONAL

Para o sistema visual humano interpretar imagens é natural. O ser humano pode compreender uma estrutura tridimensional, as cores, a profundidade e as emoções nas pessoas à sua volta com aparente facilidade. Assim, forma-se o complexo processo de reconhecimento, em síntese, é realizado pela captura da luz pelos olhos e interpretado pelo cérebro por meio de reconhecimento de padrões, contexto, memória e emoções (FORSYTH; PONCE, 2012).

Em consequência disso, surge a visão computacional que é uma área da Ciência da Computação com a tarefa de processar imagens adquiridas através de uma câmera eletrônica (NIXON e AGUADO, 2002), e emprega um conjunto de técnicas para adquirir, processar e analisar imagens a fim de reproduzir em sistemas a capacidade humana da visão e assim amparar análises do ambiente ou objeto (JAHNE e HAUBECKER, 2000).

A aquisição das imagens, na maioria das vezes é efetuada por meio de dispositivos eletrônicos, como câmeras fotográficas e filmadoras digitais (SOUZA, 2010). Após a aquisição, algumas etapas de processamento são executadas conforme apresentadas na Figura 3, para obter informações da imagem com o intuito de alcançar um determinado objetivo específico, como, o reconhecimento e a classificação de animais.




Figura 3 – Exemplos de processamento de imagens, (a) imagem original, (b) imagem em tons de cinza, (c) imagem com threshold e (d) imagem com detecção de bordas. Fonte: Arquivo Pessoal

Com o objetivo de aumentar a qualidade da imagem, a etapa de pré-processamento torna-se de suma importância para que não haja interferências e imperfeições nas etapas futuras. Nessa etapa, são realizados os processos de redução de distorções e brilho da imagem. Posteriormente, é realizada a segmentação da imagem aplicando técnicas para extração dos objetos de interesse (SZELISKI, 2010). Esses objetos são estipulados com a finalidade e objetivo da aplicação e de seu uso. A próxima etapa é capturar as informações que permitam a definição dos objetos de interesse, desta maneira as características extraídas podem ser reconhecidas matematicamente a fim de classificar objetos similares na imagem (QUINTA, 2013). Finalmente, técnicas de aprendizado de máquina são utilizadas para criar uma base de conhecimento com relação aos objetos de interesses adquiridos na etapa anterior, a fim de que, sejam analisados de maneira automática, permitindo que sua identificação e reconhecimento possa ser feito através do conjunto de objetos existentes (SZELISKI, 2010).

A visão computacional, inteligência artificial, aprendizado de máquina e mineração de dados são áreas da computação que têm se destacado na pesquisa sobre temas relacionados à agropecuária (CÁCERES et al., 2011; BORTH et al., 2014; GORA et al., 2018,). Weber et al. (2020), utilizam-se de técnicas de aprendizado de máquina para comparar medições de biométricas manuais com medições adquiridas através de um sistema computacional. Portanto, esta área da visão computacional depende de muitos parâmetros para configurar técnicas e procedimentos.

2.2.1 Aprendizado de Máquina

A aprendizagem de máquina, do inglês *machine learning*, é uma subárea da inteligência artificial, que se utiliza de técnicas computacionais para o reconhecimento de padrões (NASRABADI, 2007). Essas técnicas computacionais podem ser aplicadas em conjunto com técnicas de visão computacional, buscando resolver problemas comuns aos seres humanos, porém complexos para a computação. Esses problemas na maioria das vezes correspondem a problemas de classificação ou de regressão.

Para apoiar esse processo de aprendizado de máquina, o software WEKA foi desenvolvido em linguagem de programação Java pela Universidade de Waikato¹. Este software permite a aplicação e comparação de várias técnicas de aprendizado de máquina já desenvolvidas e consolidadas. Isso se dá por meio da entrada de um conjunto de dados, que após a aplicação de algoritmos obtém-se a predição de resultados ou padrões. O software permite ainda que se faça validações dos modelos gerados através de métricas como: coeficientes de correlação, precisão, revocação, medida-f, matriz de confusão entre outros (HALL et al., 2009). Como exemplo de algoritmos que aplicam aprendizados de máquina para o processo de classificação pode-se citar KNN, SVM e J48 que são descritos a seguir.

O KNN que é o algoritmo K vizinhos mais próximos (*K-Nearest Neighbors*), apresentado inicialmente por Cover e Hart (1967), é um dos mais simples algoritmos de classificação, porque é baseado através de instância. Assim, para realizar a classificação é necessário o emprego de um conjunto de treinamento, uma vez que não há uma etapa de aprendizado separada da classificação. O algoritmo KNN implementa a classificação a partir da maior aproximação entre os k vizinhos mais próximos. Este algoritmo pode ser utilizado também para regressão, podendo assim calcular a média ponderada das distâncias dos vizinhos mais próximos.

O SVM que são Máquinas de Vetores de Suporte (*Support Vector Machine*), foi inicialmente introduzido por Boser et al. (1992) e Vapnik (1998). Foi desenvolvido por uma técnica que a partir de um dado conjunto de classes cria uma função que possa separá-las. Por exemplo, dada duas classes: boi e fundo,

¹

[<https://www.waikato.ac.nz/>](https://www.waikato.ac.nz/)

aplicando esses algoritmos, a máquina de vetores de suporte separa estes dois conjuntos através de uma margem que divide o plano onde estão plotados os dados de forma que consiga separá-los por classes. Inicialmente criada para tratar de problemas binários, as máquinas de vetores de suporte também podem ser utilizadas para tratar problemas de múltiplas classes.

O J48 é a implementação do c4.5 no WEKA, apresentado em forma de árvore de decisão constituída por um conjunto de dados de treinamento, podendo ser usado para classificar as instâncias no conjunto de teste. A mesma é formada por uma estrutura de regras, onde um problema complexo é decomposto em subproblemas mais simples, sendo composta por nós e folhas de decisão que podem indicar as classes de um determinado conjunto de dados (QUINLAN, 2014). De acordo com este autor, a geração da árvore de decisão é realizada através de um conjunto de dados de treinamento, utilizando a estratégia de divisão e conquista.

2.2.2 Redes Neurais Convolucionais (CNN)

As Redes Neurais Convolucionais são uma classe de rede neural artificial desenvolvida para processar dados em grande escala, e com menor uso de processamento. Uma vez que ocorre a redução do mesmo, por meio do uso de cálculos convolucionais, diferentemente da rede neural artificial que utiliza multiplicação de matrizes no cálculo de pesos de camadas ocultas (GOODFELLOW et al., 2016). Essa intervenção convolucional afeta três aspectos essenciais de um sistema de aprendizado automática: compartilhamento de parâmetros, interações esparsas e representações invariantes (LECUN et al., 2015).

A LeNet foi uma das primeiras CNNs propostas, conforme LeCun et al. (2015), para o reconhecimento óptico de caracteres. A rede neural artificial tradicional visa calcular peso apenas uma vez a cada camada, essas camadas são os níveis do processo de uma rede. Isso significa que todos os pesos de uma camada serão recalculados a cada iteração, implicando em maior quantidade de processamento. Em uma CNN os parâmetros são fixos e o número de conexões neurais reduzidas, portanto, não são mais completamente conectadas, assim o núcleo de uma transação convolucional sempre terá seu tamanho reduzido

comparado com a entrada. Além disso, o compartilhamento de parâmetros também traz a vantagem da representação constante, permanecendo certas características de entrada (GOODFELLOW et al., 2016).

Os elementos de uma camada de convolução são organizados em esquemas de características em que são conectados a fragmentos locais nos mapas de atributos das camadas anteriores através de um conjunto de pesos. Esses pesos, também descritos como banco de filtros, integram a soma local ponderada de cada camada que, por sua vez, passa por uma função de correção a fim de eliminar valores negativos. O banco de filtros pode compartilhar os elementos do mapa de características, mas diferentes mapas de filtros usam diferentes bancos de filtros. A principal função da camada de convolução compreende em detectar conjunções locais de atributos de camadas anteriores, exemplo conforme Figura 4 (LECUN et al., 2015).



Figura 4 – Exemplos de convolução utilizando Filtro de Sobel.

O agrupamento semântico de características ocorre na camada de *pooling*, que é usada para reduzir as dimensões espaciais do pixel. Como as posições relativas das características são constantes, uma identificação confiável de padrões é possível refinando a posição de cada característica (LECUN et al., 2015). Consequentemente, obtém-se uma maior eficiência computacional visto que diminui o tamanho da entrada anterior conservando as características. Ao final da rede, uma simples camada completamente conectada calcula as classificações das classes definindo sua saída (GOODFELLOW et al., 2016). A Figura 5 exemplifica a arquitetura da rede GoogLeNet (2014) da Google, também conhecida como Inception V1. Além desta arquitetura pode-se citar a VGGNet (2014), AlexNet (2012), ResNet (2015) entre outras.




Figura 5 – Ilustração do processo de classificação através da arquitetura LeNet, um modelo CNN. Fonte: Arquivo Pessoal

Então, pode-se afirmar que CNNs tradicionais utilizam associações de blocos de camadas convolucionais acompanhadas por uma função de ativação, possivelmente utilizando-se de um *pooling* (Pool) e posteriormente uma sequência de camadas completamente conectadas (FC), todas seguidas por funções de ativação conforme a Equação 1 e Figura 6 (PONTI e DA COSTA, 2018).

$$\text{CNN} \equiv P \times [C \times (\text{Conv} \rightarrow \text{AF}) \rightarrow \text{Pool}] \rightarrow F \times [\text{FC} \rightarrow \text{AF}]$$

Equação 1 – Função de Ativação de uma CNN




Figura 6 – Ilustração da aplicação Convolução e Pooling em uma modelo de CNN. Fonte: Arquivo Pessoal

Atualmente é possível encontrar diversas bibliotecas de Inteligência Artificial que implementam as principais operações utilizadas nas CNNs. As mais utilizadas são: YOLO (REDMON et al., 2016), Caffe (JIA et al., 2014), MatConvNet (VEDALDI e LENC, 2015), Theano (AL-RFOU et al., 2016), Torch (COLLOBERT et al., 2011) e TensorFlow (ABADI et al. 2015). Essas bibliotecas disponibilizam

execução em múltiplas CPUs ou GPUs, e são usadas por diversas empresas para reconhecimento de objetos, conforme Figura 7.




Figura 7 – Exemplos de reconhecimento de objetos, pessoas e animais feitos por uma CNN. Adaptado de Ren et al. (2015)

2.3 IDENTIFICAÇÃO DE BOVINOS

A identificação dos animais de forma barata, rápida e segura é de extrema importância para grande parte das funcionalidades de um sistema de manejo, o que facilita os processos zootécnicos, as atividades de controle e a contabilidade econômica da produção. Dentre os sistemas de identificação mais utilizados na pecuária brasileira pode-se citar a marcação a ferro quente (elétrico ou fogo), tatuagens, brincos, colares etc. (LOPES, 1997), permitindo assim sua rastreabilidade física.

Assim, é desejável que produtores de bovinos implantem novas formas de gestão e, que façam uso da rastreabilidade como ferramenta dentro do processo de padronização do sistema de produção, permitindo uma maior qualidade e produtividade do rebanho, alcançando novos e competitivos mercados nacionais e internacionais (GIMENEZ, 2015; MORGAN, 2016; SILVA & NÃÃS 2006; REDIVO ET AL., 2012),

A rastreabilidade integra a cadeia produtiva como uma ferramenta para viabilizar a segurança adotada nos processos produtivos, tendo a identificação

como item indispensável, pois possibilita e facilita a coleta e controle dos dados de um indivíduo e do meio em que se insere. Sua implantação, porém, varia de país para país, de acordo com os hábitos alimentares dos consumidores e sua classificação no mercado mundial como importador ou exportador (GIMENEZ, 2015; PINEDA, 2016).

Valle (2007) cita alguns procedimentos em relação a identificação de bovinos, dentre eles a identificação dos animais terá que acontecer no nascimento; seguido por emprego de um sistema de identificação que assegure a verificação e a validação, ao longo do tempo, da totalidade das informações numéricas e descritivas, associadas com o histórico do animal ou do grupo de animais manejados; em seguida o emprego de modelos de identificação que garanta a individualidade, a fixação no animal de forma permanente e inviolável; e finalmente os tipos usuais de identificação para bovinos são os brincos auriculares, tatuagem na orelha, marca a ferro quente e identificadores eletrônicos.

Lopes et al. (2013), fizeram a comparação do custo das vantagens e desvantagens da utilização do brinco auricular convencional e o da arruela auricular eletrônica; e comprovam que o tempo gastos de contenção e implementação, e no tempo de leitura é 30% menor na arruela eletrônica.



Figura 8 – Exemplos de identificação de bovinos. A) Utilização de brincos. B) Marcação a fogo. Fonte: www.google.com



Figura 9 – Exemplos da aplicação da tatuagem em bovinos

Fonte: <https://lifelink.com.br/rastreamento-de-gado/>




Figura 10 – Exemplos de local para marcação corretas a fogo em bovinos. Fonte: Arquivo Pessoal.



Figura 11 – Exemplos de identificações. A) Transponder. B) Brincos. C) Colar. Fonte: Arquivo Pessoal.

Tharwat et al (2015) identificaram bovinos através do espelho nasal, após coleta de imagens utilizando uma câmera fotográfica em 31 bovinos, com

diferentes iluminações, rotações e qualidades das imagens. Posteriormente, foi aplicado técnicas de visão computacional como escala de cinza e algoritmos de classificação como SVM e KNN. Do mesmo modo, Kumar et al. (2017) utilizaram-se de uma câmera fotográfica de 30 megapixel para aquisição de imagem e abordagens de reconhecimento baseadas em aprendizado profunda. Ainda relata um mapeamento sistemático do uso de técnicas computacionais para reconhecimentos de animais.




Figura 12 – Exemplos de identificações através do espelho nasal.

Fonte: Gimenez (2015)

Conforme exemplos de identificação existentes, a implantação de um novo método de identificação de bovinos que não causem maus tratos, e venha colaborar com o bem-estar animal, auxilia na justificativa do estudo e implementação da técnica apresentada, a utilização de imagens com CNN para reconhecimento dos animais.

3. OBJETIVOS

3.1 Objetivo geral

Analisar e desenvolver um método baseado em rede neural convolucional com o intuito de identificar individualmente bovinos da raça Pantaneira.

Assim viabilizar o rastreamento e o registro do histórico de dados referente ao manejo sanitário de cada animal, desde seu nascimento até o abate, e consequentemente, atender às exigências de rastreabilidade exigida por mercados importadores, bem como nichos de mercados mais exigentes como os que estão preocupados com certificação de origem da carne bovina.

3.2 Objetivos específicos

- Criar um banco de imagens de bovinos Pantaneiros.
- Selecionar as principais técnicas ou ferramentas baseadas em visão computacional que permitam implementar software para identificação de bovinos Pantaneiros;
- Testar método ou técnica baseado em visão computacional e aprendizado profundo (*deep learning*) que possa identificar os bovinos;
- Executar experimentos com o método proposto sobre o banco de imagens;
- Transferir o conhecimento obtido por meio de publicações em eventos e revistas técnico-científicos.

4. REFERÊNCIAS

- ABREU, U. G. P.; MCMANUS, C.; SANTOS, S. A. Cattle ranching, conservation and transhumance in the Brazilian Pantanal. *Pastoralism*, v.1, p. 99-114. 2010.
- ABREU, U. G. P.; SANTOS, S. A.; SERENO, J.R.B.; COMASTRI FILHO, J. A.; RAVANELLI, M. S. Caracterización Morfométrica de los bovinos Pantaneiros del núcleo de consevación in situ de Nhumirim. *Archivos de zootecnia*, v.54, n.237, p. 211-16, 2005.
- BOWLING, M. B., PENDELL, D. L., MORRIS, D. L., YOON, Y., KATOH, K., BELK, K. E., & SMITH, G. C. Identification and traceability of cattle in selected countries outside of North America. *The Professional Animal Scientist*, 24(4), 287-294, 2008.
- CARVALHO, G. M. C.; FÉ DA SILVA, L. R.; ALMEIDA, M. J. O.; LIMA NETO, A. F.; BEFFA, L. M. Avaliações fenotípicas da raça bovina Curraleiro Pé-duro do semiárido do Brasil. *Archivos de zootecnia*, v.62, n.237, p. 9-20, 2013.
- DANI, S. U.; OLIVEIRA, M. V. M. Cattle, cheese and conservation. *Nature*, v.502, n.7472, p. 448, 2013.
- GIMENEZ, C. M. Identificação Biométrica de Bovinos Utilizando Imagens do Espelho Nasal. 2015. 114 p. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2015.
- JULIANO, R. S.; ABREU, U. G. P.; ROSA, A. N.; SERENO, J. R. B.; SANTOS, S. A. Conservação de recurso genético animal (RGA): Bovino Pantaneiro. Coleção 500 Perguntas, 500 Respostas, GADO DE CORTE NO PANTANAL. 2ed.Corumbá: Embrapa Pantanal, 2012.
- LECUN, Y.; BENGIO, Y.; HINTON, G., Deep learning. *Nature*, 521(7553), p. 436–444, 2015.
- LOPES, M. A. Informática aplicada a bovinocultura. Jaboticabal: FUNEP, 1997.
- LOPES, M. A.; DAS DORES SILVA, M.; DEMEU, A. A.; GOMIDE, D. R.; BRUHN, F. R. P. Custo da implantação e utilização de dois métodos de identificação de bovinos leiteiros. *Revista Ceres*, v.60, n.6, p. 757-764, 2013.
- MARQUES JUNIOR, H. R.; JULIANO, R. S.; ABDO, Y. Bovino pantaneiro: retrospectiva histórica e fomento à raça. Experiência da parceria entre Embrapa Pantanal, Agropecuária Preservação da Fauna e Universidade Católica Dom Bosco. *Multitemas (UCDB)*, v.2, p. 71-86, 2012.

- MAZZA, M. C. M.; MAZZA, C. A. S.; SERENO, J. R. B.; SANTOS, S. A. L.; MARIANTE, A. S. Conservation of Pantaneira cattle in Brazil. Historical origin. *Archivos de Zootecnia*, v.41, n.154, p. 443-453, 1992.
- NÃÃS, I. A. Uso de t cnicas de precis o na produ  o animal. *Revista Brasileira de Zootecnia*, v.40, p.358-364, 2011.
- MORGAN, A.; WINCK, C. A.; GIANEZINI, M. A influ ncia da rastreabilidade na cadeia produtiva brasileira de carne bovina. *Revista Espacios*, v.37, p. 20, 2016.
- PONTI, M. A.; DA COSTA, G. B. P. Como funciona o deep learning. *arXiv preprint arXiv:1806.07908*, 2018.
- REDIVO, A.; SORNBERGER, G. P.; LIMA, D. C. M.; REDIVO, A. R. O uso da rastreabilidade e certifica  o na produ  o de bovinos de corte: um estudo de caso. XXXII Encontro nacional de engenharia de produ  o. Desenvolvimento Sustent vel e Responsabilidade Social: As Contribui  es da Engenharia de Produ  o. Bento Gon alves, RS, 2012.
- REZENDE, M. P. G.; LUZ, D. F.; RAMIRES, G. G.; Oliveira, M. V. M.  ndices zoot cnicos de novilhas da ra a Pantaneira. *Veterin ria e Zootecnia*, v.21, n. 4, p. 550-555, 2015.
- RODELA, L. G.; QUEIROZ NETO, J. P.; SANTOS, S. A. Classifica  o das pastagens nativas do Pantanal da Nhecol ndia, Mato Grosso do Sul, por meio de imagens de sat lite. *Anais XIII Simp sio Brasileiro de Sensoriamento Remoto*, Florian polis, Brasil, 21-26 abril 2007, INPE, p. 4187-4194, 2007.
- SILVA, K. O.; NÃÃS, I. A. Avalia  o do uso de identificadores eletr nicos em su nos. *Engenharia Agr cola*, Jaboticabal, v.26, n.1, p.11-19, 2006.
- SISBOV. Cartilha do novo Servi o de Rastreabilidade da Cadeia Produtiva de Bovinos e Bubalinos. Bras lia, p. 20. 2006.
- VALLE, E. R. Boas pr ticas agropecu rias - bovinos de corte. Campo Grande, MS. Embrapa Gado de Corte, p. 86. 2007.
- THARWAT, A.; GABER, T.; & HASSANIEN, A.E. Two biometric approaches for cattle identification based on features and classifiers fusion. *International Journal of Image Mining*, v.1, n.4, p. 342, 2015.
- WEBER, V. A. M; WEBER, F. W.; GOMES, R. C.; OLIVEIRA JUNIOR, A. S.; MENEZES, G. V.; BELERE, A. S; ABREU, U. G. P.; PISTORE, H. Prediction of Girolando cattle live weight by means of body measurements extracted from images. *Revista Brasileira de Zootecnia*, v.49. 2020.
- WWF.  reas priorit rias para conserva  o da biodiversidade no Cerrado e Pantanal. Bras lia: WWF-Brasil, p. 128. 2015. ISBN: 978-85-5574-017-6.

CAPÍTULO 2

Reconhecimento de Bovino da raça Pantaneira utilizando visão computacional através da Rede Neural Convolucional

Computers and Electronics in Agriculture

Recognition of Pantaneira cattle breed using Computer Vision and Convolutional Neural Networks

WEBER, F.L.^{1*}; WEBER, V.A.M.²; MENEZES, G.V.³; OLIVEIRA JUNIOR; A.S.³,
ALVES, D.A.¹; OLIVEIRA, M.V.M.¹; MATSUBARA, E.T.¹; PISTORI, H.^{2,3};
ABREU, U.G.P.^{1,4}

¹Programa de Pós-Graduação em Zootecnia, Universidade Estadual de Mato Grosso do Sul, Unidade Universitária de Aquidauana.

Rodovia Aquidauana-UEMS Km 12, Cx Postal 25- CEP 79200-000, Aquidauana- MS, Brazil

²Departamento de Ciências Ambientais e Sustentabilidade Agropecuária, Universidade Católica Dom Bosco, Campo Grande – MS, Brazil

³Faculdade de Computação (FACOM), Universidade Federal do Mato Grosso do Sul, Campo Grande – MS, Brazil

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

* Correspondent author

E-mail: fabrico.weber@gmail.com

Abstract

The objective of this paper is to provide recognition for Pantaneira cattle breed using Convolutional Neural Networks (CNN). Fifty-one animals from the Center of Conservation the Bovine Pantaneiro of the Aquidauana (NUBOPAN) were studied. The center is located in the region Pantanal of Brazil. Four monitoring cameras were distributed in the fences and took 27,849 images of Pataneira cattle breed using different angles and positions. The following three CNN architectures were used for the experiment: DenseNet-201, Resnet50 and Inception-Resnet-V. All networks were submitted to 10-fold stratified cross-validation over 50 epochs. The results showed an accuracy of 99% in all networks, which is encouraging for future research.

Keywords: Pantaneira Cattle, individual cattle recognition, CNN, computer vision

1. Introduction

Pantaneira cattle breed are part of the *Bos taurus taurus* family and descend from 11 European cattle breeds that were crossbred in the seventeenth century. Six of these breeds were Portuguese (Alentejana, Algarvia, Barrosa, Mertolenga, Minhota, Mirandesa) and five were Spanish (Arouquesa, Berrenda Negra/Vermelha, Negra Andaluza, Retinta, Rubia Gallega) (JULIANO et al., 2012). These animals lived alongside the pioneers who occupied the central region of South America. Pantaneira cattle breed were subject to natural selection over several generations due to pressures from the biome's peculiar environmental features in the area. The adaptive value of these animals resulted in a higher reproductive rate of the animals that best adapted to the environmental conditions. This has governed a greater aptitude to different climatic conditions, especially floods, and the cyclicity of native forage supplies in the Pantanal (MAZZA et al., 1992; SNA, 2016).

Researchers have described several animal characteristics including different biotypes and pelages. In 1909, Lisboa described a small animal with short red or brown pelage, a long tail, and an undeveloped back (MAZZA et al., 1994). In 1913, Cotrim described a small animal with a short, thin head. It had a short pelage, small ears and the snout was surrounded by a white crown as shown in Figure 1 (MAZZA et al., 1992).



Figure 1: Pantaneira cattle breed in NUBOPAN. Source: Personal File.

For many years, Pantaneira cattle breed were raised in extensive systems and few zootechnical practices were adopted. This was due to the typical pastoral systems in the Pantanal biome which included large paddocks, a seasonal supply of native pastures, and alternations between periods of flooding and drought (PRIMO, 1992). From mixing with other breeds, mainly zebu cattle, due to disorganized crossbreed, Pantaneira cattle breed almost disappeared.

In order to preserve and insert the breed into regional production systems, the Brazilian state of Mato Grosso do Sul (MS) has recently declared Pantaneira cattle breed as state cultural and genetic heritage. Researchers from the Center of Conservation the Bovine Pantaneiro of the Aquidauana (NUBOPAN), the State University of Mato Grosso do Sul (UEMS), and the Pantanal unit of the Brazilian Agricultural Research Corporation (EMBRAPA) have been working towards *in situ* conservation for the breed. Using genetic studies, researchers seek to provide local farmers with cattle units that will contribute to increasing the size of the population. According to Dani e Oliveira (2013), approximately 500 purebred animals are estimated to exist in properties throughout the Pantanal region.

Researchers analyzed the morphometric features of pasture raised beef cattle in the Pantanal region of Nhecolandia (ABREU et al., 2005). They suggest that Pantaneira cattle have an average body length of 138.44 ± 5.79 cm, 47.26 ± 2.33 cm in rump length, 122.67 ± 3.91 cm in wither height, 126.71 ± 5.28 cm in rump width, 44.99 ± 2.74 cm for ischium opening, and 165.66 ± 7.00 cm for thoracic perimeters. Other research obtained similar results, which demonstrates the morphometry of Pantanal heifers (Rezende et al., 2014).

The Pantaneira cattle have several main differences in breed pattern. This includes 17 types of horn, seven different color types, 47 variations of pelage, and 14 other particularities including stripe patterns. Stripe patterns allow Pantaneira cattle to mimic the patterns found in the landscape of the Pantanal region. This particular feature offers

protection against regional predators (SNA, 2016).

Cheap, fast and safe methods of animal identification are extremely important for many management system functions. These systems facilitate zootechnical processes, control activities, and provide accountability for production. Some of the most common identification systems for Brazilian livestock include hot iron branding using electricity or fire tattoos, earrings, and necklaces (LOPES, 1997). These devices allow cattle to be traced and identified as shown in Figure 2.




Figure 2: Examples of cattle identification. A) Earrings. B) Hot iron branding.

Source: <https://www.comprerural.com>

Cattle production farmers should implement new forms of management to utilize traceability within standard production system processes. This could lead to better quality cattle and higher productivity which would allow farmers to break into competitive national and international markets (GIMENEZ, 2015; MORGAN, 2016; SILVA & NÃÃS 2006; REDIVO ET AL., 2012).

Traceability is part of the production chain and enables safe production processes. Identification is a crucial feature as it facilitates data collection and controls individual cattle. Its implementation, however, varies from country to country in accordance with consumers eating habits and whether the country is classified as an importer or an exporter (GIMENEZ, 2015; PINEDA, 2002).

The following list includes cattle identification procedures (Valle, 2007):

- Animal identification should take place at birth
- An identification system should be implemented that ensures the verification and validation of all numerical and descriptive information associated with the history of the animal or group of animals
- Identification models should be employed that ensure individuality and a permanent and inviolable fixation on the animal

Earrings, ear tattoos, branding, and electronic identifiers are examples of common techniques used to identify cattle (Valle, 2007). Researchers such as Weber et al. (2020), use machine learning techniques to compare manual biometric measurements with measurements acquired through a computer system.

Researchers have conducted various studies using different CNN architectures. Too et al. (2019) created a comparative study of deep learning (DL) models to identify plant diseases. In this study, Too evaluated architectures including VGG 16, Inception V4, ResNet with 50, 101 and 152 layers and DenseNet with 121 layers. The DenseNet architecture obtained best result with an accuracy of 99.75%. Lu et. al. (2018) used various CNN architectures to classify marine organisms including AlexNet, GooLeNet, ResNet50 and ResNet101. These were supported by the deep convolutional filtering network (FDCNet). In this study, ResNet was the architecture that presented the best results with an accuracy of 91%.

The possibility of CNN alterations led Lorencin et al. (2019) to apply three customized CNN architectures to the recognition of marine objects including ships, boats, waves, and marine animals. In this research, a dataset from Google satellite images with 5,608 samples was used. The results obtained from this research showed that CNN recognition of waves and marine animals was accurate to 88.56%. Accuracies of 96.92% for the recognition of garbage and 89.21% for the recognition of oil stains or spills were

also obtained.

These results support the use of DenseNet and ResNet architectures in this study. Further research development was conducted in pig recognition via the face using CNN (HANSEN et. al., 2018). Ten pigs were used in the experiment and formed a dataset with 1,553 images. Hansen achieved an accuracy rate of 96.7% through applying a pre-trained VGG-face model. The CNN architecture used was created by the researchers in this study. Researchers have also used video to generate datasets. For example, Chen et al. (2014) used video to acquire images of 20 wild animal species. A total of 23,876 images were extracted from the video frames. They compared the bag of visual words (BOVW) model with CNN for species recognition.

As described above, several researchers utilized CNNs to identify wild animals, marine objects, pigs and plant diseases. However, there is little research in the identification of cattle using CNN. As such, we propose to address this issue through identifying Pantaneira cattle breed using computer vision and CNNs.

2. Materials and Methods

In this section, we describe how we built the data set, as well as the methods and equipment's used for recording, the choice of CNNs used in this paper, how we divided the data into training and test sets, as well as the hardware used to perform the experiment.

A. Dataset

The images in the dataset were collected between 1:50pm and 4:48pm on January 25, 2019 at the Center of Conservation the Bovine Pantaneiro of the Aquidauana (NUBOPAN) in the State University of Mato Grosso do Sul (UEMS). This is located in the municipality of Aquidauan/MS which is in the Pantanal region of Mato Grosso do Sul,

Brazil. The geographical coordinates were as follows: latitude 20°28' S, longitude 55°48' W and an altitude of 149 meters.

In this study, 51 Pantaneira cattle breed units of both sexes and various ages were used. This is equivalent to 10% of the existing population for this breed. Images were collected using the Digital Video Recorder (DVR) set MIDI MD-1004NS MD-DVR41. The image quality was AHD 720p and the recording capacity was 1Tb. Four cameras were positioned at the exit outlet (see Figure 4) to collect images of the back, profile, side, and face. Images of the cattle's backs were collected using camera 1. This was positioned approximately 2.5 meters high with an inclination angle of 30°. The other cameras were positioned according to the sketch shown in Figure 4 at the same height as the pickets.




Figure 4: Sketch of the picket exit at NUBOPAN. This shows the position of the recording cameras and the cattle flow. Source: Personal File

The videos collected were stored in the DVR, transferred to computers, analyzed, and divided into 212 smaller videos. Images of the cattle were then extracted from these videos. The dataset was formed using 27,849 images of Pantaneira cattle and the number of images obtained varied according to filming to time of each cattle. The dataset includes

partial images of cattle where heads or legs have been occluded. This is show in Figure 5.

Figure 6 shows a selection of images taken of animal No. 3.




Figure 5: Distribution of classes by number of images.



Figure 6: Examples images collected from the videos. 1 (a) back image, 2 (c) left side profile image, 3 (b) right side profile image, and 4 (d) facial image. Source: Personal File.

B. Convolutional Neural Networks

CNNs are an artificial neural network class designed to process large-scale data using less processing. Processing can be reduced using convolutional calculations, unlike the artificial neural network which uses matrix multiplication to calculate hidden layer

weights (GOODFELLOW et al., 2016). Convolutional intervention affects three essential aspects of an automatic learning system: parameter sharing, sparse interactions, and invariant representations. One of the first architectures to use CNN was LeNet (LECUN et al., 2015). This is shown.

DenseNet connects each layer to every other layer. On the other hand, traditional convolutional networks with L layers have L connections. In other words, one connection between each layer and its subsequent layer. Convolutional Dense Networks have $L(L+1)/2$ connections. For each layer, feature maps of all previous layers are used as inputs. Their own feature maps are used as entries in all subsequent layers. DenseNets have several advantages as they alleviate the problem of vanishing gradient information, strengthen the propagation of features, encourage feature reuse, and reduce the number of required parameters.

Simonyan and Zisserman (2014) presented the VGG network architecture. This had 3×3 convolution layers stacked on top of each other and used max pooling to reduce the size of images. This was followed by a softmax classifier which used two fully connected layers with 4096 nodes each. Using this network, however, has its disadvantages. For example, it is slow to train, and the network weights are large in relation to disk usage.

The objective of Inception architecture (SZEGEDY et al., 2014) was to act as a “multilevel extractor” by computing convolutions of 1×1 , 3×3 , and 5×5 within the same network layer. The output of the filters was then accumulated and linked to the measurement of the channel before being sent to the next network layer. Originally, the architecture model was called GoogLeNet. The current name is Inception vN. The term N refers to the version number set by Google in every new release.

ResNet-50 contains a residual learning structure to facilitate the training of considerably deeper networks (HE et al., 2016). The layers were redesigned as residual

functions with reference to layer entries, rather than unreferenced functions. Residual networks are easier to optimize and may generate greater accuracy. In the ImageNet dataset, residual networks with a depth of up to 152 layers were assessed. However, these were less complex. This set of residual networks achieved an error rate of 3.57% in the ImageNet test set. It then received first prize in the ILSVRC, 2015 (RUSSAKOVSKY, et al., 2015).

Data augmentation allows the generation of new images using the original dataset. It is, therefore, better to use a model whose parameters have already been trained with a large dataset. For example, the ImageNet database (DENG et al., 2009), contains the classification of over one million images within 1000 categories. The transfer-learning process can be described as recycling a pre-trained data model through known classes such as ImageNet. To create a new classifier, the last layer must be removed and a new output layer with the desired number of classes must be added. This classifier must be trained from scratch using a random startup.

The partial training of weights imported via transfer-learning must then be fine-tuned. There are several ways to perform this process. These methods include authorizing the algorithm to adjust all network weights based on the new images or freezing some layers and authorizing the algorithm to adjust the parameters for a subset of layers.

Cattle recognition was performed using the CNN algorithm. This aimed to process images collected by an electronic camera (NIXON & AGUADO, 2002) and employed a set of techniques to capture, process and analyze images. The purpose was to reproduce the human capacity of vision in the systems (JAHNE & HAUBECKER, 2000). The images were collected using electronic devices including cameras and digital camcorders (SOUZA, 2010).

Three CNN architectures were selected: DenseNet-201, Resnet50 and Inception-Resnet-V2. They contained the initial weights of the ImageNet image base models through transfer learning. Figure 5 shows the distribution of number of images per class. The potential of Pantaneira cattle recognition was then tested statistically. Each class represented a bovine in the dataset as shown in Figure 7. The following standard parameters were used for the implementations: img width, img height = 256x256 (size of the input image in pixels); lot size = 32; times = 50; SGD optimizer with learning rate = 0.0001 and moment = 0.9. These are similar to the implementations used by Amorim et al. (2019).



Figure 7: Example of the RecBov51C dataset where each cattle represented a class.

C. Separation of training and test set

All networks were trained using the image dataset RecBov51c. This was done using the ImageNet image dataset for transfer learning with fine tuning of 100% and stratified cross-validation of 10 folds over 50 epochs. In order to create the model, the collection was divided into 25,085 images (90% from dataset) used for training and 2,764 images (10% from dataset) used for testing.


D. Hardware

The experiments in this paper were conducted using an Intel® Core™ i5-8300H personal computer. This ran at 2.30 GHz and contained 8GB of RAM, Nvidia GeForce GTX 1050/PCIe/SSE2 graphic cards, and four megabits of internal memory. This computer used the 64-bit Linux Ubuntu 18.04.3 LTS operating system.

3. Results and Discussions

The results obtained using the three architectures were as follows. Resnet50: 99.20% accuracy during training and 99.78% accuracy in the test with a processing time of 54 hours and 04 minutes; InceptionResNetV2: 99.87% accuracy during training and 99.52% in the test with a processing time of 35 hours and 11 minutes; DenseNet: 99.74% accuracy during training and 99.85% in the test with a processing time of 13 hours and 14 minutes. Figures 8, 9, 10, and Table 1 show the results described above.

Figure



8: Training accuracy, testing accuracy and loss results for Resnet50.




Figure 9: Training accuracy, testing accuracy and loss results for InceptionResNetV2.




Figure 10: Training accuracy, testing accuracy and loss results for Densenet201.

Table 1: Accuracy results in Test and Training.

Model	Accuracy Training (%)	Accuracy Test (%)	Duration of training process	Duration of test process
ResNet50	99.20	99.78	52h:41m	2h:20m
InceptionResNetV2	98.87	99.52	29h:29m	6h:42m
DenseNet201	99.74	99.85	7h:26m	5h:48m

From epochs 37th onwards, all architectures will have stabilization of error reductions in the test set, from one epochs to another, less than 0.000007277%, according to Figures 8, 9 and 10. It can also be seen that the difference begins to narrow before, epoch 34th for the InceptionResNetV2 architecture (Figure 9) and epoch 30th for the DenseNet-201 architecture (Figure 10). Thus, 50 epochs seem to be sufficient to verify the generalization in both architectures.

Figures 11, 12 and 13 show the subset of the confusion matrix only with the errors in the tenth folder of the neural network model. Figure 11 shows that the ResNet50 architecture, which had the greatest accuracy, incorrectly classified seven images. They are distributed in an image incorrectly classified by class: 30, 36, 39, 40, 48, 50, and 52. In classes 36 and 39, the incorrect image classifications were most likely due to the incompleteness of the images as they did not show a complete representation of the animals. In addition, this could be due to the dark pelages which appear similar as shown in Figure 14. However, according to Figure 12, which shows the ResNet50 architecture, there were 19 incorrect classifications. These were distributed in classes 36 and 48. This corresponds to the accuracies of 77.3% and 90.6%, respectively. Figure 13, which shows the InceptionResNetV2 architecture, contains 24 errors. This is the highest number of incorrect classifications within the study. The classes with the highest incorrect

classifications were numbers 24 and 37. These contained accuracies of 96.6% and 90.9%, respectively. Therefore, all classes obtained a high number of correct answers. None of the proposed models were statistically different from the others. This was tested using the ANOVA hypothesis test in RStudio. The p-values < 0.05 found for each metric were reported to rule out a null hypothesis. The standard deviation was 0.29 among the models as shown in Table 1.

	2	3	36	39	40	47	48	49	50	52	53
2	133	1									
30		23									
36			30	1							
39			1	21							
40					18						
47						30	1				
48							16		1		
49					1			40			
50									27		
52										49	
53										1	48
	2	30	36	39	40	47	48	49	50	52	53

Figure 11: Error confusion matrices in DenseNet20 neural network architecture.




Figure 12: Error confusion matrices in ResNet50 neural network architecture.




Figure 13: Error confusion matrices in InceptionResNetV2 neural network architecture.



Figure 14: Image a) class 36 cattle unit. Image b) class 39 cattle unit.

Using the data obtained from the confusion matrix, the following items were calculated: accuracy (using the percentage of correctly calculated samples), precision (the classifier's capacity not to label a negative example as positive), recall (the classifier's capacity to present correct classifications for all positive samples), and F1-score (the harmonic mean of precision and recall) this is shown in Tables 2 and 3 (Sokolova & Lapalme, 2009).

Table 2: Accuracy with cross-validation result and standard deviation by model.

Model	Accuracy with cross-validation (%)	Standard Error
ResNet50	99.55	0.1507
InceptionResNetV2	99.15	0.2811
DenseNet201	99.86	0.0426

Table 3: Precision, recall, and F1-score by model.

Model	Precision	Recall	F1-score
ResNet50	0.99	0.99	0.99
InceptionResNetV2	0.99	0.99	0.99
DenseNet201	1.00	1.00	1.00

One further crucial factor is the processing time. Processing time is associated with the training efficiency of the current set or a new dataset alongside which processing capacity equipment is available to train the network. On the other hand, this method can process large volumes of records with low computational costs.

The researchers that performed the facial recognition of cattle using images obtained an accuracy of 95% (Kumar et al., 2016). Therefore, the research results in this paper are close to the values obtained by Kumar et al.

In sum, the results indicate that it is possible to accurately recognize Pantaneira cattle units individually in a noninvasive way. This can be achieved by capturing images from different positions. Using a trained CNN, we achieved a 99% accuracy in 2,764 images of 51 cattle units.

With regard to future work, capturing images from different angles might improve the accuracy of individual identification. As such, further research should be conducted into identifying which angles are necessary for bovine identification. This would also reduce the number of images required for implementation into a system.

4. Conclusion

The paper used three neural network architecture models to identify Pantaneira cattle breed. The videos captured via four monitoring cameras were used to extract images containing the subjects of interest: the back, profile, side, and face. In the classification stage, three well-known DL models were compared: InceptionResNetV2, Resnet-50, and DenseNet201. The results showed that the models used in this research achieved good results with a 99.86% degree of accuracy. The results indicated that the models assessed may support researchers and farmers in the recognition of Pantaneira cattle. In future, this method may contribute to better animal welfare. Furthermore, CNN models could form the basis of a computer vision system that automatically identifies animals.

References

1. JULIANO, R. S.; ABREU, U. G. P.; ROSA, A. N.; SERENO, J. R. B.; SANTOS, S. A. “Conservação de recurso genético animal (RGA): Bovino Pantaneiro”. Coleção 500 Perguntas, 500 Respostas, GADO DE CORTE NO PANTANAL. 2ed. Corumbá: Embrapa Pantanal, 2012.
2. MAZZA, M.C.M.; MAZZA, C.A.S.; SERENO, J.R.B.; SANTOS, S.A.L.; MARIANTE, A.S., “Conservation of Pantaneira cattle in Brazil. Historical origin”. *Archivos de Zootecnia*, Vol. 41, No. 154, pp. 443–453, 1992.
3. SNA - Sociedade Nacional de Agricultura, 2016. Ameaçado de extinção, gado Pantaneiro é alvo de pesquisas em Mato Grosso do Sul. Disponível em :<<https://www.sna.agr.br/ameacado-de-extincao-gado-pantaneiro-e-alvo-de-pesquisas/>> Acessado em: 31/07/2019.
4. MAZZA, M.C.M.; MAZZA C.A.S.; SERENO, J.R.B.; SANTOS, A.S.; PELLEGRIN, A.O. Etnobiologia e conservação do bovino pantaneiro. Corumbá: EMBRAPA, pp. 61, 1994.
5. PRIMO, A.T., 2004. América: conquista e colonização: a fantástica história dos colonizadores ibéricos e seus animais na era dos descobrimentos. 1º ed. Movimento. Porto Alegre, BR.
6. DANI, S. U.; OLIVEIRA, M. V. M. Patents: Universities are right to partner. *Nature*, v. 502, n. 7472, p. 448, 2013.

7. ABREU, U.G.P.; SANTOS, S.A.; SERENO, J.R.B.; COMASTRI-FILHO, J.A.E RAVANELLI, M.S., Caracterización morfométrica de los bovinos Pantaneiros del núcleo de conservación in situ de Nhumirim. Archivos de Zootecnia, Vol. 54, pp. 211–216, 2005.
8. REZENDE, M.P.G.; LUZ, D.F.; RAMIRES, G.G.; Oliveira, M.V.M., Índices zootécnicos de novilhas da raça Pantaneira. Veterinária e Zootecnia, Vol. 21, No. 4, pp. 550–555, 2015.
9. LOPES, M.A. *Informática aplicada à bovinocultura. Jaboticabal*: FUNEP, 1997.
10. GIMENEZ, C.M., 2015. Identificação Biométrica de Bovinos Utilizando Imagens do Espelho Nasal. 114 p. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga.
11. MORGAN, A.; WINCK, C.A.; GIANEZINI, M., A influência da rastreabilidade na cadeia produtiva brasileira de carne bovina. Revista Espacios, Vol. 37, pp. 20, 2016.
12. SILVA, K.O.; NÃÃS, I.A., Avaliação do uso de identificadores eletrônicos em suínos. Engenharia Agrícola, Jaboticabal, Vol. 26, No. 1, pp.11–19, 2006.
13. REDIVO, A.; SORNBERGER, G.P.; LIMA, D.C.M.; REDIVO, A.R., 2012. O uso da rastreabilidade e certificação na produção de bovinos de corte: um estudo de caso. XXXII Encontro nacional de engenharia de produção. Desenvolvimento Sustentável e Responsabilidade Social: As Contribuições da Engenharia de Produção. Bento Gonçalves, RS.
14. PINEDA. N., 2002. Rastreabilidade: Uma necessidade do mundo globalizado. Disponível em: <<http://www.beefpoint.com.br/cadeia-produtiva/especiais/rastreabilidade-uma-necessidade-do-mundo-globalizado-6425/>>. Acesso em: 30/07/2019.

15. VALLE, E.R. Boas práticas agropecuárias - bovinos de corte. Campo Grande, MS. *Embrapa Gado de Corte*, pp. 86, 2007.

16. WEBER, V. A. M; WEBER, F. W.; GOMES, R. C.; OLIVEIRA JUNIOR, A. S.; MENEZES, G. V.; BELERE, A. S; ABREU, U. G. P.; PISTORE, H. “Prediction of Girolando cattle live weight by means of body measurements extracted from images”. *Revista Brasileira de Zootecnia*, v.49. 2020.

17. TOO, E.C.; SAM, L.Y.; NJUKI, S.; YINGCHUN, L. “A comparative study of fine-tuning deep learning models for plant disease identification.” *Computers and Electronics in Agriculture*, Vol. 161, pp. 272–279, 2019.

18. LU, H., LI, Y., UEMURA, T., GE, Z., XU, X., HE, L., KIM, H. “FDCNet: filtering deep convolutional network for marine organism classification”. *Multimedia tools and applications*, Vol. 77, No. 17, pp. 21847–21860, 2018.

19. LORENCIN, I., ANĐELIĆ, N., MRZLJAK, V. & CAR, Z. “Marine Objects Recognition Using Convolutional Neural Networks”. *Nase More*, 66 (3), pp. 112–119. 2019.

20. 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”. *Computers in Industry*. Vol. 98, pp. 145–152, 2018.

21. CHEN, G.; HAN, HE, T.X.; KAYS, Z.; R.; FORRESTER, T. Deep convolutional neural network-based species recognition for wild animal monitoring. 2014 IEEE International Conference on Image Processing (ICIP), Paris, pp. 858–862, 2014.

22. GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. Cambridge, Massachusetts: MIT Press, 2016.
23. LECUN, Y.; BENGIO, Y.; HINTON, G., Deep learning. *Nature*, 521(7553), pp. 436–444, 2015.
24. SIMONYAN, K., ZISSERMAN, A. “Very deep convolutional networks for large-scale image recognition”. arXiv preprint arXiv: 1409.1556, 2014.
25. SZEGEDY, C.; IOFFE, S.; VANHOUCKE, V.; ALEMI, A. A. (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. *In Thirty-first AAAI conference on artificial intelligence*.
26. HE, K.; ZHANG, X.; REN, S.; SUN, J., 2016. Deep residual learning for image recognition: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778.
27. RUSSAKOVSKY, O; Deng, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATY, A., 2015. “ImageNet Large Scale Visual Recognition Challenge”, *International Journal of Computer Vision (IJCV)*.
28. DENG, J.; DONG, W; SOCHER, R.; LI, L.J.; LI, K. AND FEI-FEI, L. “ImageNet: A LargeScale Hierarchical Image Database.” *CVPR09*, 2009.
29. NIXON, M.S.; AGUADO, A.S., 2002. Feature Extraction and Image Processing. Newnes, Central Tablelands.
30. JAHNE, B.; HAUBECKER, H. *Computer vision and applications: a guide for students and practitioners*. Academic Press, 2000.

31. SOUZA, K.P., 2010. Aplicação de modelos de markov ocultos na obtenção de taxas de mortalidade das larvas do mosquito da dengue. Tese (Mestrado), Faculdade de Computação, Universidade Federal de Mato Grosso do Sul.
32. AMORIM, W.P.; TETILA, E.C.; PISTORI, H.; PAPA, J.P. “Semi-supervised learning with convolutional neural networks for UAV images automatic recognition.” *Computers and Electronics in Agriculture*. Vol. 164, pp. 104932, 2019.
33. SOKOLOVA, M.; LAPALME, G., “A systematic analysis of performance measures for classification tasks.” *Inf. Process. Manage.* 45 (4), pp. 427–437, 2009.
34. KUMAR, S.; TIWARI, S.; SINGH, S.K. Face Recognition of Cattle: Can it be Done? *Proceedings of the National Academy of Sciences, India Section A: Physical Sciences*, 86(2), pp. 137–148, 2016.

CAPÍTULO 3

CONSIDERAÇÕES FINAIS

CAPÍTULO 3 – CONSIDERAÇÕES FINAIS

A identificação de bovinos é uma prática que auxilia a cadeia produtiva da carne, desde o nascimento até o abate dos animais nos frigoríficos. No entanto os métodos existentes carecem de práticas, que forneçam as mesmas vantagens, garantam o bem-estar animal e contribuam para o acompanhamento de informações: assim como preconiza a pecuária de precisão. A utilização de um método menos invasivo, como do experimento, relatado no Capítulo 2, para a identificação de bovinos Pantaneiro por meio de imagens, com apoio da visão computacional e das redes neurais convolucionais, pode contribuir para alcançar estes objetivos.

Como limitação do trabalho, pode-se citar o conjunto pequeno de amostras, pois a coleta das imagens ocorreu em apenas um dia, não possibilitando diferentes ambientes, posição do sol ou pouco iluminação, o que facilitaria a generalização do modelo gerado. A necessidade de retreinar a rede a cada nova aquisição de um bovino por uma propriedade ou a melhor hora para coletar imagens de bezerros também deve ser analisado. A verificação se há necessidade de exclusão das imagens, que correspondem às classes, de animais que são extraviados, abatidos, morrem ou são comercializados, possibilitando a liberação de espaço em disco e até ganho na utilização da memória e de velocidade de processamento para geração de novos modelos também constituem limitações.

Trabalhos futuros devem abordar raças mais usadas por determinadas finalidades, como é o caso do Nelore e Angus, que são referências para criadores de gado de corte. Também há necessidade de criação de bancos de imagens mais robustos e quem sabe automatizados. Adicionalmente, executar trabalhos como levantar requisitos junto a produtores e demais *stakeholders* para identificar carências ou necessidades, desenvolver o software com o conhecimento adquirido, produzir equipamentos e estratégias de coletas, testar a ferramenta (hardware + softwares) em propriedades de tamanho e finalidades distintas.

O apoio da tecnologia a atividades da pecuária, pode auxiliar e estimular pesquisas envolvendo equipes multidisciplinares e permitir gerar ferramentas, que possam fornecer ao setor produtor de bovinos informações mais rápidas e

consistentes sobre os animais, permitindo assim uma melhor gestão em curto, médio e longo prazo.