

DESENVOLVIMENTO DE SOFTWARE PARA CONTAGEM DE GADO BOVINO USANDO REDES NEURAS CONVOLUCIONAIS

Antônio de Freitas Valle Neto*
Fábio Paulo Basso**
Marcelo Caggiani Luizelli***

RESUMO

Este trabalho apresenta o desenvolvimento de um software utilizando redes neurais convolucionais, CNN, para a contagem de gado bovino a partir de imagens obtidas a campo, com a utilização de drones por sensoriamento remoto. As imagens foram feitas em propriedades da região onde se localiza esta universidade. A proposta é de um software que sirva de base para a criação de uma ferramenta, para ser usada por produtores rurais de Alegrete e região, tornando mais ágil este processo nas diferentes unidades de produção.

Palavras-chaves: Redes Neurais Convolucionais; Sensoriamento remoto; .

ABSTRACT

This work presents the development of software using convolutional neural networks, CNN, to count cattle from images obtained in the field, using drones for remote sensing. The images were taken on properties in the region where this university is located. The proposal is for software that serves as a basis for creating a tool, to be used by rural producers in Alegrete and the region, making this process more agile in different units of production.

Keywords: Convolutional Neural Networks; Remote sensing.

1. INTRODUÇÃO

A Pecuária desempenha um papel importante na sociedade e é uma das principais fontes de alimentos do mundo. Com o aumento da demanda por alimentos, pesquisas que visem o aumento da produtividade nas atividades do pecuarista são bem-vindas. Para auxiliar a produção, a pecuária de precisão faz uso de tecnologias de apoio ao produtor, visando maior produtividade e qualidade das commodities do agro negócio. Neste contexto, este trabalho busca o desenvolvimento de um instrumento que atenda demandas do setor pecuário, visando otimizar o manejo e a utilização dos insumos agropecuários, proporcionando maior eficiência econômica (ROCHA et al., 2014).

Nesse sentido, uma demanda apontada dos pecuaristas é a contagem dos animais no campo, o que permite o aumento do controle, melhor gestão e consequente

* Aluno do Curso de Ciência da Computação da Universidade Federal do Pampa, Alegrete, Rio Grande do Sul, Brasil
E-mail: antoniovalle.aluno@unipampa.edu.br

** Orientador, Professor do Curso de Engenharia de Software da Universidade Federal do Pampa, Alegrete, Rio Grande do Sul, Brasil, E-mail: fabio basso@unipampa.edu.br

*** Co-Orientador, Professor do Curso de Engenharia de Software da Universidade Federal do Pampa, Alegrete, Rio Grande do Sul, Brasil, E-mail: marceloluizelli@unipampa.edu.br

produtividade. Este Trabalho de Conclusão de Curso II apresenta o desenvolvimento de um software utilizando processamento digital de imagens e redes neurais para contagem de animais a campo.

O uso de drones permite o acesso remoto as diferentes sub divisões sem que haja a necessidade de juntar o rebanho para fazer a contagem, evita a movimentação dos animais reduzindo perdas, e proporciona um ganho significativo em termos de tempo e agilidade.

É sempre importante para a universidade a produção de trabalhos que estejam em sintonia com as demandas da comunidade na qual estão inseridos, contribuindo para o desenvolvimento desta região. Como aluno, faço parte do campus Alegrete da Universidade Federal do Pampa, Unipampa, região com um perfil fortemente ligado a agricultura e pecuária, sendo a principal fonte de produção de bens e de arrecadação por parte dos órgãos públicos locais. Neste sentido o trabalho está em sintonia com as demandas das comunidades regionais.

O estudo tem por objetivo a busca de um software, envolvendo diferentes áreas do conhecimento que incluem: sensoriamento remoto com uso de veículos não tripulados, drones, processamento de imagens obtidas a campo, uma área da Inteligência Artificial denominada aprendizado profundo, outra denominada de redes neurais convolucionais. O objetivo é desenvolver um instrumento que possa atender uma necessidade do dia a dia das propriedades para um maior controle em suas atividades.

Dentro disso, buscou-se fazer a tomada das imagens o mais próximo possível do ambiente natural real, utilizando áreas de propriedades locais que trabalham com pecuária bovina. Também é um objetivo levar em conta as variações de vegetação e relevo na construção do software, sendo representativo da região.

Este trabalho está organizado como segue. A Seção 2 apresenta a metodologia do trabalho e exemplifica o contexto de estudo; A Seção 3 discute os trabalhos relacionados; A Seção 4 descreve a proposta técnica para contagem de gado no campo, completada na Seção 5 com um estudo de avaliação. Por fim, a Seção 6 apresenta as conclusões.


2. METODOLOGIA DE TRABALHO

Primeiramente foram definidas as áreas das duas propriedades utilizadas no experimento. Em cada uma delas, foram escolhidas duas ou três sub divisões representativas do local e com facilidade de acesso, o número de idas nessas duas localidades foi de 12 vezes. A Tomada de fotos foi feita manualmente, a seguir é determinada a altura de voo entre 30 a 60 metros, a posição da câmera, colocada no sentido perpendicular ao solo, e o deslocamento em direção aos agrupamentos de bovinos visualizados, sempre procurando diferentes grupos, com diferentes indivíduos.

Terminada esta etapa, um número em torno de 2000 fotos foi coletado. Com a finalidade de aumentar número de fotos disponíveis, cada foto passa por um processo de sub divisão da seguinte forma: cada linha da foto é dividida em 4 fotos menores; o mesmo processo é feito para cada coluna; assim, cada foto gera 16 novas fotos, conforme ilustra a Figura 1.

A Figura 2 apresenta resultados da próxima etapa: a organização das classes em pastas. Neste trabalho foram definidas 3 classes: sem bovinos, com 1 bovino presente

Figura 1 - Divisão da imagem original em 16



na imagem e com 2 bovinos presentes. Na sequência, o montante das fotos são sub divididas e multiplicadas, posteriormente é feita a classificação manual, quando então a imagem é visualmente classificada e colocada nas respectivas pastas. Posteriormente, são feitos os testes com os diferentes parâmetros, então os resultados obtidos são apontados numa tabela de resultados.

Figura 2 - Classes utilizadas



classes "zero", "um" e "dois"

Algumas considerações: em relação a altura do drone, resolveu-se padronizá-la entre 50 e 60 metros. Isso proporciona menos animais que aparecem com os corpos cortados (i.e., faltando pedaços nas bordas). Por outro lado, alturas muito elevadas, acima de 80 metros, diminuem os detalhes para uma melhor identificação nos animais.

Outro parâmetro importante foi a posição vertical fixa da câmera. Esta posição perpendicular em relação ao solo, comum em aplicativos de planos de voo utilizados em topografia, permite o estabelecimento de rotas sistemáticas em áreas delimitadas, como poteiros e piquetes, possibilitando voos automatizados.

3. TRABALHOS RELACIONADOS

O trabalho (BEDOYA; CASTRILLÓN, 2019) foi desenvolvido na Colômbia e utiliza redes neurais convolucionais juntamente com a rede neural convolucional de alto desempenho (YOLO V2). Este trabalho também é um estudo aplicado no gado bovino, mas com foco em segurança. O trabalho obteve resultados positivos e demonstrou que a tarefa de identificação do gado em espaços abertos pode ser usado usando técnicas de aprendizado profundo, com um desempenho aceitável.

O estudo de (NALESSO, 2015) também realiza a contagem de gado bovino utilizando técnicas de processamento de imagens com filtros. Ele é aplicado em gado da

raça Nelore, cuja característica da pelagem é de coloração predominantemente branca. Os autores relatam ter usado esta característica com sucesso para a identificação e contagem do Gado. Com uma taxa de acerto de 97,03% os testes realizados demonstraram que o sistema proposto pode ser uma alternativa que pode ser inserida no ambiente de criação de gado.

Em outro trabalho similar (RIBEIRO; GUEDES; BARBIERI, 2019), também usando técnicas de processamento de imagens, os autores desenvolveram um programa que aplica algoritmos de Visão Computacional na contagem de gado por meio de imagens aéreas coletadas em bancos de imagens públicas. O trabalho utiliza técnicas com o uso de filtros de cinza, filtros de suavização, Limiarização de imagens, transformações morfológicas, detectores de objetos binários, e também abordagens por segmentação. Neste trabalho, como o gado apresentava uma variação de coloração grande, o sucesso na identificação dos animais ocorreu pela separação das raças. Para os animais de pelagem branca, o índice de acertos foi de 92,4%. Já para os animais com coloração escura, o índice de acerto caiu para 34,8%.

A variação de coloração é um fator que atrapalha os algoritmos de contagem de gado. Portanto, estudos dirigidos para considerar estas variações são bem vindos na literatura da área. É isto que torna o presente trabalho singular: consideramos animais de diversas colorações de pelagem para o desenvolvimento da solução de contagem de gado no campo.

4. PROPOSTA TÉCNICA PARA CONTAGEM DE GADO

O estudo foi realizado em áreas de duas propriedades no município de Alegrete, Rio Grande do Sul, com a utilização de um drone na tomada de fotos. Este experimento ocorreu no primeiro semestre de 2020.

4.1. DESCRIÇÃO DAS ÁREAS UTILIZADAS

A primeira área de estudo é a fazenda Marmota, situada no subdistrito do Pai Passo, município de Alegrete, RS, a aproximadamente 40 km da sede do município, na direção sul. A propriedade possui uma extensão total de cerca de 900 hectares e está localizada junto ao arroio Pai Passo, com uma área de mata ciliar ao redor. A base econômica da fazenda envolve a pecuária de corte, bem como o cultivo de arroz e soja.

A pecuária de corte na fazenda Marmota tem como foco a produção de terneiros. Nos últimos anos, têm sido introduzidos touros das raças Hereford e Braford, que apresentam uma coloração marrom com detalhes em branco no rosto e barriga. Apesar disso, o rebanho em geral ainda exibe uma grande variedade de colorações de pelagem, não apresentando um padrão definido para essas raças. Esse aspecto é relevante, especialmente considerando que a classificação será realizada por meio de imagens.

A vegetação nos poteiros utilizados, principalmente nos campos nativos da região, é composta por gramíneas típicas. A presença abundante de árvores em quase todas as subdivisões pode ser atribuída à influência da proximidade com a mata do arroio Pai Passo. Essa característica pode representar um desafio para a identificação de animais no contexto do experimento. Além dos campos nativos, áreas com pastagens cultivadas de inverno, como misturas de azevém (*Lolium multiflorum*) e aveia

Figura 3 - Fazenda Marmota




Localização em vermelho Marmota 30° 5'2.13"S , 55°51'33.74"O

(Avena sativa), foram utilizadas. O solo da propriedade apresenta uma coloração marrom avermelhada nas áreas mais altas e tonalidades mais acinzentadas nas partes baixas de várzea, tendendo a uma coloração preta.

A segunda área de estudo é a fazenda Centelha, localizada no município de Alegrete, a aproximadamente 65 km a oeste, próxima à divisa com Uruguai. Em termos de vegetação, os campos assemelham-se aos da área anterior, com uma menor presença de árvores. Assim como na fazenda Marmota, foram utilizadas áreas com pastagens cultivadas de inverno. O solo nessa região é de origem basáltica, apresentando coloração preta, especialmente quando a umidade do solo é mais elevada.

Figura 4 - Fazenda Centelha



Localização Centelha 29°47'43.04"S , 56°19'29.72"O

Quanto ao rebanho é mais variado em termos de coloração das pelagens, devido ao compartilhamento do uso desta área por proprietários diferentes.

4.2. DESCRIÇÃO DO EQUIPAMENTO UTILIZADO

O equipamento de sensoriamento remoto utilizado envolve 1 drone, 1 notebook para o processamento do algoritmo com as fotos obtidas:

Drone Phantom 4 (DJI):

- modelo: Advanced
- Câmera 20 MP 1 polegada CMOS
- Armazenamento em cartão de memória
- Bateria 5870 mAh 4S LiPo
- Tecnologia de navegação, GLONASS E GPS
- fotos contém informações de localização geográfica

Figura 5 - Imagem do drone frente e traseira



Notebook:

- Processador intel core(TM) i7-7500 2° ger.
- CPU 2.70 GHZ a 2.90 GHZ
- RAM 16 GB
- Placa de vídeo GEFORCE 940 MX 11 cuda core

4.3. ORGANIZAÇÃO DAS FOTOS

As fotos foram obtidas no período entre abril e junho de 2020. Foram o resultado de uma série de visitas a estas propriedades, sendo feito os apontamentos dos dados de número de fotos, temperatura, hora, presença ou não de sol, altura de vôo, que eram codificados junto com uma numeração no conjunto de fotos daquele dia. Para tanto um código em python foi feito para auxiliar a organização das pastas.


Neste exemplo:

- GB é o distrito do Guassu Boi, Centelha

Figura 6 - Codificação das fotos



GB50CN80



GB50CN107

- 50 é a altura de vôo em metros
- CN é o tipo de vegetação campo nativo
- o restante a numeração na pasta

Foram realizadas 12 visitas, o que resultou num montante aproximado de 2000 fotos.

4.4. DESCRIÇÃO DO SOFTWARE UTILIZADO

O software foi escrito em python, utilizando as bibliotecas tensorflow e keras na implementação do código da rede neural convolucional. Neste estudo, as bibliotecas acima citadas abstraem cálculos matemáticos referentes as diferentes camadas em funções onde só o que é necessário é preencher parâmetros tais como número de neurônios, tipos de funções de ativação, entre outros, e assim toda a sequência da rede neural é descrita em poucas linhas. A figura 7 mostra uma das configurações utilizadas no experimento.

Figura 7 - Sequência abstraída de uma rede CNN

```
# Inicializando a CNN
classificador = Sequential()
# Step 1 - Convolução
classificador.add(Conv2D(32, (3, 3), input_shape = (128, 128, 3), activation = 'relu'))
# Step 2 - Pooling
classificador.add(MaxPooling2D(pool_size = (2, 2)))
# Adicionando uma segunda camada convolucional
classificador.add(Conv2D(32, (3, 3), activation = 'relu'))
classificador.add(MaxPooling2D(pool_size = (2, 2)))
# Step 3 - Flattening
classificador.add(Flatten())
# Step 4 - Full connection
classificador.add(Dense(units = 128, activation = 'relu'))
classificador.add(Dense(units = 3, activation = 'sigmoid'))

classificador.compile(optimizer = 'adam', loss = 'binary_crossentropy', metrics = ['accuracy'])
outputs = [layer.output for layer in classificador.layers]
```

O código apresenta a definição e estruturação de uma rede neural convolucional (CNN) para processamento de imagens. Durante a experimentação, várias configurações foram testadas para otimizar a acurácia e evitar o overfitting. Nesta sequência temos a inicialização da sequência, a definição de uma camada convolucional, uma de pooling, outra convolucional, outra de pooling, uma de flaten, e duas camadas na rede neural propriamente dita, cada uma delas com seus respectivos parâmetros. Finalmente em uma linha de comando para a compilação, processamento, ali também parâmetros são escolhidos.

5. RESULTADOS OBTIDOS

Para o acompanhamento dos resultados foi criada uma tabela de registro dos processamentos na rede neural, CNN, os seus diferentes parâmetros e resultados obtidos, a figura 8 mostra uma destas tabelas que obteve os melhores resultados utilizando a função de ativação ReLU (rectified linear unit):

Figura 8 - Tabela de testes

c	Data	ntr	ntr	Categorias	CO	NN	FA	T	Ep	st	Loss	accT	loss	accV
1	6/5	750	250	Campo/sois	1	128	Relu	300	20	1000		0.9014		0.6723
2	9/5	750	250	Campo/sois binary_crossent	1	128	Relu	180	20	1000	0.23	0.9007		0.6305
3	9/5	1600	400	Campo/sois categorical	1	128	Relu	320	20	2000	0.199	0.9191		0.7038
4	9/5	1600	400	Campo/boi categorical	2	256 128	Relu	36-	20	2000	0.190	0.9217	0.8815	0.7323
5	14/5	1200	300	Campo/um/dois categorical	2	128	Relu	420	20	1200	0.2884	0.8769	0.9780	0.7653
6	15/5	2000	500	Campo/um/dois categorical	2	128	Relu	570	30	2530	0.1266	0.9537	0.5601	0.8513
7	18/5	2000	500	Campo/um/dois categorical	2	256 128	Relu	900	30	2530	0.0828	0.9722	1.2522	0.8286
8	19/5	2400	600	Campo,um, dois categorical	2	512 128	Relu	1700	30	3000	0.0403	0.9874	1.4101	0.8699
9	20/5	2400	600	Campo,um, dois categorical	1	512	Relu	1600	30	3000	0.0440	0.9871	0.7960	0.8681
10	24/5	1200	300	Campo/um/dois categorical_cros	1	128	Relu	420	20	1200	0.1571	0.9417	0.2250	0.8133
11	24/5	1200	300	Campo/um/dois categorical_cros	2	256 128	Relu	420	20	1200	0.1571	0.9417	0.2250	0.8133
12	26/5	3200	800	Campo/um/dois categorical_cros	2	256 64	Relu	1200	20	1200	0.1571	0.9710	0.2250	0.9261

A tabela acima apresenta um conjunto de parâmetros que tiveram variações de valores para a avaliação da acurácia obtida nos treinos e nos testes: Número de fotos para treino, número de fotos para teste, tipo de classificação executado pelo modelo, número de camadas da rede, número de neurônios por camada, função de ativação utilizada, tempo de processamento, em relação ao ciclo da rede neural, o número de steps, número de épocas, e os valores de saída de acurácia e perda (loss), para treino e para teste.

Observando os resultados obtidos em relação a variação nos valores dos parâmetros, com o aumento do número de fotos para a etapa de treino e para a etapa de testes, a acurácia melhorou como era esperado devido a maior diversidade que um número maior de fotos proporciona. O número de camadas ocultas, juntamente com a aumento no números de neurônios nestas camadas apresentou também uma melhora na acurácia da fase de treinos e da fase de testes. Em conjunto na melhor combinação de parâmetros a acurácia nos treinos foi acima de 98%, e a acurácia nos testes, um pouco menor, chegando a 92,61% no melhor caso.

6. CONSIDERAÇÕES FINAIS

O presente estudo representa uma contribuição significativa para a pesquisa em pecuária de precisão, oferecendo uma abordagem inovadora para a contagem de gado bovino através da utilização de redes neurais convolucionais (CNN) em conjunto com sensoriamento remoto por meio de drones. A implementação prática desta técnica em áreas de propriedades rurais do município de Alegrete, Rio Grande do Sul, proporcionou resultados promissores, destacando a eficácia da abordagem proposta.

O desenvolvimento desse software utilizando CNNs para contagem de gado em cenários reais de pecuária demonstra o potencial transformador da inteligência artificial no setor agrícola. A precisão e eficiência alcançadas através da análise de imagens aéreas possibilitam uma gestão mais inteligente dos rebanhos, contribuindo para a pecuária de precisão e, conseqüentemente, para o aumento da produtividade.

O experimento ficou restrito ao uso de 2 classes num primeiro momento, e de 3 classes num segundo, dentro dessa margem, o trabalho atingiu resultados satisfatórios, em relação a acurácia obtida nos treinos e nos testes. Apesar da boa acurácia, observou-se algumas limitações. Assim, deve-se que considerar que o número de animais presentes nas fotos, conforme o método descrito na metodologia de divisão de uma foto em 16 outras, resultou em fotos com uma grande variação no número de indivíduos e muitos casos de animais parcialmente cortados, presentes em 2 fotos. Isto é um complicador para o estabelecimento do número de classes e evitar contagens duplicadas.

A introdução dessa técnica na pecuária oferece benefícios práticos aos produtores rurais, permitindo uma contagem de gado mais rápida, precisa e não invasiva. Ao evitar a necessidade de reunir os animais para contagem manual, reduz-se o estresse nos rebanhos, minimizando perdas e melhorando o bem-estar animal. Além disso, a automação desse processo proporciona economia de tempo e recursos, aumentando a eficiência operacional das propriedades rurais.

Ao longo da realização do trabalho de conclusão de curso, também observou-se uma tendência crescente na região de Alegrete na investigação de tecnologias de sensoriamento remoto e inteligência artificial na agricultura, com ênfase na pecuária de precisão. Estudos recentes exploram não apenas a contagem de animais, mas também a monitorização da saúde do rebanho, identificação de comportamentos anormais e até mesmo a predição de condições de pastagem. Essa convergência de tecnologias abre novas perspectivas para a modernização da pecuária na região.

Para viabilizar a introdução generalizada dessa técnica, é crucial considerar algumas melhorias e aprimoramentos. Isso inclui a realização de estudos mais abrangentes em diferentes contextos e regiões, para garantir a robustez e adaptação do modelo a diversas condições. A exploração de técnicas de *transfer learning*, o treinamento do modelo em grandes conjuntos de dados e a sua adaptação a diferentes raças de gado podem ser passos essenciais.

A introdução da tecnologia desenvolvida em ambiente relevante é algo desejável para estudos futuros. A colaboração entre pesquisadores, produtores e empresas de tecnologia é essencial para acelerar a adoção dessas tecnologias inovadoras. Além disso, a integração de ferramentas de pecuária de precisão com sistemas de gerenciamento agrícola já existentes pode facilitar a aceitação e implementação dessa abordagem em larga escala. Em última análise, a introdução bem-sucedida dessa técnica em cenários relevantes de pecuária de precisão não apenas modernizaria as práticas agrícolas, mas também contribuiria para a sustentabilidade, eficiência e competitividade do setor pecuário, promovendo um equilíbrio entre inovação tecnológica e práticas agrícolas tradicionais.

REFERÊNCIAS

BEDOYA, D. I. G.; CASTRILLÓN, R. Reconocimiento automático de ganado bovino a partir de imágenes aéreas tomadas con drones: Un enfoque exploratorio. In: **Memorias de Congresos UTP**. [S.l.: s.n.], 2019. p. 32–39.

NALESSO, F. C. Contagem automática de bovinos em rebanho baseada em análise e processamento de imagens. 2015.

RIBEIRO, N. G. V.; GUEDES, G. B.; BARBIERI, T. T. Aplicação de algoritmos de visão computacional na contagem de gado por meio de processamento de imagens aéreas. **Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação**, v. 1, n. 10, 2019.

ROCHA, D. S. d. et al. Potencialidades do uso de um sistema webgis na pecuária de precisão: Estudo de caso embrapa pecuária sul. Universidade Federal de Santa Maria, 2014.