

Visão computacional aplicada à predição de altura de pastagens

Wendell Gasparoni¹, Ana Paula Lüdtke Ferreira¹[0000-0001-7057-9095],
Teresa Cristina Moraes Genro^{1,2}[0000-0001-9601-9619]

¹ Programa de Pós-graduação em Computação Aplicada
Universidade Federal do Pampa, Bagé, Brazil

{wendellalves.aluno, anaferreira}@unipampa.edu.br

² Empresa Brasileira de Pesquisa Agropecuária, Bagé, Brazil
cristina.genro@embrapa.br

Resumo A pecuária de corte exige uma boa estimativa da quantidade de alimento no pasto para evitar situações de sub e sobrepastejo. A altura da vegetação correlaciona com a quantidade de matéria seca e pode ser usada como métrica para estimativas da disponibilidade de alimento no pasto. Este trabalho propõe uma solução para a determinação da altura média da vegetação baseada em visão computacional, utilizando redes neurais convolucionais. As espécies de pasto usadas nos modelos são vegetação nativa dos campos sul-brasileiros, azevém e capim-sudão, mas a técnica pode ser usada para qualquer outro tipo de vegetação. A coleta de dados usa imagens capturadas pelo aplicativo H-Pasture a partir de celulares comuns, diminuindo custos operacionais e aumentando a agilidade nos processos de tomada de decisão, promovendo uma gestão sustentável dos recursos naturais. Os resultados obtidos apresentam coeficientes de correlação de 0,9249 para pastagens nativas, 0,9312 para azevém e 0,7292 para capim-sudão. Os resultados ainda podem ser aprimorados, mas destacam o potencial da técnica proposta para o aprimoramento do manejo de pastagens, com possíveis aplicações nos modelos de negócio baseados em pecuária extensiva.

Keywords: beef cattle production · CNN · machine learning · vegetation management

1 Introdução

O ecossistema Campos Sulinos se estende pela Região Sul do Brasil, Uruguai, Argentina e uma parte do Paraguai, apresentando uma grande biodiversidade florística [45,8]. As características da vegetação desse ecossistema favorecem modelos de negócio baseados em pecuária extensiva [36,34], que dependem de uma boa estimativa de disponibilidade de alimento no pasto, para que a movimentação de animais entre poteiros possa ser realizada com maior precisão, de forma a garantir bons resultados no processo de produção animal [21].

As pastagens são um ecossistema dinâmico e o manejo do pasto é apontado por produtores e técnicos que utilizam esse modelo para a produção animal como

desafiador, pois as orientações e as definições relativas à lotação dos piquetes e à definição do momento de entrada e saída dos animais nas áreas são pouco precisas. Frequentemente, são observadas situações de superpastejo ou subpastejo, ambas acarretando em baixo desempenho animal, seja por produção vegetal aquém do potencial e degradação da pastagem no primeiro caso, ou desperdício de forragem no segundo [25].

A pesquisa em manejo de pastagens concentra-se em dois conceitos principais: a oferta de forragem e a intensidade de pastejo, baseada no cálculo de forragem disponível por peso vivo animal por determinado período de tempo [32]; e a interceptação luminosa, sugerindo que o pastejo é ideal quando 95% da radiação é interceptada pelo pasto [9,6]. Estes conceitos requerem treinamento especializado e equipamentos específicos, muitas vezes inacessíveis para pequenas e médias propriedades. Estudos revelam que a altura do pasto tem uma relação direta com a massa de forragem disponível, tornando-se um critério prático de fácil mensuração para determinar o momento ótimo de pastejo e ajustes na carga animal, contribuindo para uma gestão eficiente e sustentável da pastagem [2,44,10,38,21,42]. Pesquisas no Rio Grande do Sul reforçam a altura do pasto como um indicador confiável para o manejo, influenciando positivamente no desempenho animal e na mitigação das emissões de gases de efeito estufa, ao controlar a altura, diversos componentes do sistema são indiretamente geridos, promovendo a sustentabilidade [33,39,18].

Assim, o manejo da altura do pasto tem impacto no desempenho do gado, na qualidade da forragem, e na sustentabilidade ambiental, sendo que, na prática, tal manejo frequentemente depende de métodos manuais que utilizam réguas e discos para medir a altura da vegetação. Esses métodos são trabalhosos, demorados, e sujeitos a erros humanos devido à necessidade de múltiplas medições para estimar a altura de forma representativa, complicando-se pela diversidade de espécies de forragem e variabilidade do ambiente agrícola, o que eleva a dificuldade e imprecisão das medições manuais [46].

Com o intuito de superar os desafios enfrentados na medição da altura da vegetação em pastagens nativas e cultivadas, particularmente nas pastagens da Região Sul do Brasil, este trabalho propõe uma abordagem que busca a automatização desse processo por meio da aplicação de técnicas de visão computacional. A estratégia adotada envolve o uso de redes neurais convolucionais (*convolutional neural networks*, ou CNN), um tipo especial de rede neural artificial utilizada para processar dados com topologia em grade, como imagens e séries temporais [23]. Em síntese, são desenvolvidas arquiteturas de redes neurais para serem treinadas com fotos de determinados tipos de vegetação: nativa, azevém (*Lolium multiflorum L.*) ou capim-sudão (*Sorghum sudanense L.*). Isso permite a estimativa automática da altura da vegetação na área fotografada.

O restante deste texto está organizado como se segue: na Seção 2 são apresentados os trabalhos relacionados à nossa abordagem, na Seção 3 é apresentado o conjunto de material e métodos utilizado ao longo do experimento, a Seção 4 os resultados são apresentados e discutidos e a Seção 5 apresenta a conclusão e os trabalhos futuros.

2 Trabalhos correlatos

Os trabalhos correlatos foram encontrados a partir de uma revisão de escopo da literatura, para a qual foi elaborado um protocolo específico com o apoio da ferramenta Parsifal (<https://parsif.al/>). O protocolo definiu as bases de pesquisa (IEEE Digital Library, Science@Direct e Scopus), as strings de busca e os critérios de seleção. A delimitação temporal abrangeu publicações a partir de 2019.

A análise dos artigos encontrados na revisão evidenciou que a literatura apresenta tendências e lacunas no campo da predição da altura da vegetação com base na análise de imagens fotográficas. Vários artigos [7,17,19,24,31] destacam a técnica de *structure from motion* (SfM) em combinação com *unmanned aerial vehicle* (UAV) para medir a altura da vegetação em cenários de savana e plantações. Alguns desses estudos também forneceram análises quantitativas dos resultados, com coeficiente de determinação variando de 0,80 a 0,98, caracterizando a precisão dessas abordagens para o cenário estudado.

A aplicação de modelos de regressão para a estimativa da altura da vegetação também foi abordada nos artigos [4,28,31,27]. Esses modelos mostraram resultados promissores para os cenários estudados (com coeficiente de determinação variando de 0,838 a 0,9467, especialmente quando combinados com dados de sensores remotos, como *synthetic aperture radar* (SAR) e imagens multiespectrais. Os resultados quantitativos obtidos em diversos estudos destacam a capacidade desses modelos em prever a altura da vegetação em plantações.

[48,37,14] implementam inversão customizada de modelos físicos, como *water cloud model* (WCM) e *random volume over ground* (RVoG). Nestes trabalhos o coeficiente de determinação varia entre 0,58 e 0,86. Em [37] é aplicado o método *particle filter* (PF), alcançando coeficiente de determinação de 0,95.

Em [12], o estudo introduz um algoritmo *bayesian point cloud classification* (BPCC), que usa filtragem automática e classificação por agrupamento para analisar dados *light detection and ranging* (LiDAR). Este algoritmo foi testado contra métodos manuais e semi-automáticos (PROTOLIDAR). Mostrou forte correlação com o método PROTOLIDAR nas estimativas de altura e largura da vegetação, com coeficiente de determinação de 0,94 e 0,89, respectivamente.

O uso de redes neurais como método para estimar a altura da vegetação é destacado em três trabalhos. [1] compara diferentes técnicas, incluindo *artificial neural network* (ANN) e *convolutional neural networks* (CNN), para estimar a altura de culturas de girassol utilizando dados dos satélites Sentinel-1 e Sentinel-2. O menor *root mean squared error* (RMSE) para o período de alongamento do caule foi alcançado pela ANN (3,083 cm), enquanto para CNN, os menores RMSE foram registrados durante as fases de desenvolvimento da inflorescência e florescimento (19,223 cm e 8,731 cm, respectivamente).

Em outro estudo [11], a integração de dados SAR híbrido-polarizados da RISAT-1 com WCM modificado e redes neurais foi utilizada para a estimativa da altura da cultura de trigo. Essa metodologia alcançou um coeficiente de determinação de 0,68.

O terceiro estudo [40] analisa a resposta espectral de imagens aéreas obtidas por UAV aplicada ao manejo de pastagens. Utilizando uma rotina de aprendizado de máquina, o estudo conseguiu classificar eficazmente as condições de manejo da pastagem com base na altura e na cobertura do solo. O modelo ajustado obteve uma exatidão de 66% e um índice kappa de 0,53.

A maioria dos artigos revisados concentra-se em plantações, que apresentam topografia e distribuição de vegetação mais uniformes. O escopo deste trabalho (assim como em [40]) abrange a aplicação em pastagens. O pastejo é um processo dinâmico, que modifica a estrutura das plantas que estão na área, afetando a medida da altura, ao contrário das plantas cultivadas para grão, que não sofrem remoção de tecido. Essa dinâmica adicional, com a presença de animais que interagem com a vegetação, impõe desafios na predição da altura da vegetação. Portanto, este trabalho representa uma nova contribuição para o campo, uma vez que se propõe a preencher essas lacunas ao explorar a aplicação de CNN em conjunto com imagens fotográficas para a predição da altura da vegetação em pastagens típicas dos Campos Sulinos, levando em consideração a maior heterogeneidade na topografia do terreno e na altura da vegetação. Espera-se que essa abordagem ajude no desenvolvimento de práticas agrícolas mais eficientes e no manejo sustentável de pastagens nesta região.

3 Material e métodos

3.1 Construção da base de dados

A coleta de dados pode ser feita de qualquer dispositivo de captura de imagens digitais. Para facilitar a integração dos dados com o mecanismo de apoio à tomada de decisão, foi desenvolvido o módulo H-Pasture Collector para integração com o aplicativo H-Pasture [20], usado para recomendação de entrada e saída de animais das pastagens com base na sua altura média. Até então, o sistema fazia as recomendações com base no ingresso manual de medições de altura. O módulo foi construído com o *framework* Flutter (<https://flutter.dev/>) e um *back end* em ASP.NET 6 (<https://dotnet.microsoft.com/>), conectado a um banco de dados relacional PostgreSQL (<https://www.postgresql.org/>).

O H-Pasture Collector objetiva a captura, organização e gestão das fotos coletadas durante o processo de construção da base de fotos. Além disso, tem a capacidade de operar em modo *offline*, permitindo que os usuários colem fotos em locais remotos ou com conectividade limitada.

O *back end* do sistema foi hospedado em serviços da Amazon Web Services (AWS). A *application programming interface* (API) é executada em uma instância EC2 do tipo t2.micro, enquanto o banco de dados PostgreSQL é gerenciado por meio do Amazon RDS. As instâncias foram configuradas dentro do AWS Free Tier, permitindo a implantação econômica durante o desenvolvimento. A escolha da AWS garante escalabilidade e confiabilidade à infraestrutura do sistema.

A coleta de dados ocorreu nas dependências da Embrapa Pecuária Sul, em 20 de outubro de 2023 e em 20 de fevereiro de 2024, com captura de 753 fotos

de pastagens com vegetação nativa, 500 fotos com azevém e 504 fotos de capim-sudão, totalizando 1757 fotos. As capturas visavam abranger uma variedade de alturas da vegetação em diferentes ambientes, no entanto, a sua amplitude foi limitada pela configuração da vegetação nos dias das coletas. Assim, as alturas da vegetação variaram entre 3 a 43 centímetros para a vegetação nativa, 3 a 39 centímetros para o azevém, e 27 a 130 centímetros para o capim-sudão.

O procedimento de coleta das fotos envolveu etapas padronizadas. Para cada ponto de amostragem, um quadro de 0,25 m² foi posicionado na vegetação para servir como ponto de referência (Fig. 1-A). Em seguida, foram realizadas cinco medições de altura a partir do interior desse quadro. Após anotar as medições no aplicativo H-pasture Collector, o quadro foi removido e as fotos foram tiradas, garantindo que a região central do quadro estivesse sempre centralizada nas imagens. A captura das fotos, retratada pela Fig. 1-B, ocorreu em diferentes distâncias entre a câmera e a vegetação (0,5; 1; 2 e 3 metros) e em diferentes ângulos (0°, 90°, 180° e 270°) em relação ao ponto de referência, resultando em aproximadamente 16 fotos coletadas para cada ponto de amostragem. Esse procedimento foi repetido em todos os pontos de amostragem para garantir uma representação abrangente da vegetação em diferentes condições. Exemplos de fotos capturadas para cada tipo de vegetação são apresentados na Fig. 1-C.

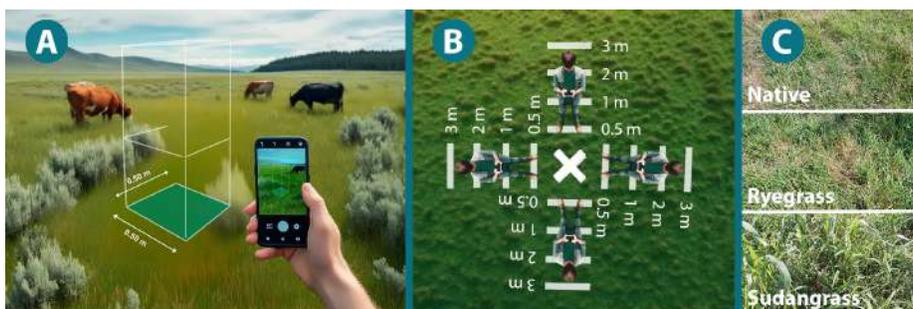


Figura 1. Método para coleta de fotos.

Para o pré-processamento de dados foram desenvolvidos dois conjuntos de *scripts*, um em C# para a primeira etapa e um *notebook* em Python para a segunda etapa. A primeira etapa foi dedicada à descarga das fotos coletadas do *back end* na nuvem. Após a conclusão da descarga, um arquivo JSON foi gerado para mapear cada foto descarregada com a altura média coletada no contexto da foto. Esse processo de descarga e geração ocorre por três vezes, ou seja, uma vez para cada tipo de vegetação (nativo, azevém e capim-sudão).

Na segunda etapa, as fotos (resolução original 1080x720) foram ajustadas para uma resolução de 720x720 *pixels*. Este ajuste incluiu um corte das imagens a partir do centro. Todas as fotografias preservaram seus três canais de cores padrão RGB. Ainda nesta etapa, as fotos (agrupadas por tipo de vegetação) foram distribuídas em dois conjuntos distintos: um conjunto de treinamento

com 80% das imagens e um conjunto de teste, que abrange as 20% imagens restantes. *Data augmentation* [3] foi aplicada exclusivamente aos conjuntos de treinamentos de cada uma das espécies, consistindo no espelhamento horizontal, duplicando a quantidade de fotos para treinamento.

No final das duas etapas de tratamentos dos dados, três bases de dados foram criadas: uma para vegetação nativa, outra para azevém e a última para o capim-sudão.

3.2 Projeto e validação das CNN

As redes neurais convolucionais foram projetadas para lidar com entradas matriciais que apresentam dependências espaciais em regiões locais da grade, representados por elementos adjacentes na matriz [3]. A eficácia das CNN não se limita a imagens, estendendo-se a dados temporais, espaciais e espaço-temporais. Assim, a utilização de CNN se mostrou o caminho natural para analisar fotos bidimensionais de pastagens, alinhando-se com a natureza dos dados e suportado por literatura (ver Seção 2).

Ao acolher o desafio de explorar o vasto território das CNN, foi inicialmente direcionada a atenção para arquiteturas já consolidadas, reconhecendo o valor de construir sobre os alicerces de conhecimento preexistentes.

Numa análise realizada de arquiteturas existentes, foi delimitado o enfoque às arquiteturas VGG16 [41], Xception [13] e EfficientNetV2S [43], buscando uma diversidade que abarcasse diferentes níveis de complexidade, ao mesmo tempo em que se mantivesse viável para execução em ambiente com restrição de unidades de computação no Google Colab. Cada uma dessas arquiteturas traz consigo inovações, oferecendo um panorama abrangente do estado da arte em redes neurais convolucionais. Diferentes estudos evidenciam a aplicabilidade das bases convolucionais VGG16 e Xception em problemas de regressão [29,26,47,15].

Nossa abordagem concentrou-se em desenvolver uma arquitetura de regressão profunda simples para cada um dos tipos de vegetação (nativa, azevém e capim-sudão), caracterizada pelo uso de CNN com uma camada de regressão linear no topo ou variações dessa estrutura.[30] mostra que em três dos quatro problemas analisados, as redes de regressão profunda simples, quando ajustadas corretamente, são capazes de competir de forma significativa com os métodos específicos encontrados na literatura, os quais são dedicados exclusivamente à resolução de uma única tarefa.

A Fig. 2 ilustra a versão abstrata da arquitetura final desenvolvida, antes da otimização dos parâmetros. Na etapa 1, encontramos a camada de entrada. A etapa 2 descreve a base convolucional, que pode ser da rede VGG16, Xception ou EfficientNetV2S. A base convolucional refere-se à parte da rede neural convolucional responsável pela extração de características das imagens de entrada. A camada de achatamento é destacada na etapa 3. A etapa 4 engloba as camadas densas e a camada de saída. Embora a figura represente três camadas densas, esse número é um hiperparâmetro a ser otimizado, juntamente com a quantidade de unidades em cada camada.

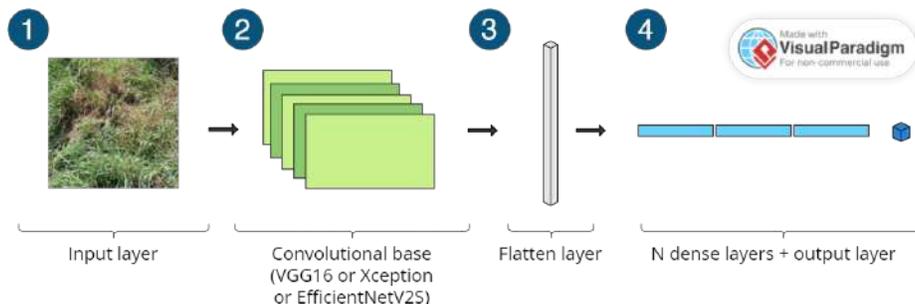


Figura 2. Representação abstrata da arquitetura.

Tabela 1. Espaço de hiperparâmetros para investigação.

Hiperparâmetro (θ)	Valores
<i>conv_base</i>	VGG16, Xception ou EfficientNetV2S
<i>num_layers</i>	1, 2 ou 3
<i>units_0, units_1, units_2</i>	32, 160, 288 ou 416
<i>activation</i>	<i>linear</i> ou <i>softplus</i> [16]
<i>lr</i>	1×10^{-4} , 1×10^{-5} ou 1×10^{-6}

Por fim, com do espaço de hiperparâmetros definido (Tabela 1), o processo de pesquisa foi executado individualmente para cada tipo de vegetação, desenvolvendo conjuntos específicos de hiperparâmetros para a rede aplicada à vegetação nativa, azevém e capim-sudão. Utilizou-se otimização bayesiana, com 15 tentativas máximas por conjunto e 15 épocas de treinamento, permitindo uma análise ajustada às particularidades de cada vegetação.

O Google Colab foi utilizado para criação e treinamento das redes devido à sua infraestrutura flexível e escalável, eliminando a necessidade de configurar servidores locais. A biblioteca Keras (<https://keras.io/api/>) foi empregada para o desenvolvimento e treinamento. Os pesos foram inicializados utilizando a configuração padrão do Keras (*weights = imagenet*), e nenhuma base externa foi utilizada para o treinamento devido à ausência de bases adequadas para o trabalho. Portanto, todas as etapas seguintes de treinamento foram realizadas utilizando a base desenvolvida, garantindo que o modelo fosse especificamente ajustado para os dados do nosso estudo.

O método *hold-out* foi usado para treinamento e validação [3,35,5]. Os dados foram divididos na proporção de 80% para o conjunto de treinamento e 20% para o conjunto de teste.

A avaliação dos modelos de CNN foi feita sobre os dados de teste com a métrica *mean absolute error* (MAE), Eq. (1), que mede a média dos valores absolutos das diferenças entre as previsões do modelo e os valores reais. Formalmente:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

onde n é o número de amostras, y_i representa o valor real e \hat{y}_i é a previsão feita pelo modelo.

O coeficiente de correlação foi usado para examinar a relação entre as previsões do modelo e os valores reais, permitindo avaliar a qualidade das previsões em termos de direção e intensidade. Adicionalmente, foi aplicado RMSE, Eq. (2), para analisar a precisão do modelo. O RMSE é a raiz quadrada do *mean squared error* (MSE), fornecendo uma medida do desvio padrão das diferenças entre as previsões e os valores reais, na mesma unidade dos valores originais:

$$\text{RMSE} = \sqrt{\text{MSE}} \quad \text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

A utilização do RMSE complementa a análise, oferecendo uma visão mais completa sobre a precisão das previsões do modelo, enfatizando erros maiores devido à natureza quadrática da métrica.

4 Resultados e discussão

Utilizando o Keras Tuner, os hiperparâmetros das redes neurais foram ajustados para maximizar a precisão e o desempenho para cada tipo de vegetação. Para a vegetação nativa, o melhor conjunto de hiperparâmetros incluiu a arquitetura VGG16 com duas camadas densas de 288 unidades, uma taxa de aprendizado de 1×10^{-5} e a função de ativação *softplus* na camada de saída. Para azevém e capim-sudão, os melhores hiperparâmetros foram idênticos, consistindo na arquitetura VGG16 com três camadas densas (32, 160, 416 unidades), função de ativação linear na camada de saída, e taxa de aprendizado de 1×10^{-5} .

A Tabela 2 apresenta detalhadamente a arquitetura final da rede para a vegetação nativa, azevém e capim-sudão. Para vegetação nativa, a arquitetura utiliza a base convolucional da rede VGG16 para extrair características das imagens de entrada, transformando-as em representações de dimensões (*None*, 11, 11, 512). Esta etapa serve para capturar informações relevantes das imagens e alimentar as camadas densas subsequentes. Após a camada VGG16, há uma camada de achatamento que transforma as representações de características em um vetor unidimensional de dimensões (*None*, 61952). Em seguida, há três camadas densas consecutivas.

As duas primeiras camadas densas com ativação *rectified linear units* (ReLU), *dense_1* e *dense_2*, têm 288 unidades cada uma e utilizam a função de ativação ReLU [22]. Essas camadas são responsáveis por extrair características das representações de alto nível aprendidas pela VGG16. A última camada densa, possui apenas uma unidade, indicando que a rede está sendo utilizada para uma tarefa de regressão. A função de ativação desta camada é *softplus*, que é uma função suave que retorna valores positivos. Esta camada é responsável por gerar

a saída final da rede, que é um valor da estimativa da altura média do pasto na foto de entrada.

Tabela 2. Arquitetura final para vegetação nativa e azevém/capim-sudão.

Arquiteturas					
Nativo			Azevém/Capim-sudão		
Camada	Formato saída	Ativação	Camada	Formato saída	Ativação
input	(356, 356, 3)	-	input	(356, 356, 3)	-
vgg16	(11, 11, 512)	-	vgg16	(11, 11, 512)	-
flatten_1	(61952)	-	flatten_1	(61952)	-
dense_1	(288)	ReLU	dense_1	(32)	ReLU
dense_2	(288)	ReLU	dense_2	(160)	ReLU
output	(1)	Softplus	dense_3	(416)	ReLU
-	-	-	output	(1)	Linear

É importante mencionar que a dimensão da entrada da rede, definida como 356x356 *pixels*, foi restrita pelo consumo de memória na versão gratuita do Google Colab, mas poderia ser maior na versão paga.

A rede final para as vegetações azevém e capim-sudão compartilham a mesma estrutura, uma vez que o Keras Tuner retornou o mesmo conjunto de hiperparâmetros para ambos os tipos de vegetação. A estrutura é semelhante à rede para vegetação nativa, com alterações ocorrendo após a camada de achatamento. A rede prossegue com quatro camadas densas consecutivas. As três primeiras camadas densas aplicam a função de ativação ReLU, gerando saídas de tamanhos (*None*, 32), (*None*, 160) e (*None*, 416), respectivamente. A quarta camada é a camada de saída, com ativação linear, que produz uma saída de tamanho (*None*, 1). Essa camada finaliza a rede neural, fornecendo a estimativa da altura média do pasto na foto de entrada.

Com as arquiteturas definidas para cada tipos de vegetação, procedeu-se com o treinamento e avaliação das redes neurais. Estes treinamentos e avaliações foram realizados em três repetições para garantir robustez nos resultados obtidos.

Os coeficientes de correlação dos três gráficos na figura Fig. 3 foram obtidos a partir da primeira repetição do treinamento e avaliação das redes neurais. Os coeficientes para a vegetação nativa e o azevém são altos, 0,9224 e 0,9334, respectivamente, indicando boa previsão e ajuste do modelo aos dados de teste. Já o coeficiente para o capim-sudão é menor, 0,7201, sugerindo uma correlação moderada e uma capacidade de previsão ligeiramente inferior. Isso implica que, enquanto as redes neurais se saíram bem na estimativa da altura da vegetação nativa e do azevém, a estimativa para o capim-sudão pode precisar de ajustes na arquitetura da rede ou nos dados de treinamento.

A Tabela 3 resume os resultados da avaliação das redes em relação aos tipos de vegetação. Para a vegetação nativa, os resultados revelaram um RMSE de 2,3982 cm, calculado a partir das três repetições da avaliação. Além disso, foi obtido um MAE de 1,7871 cm, indicando que, em média, as previsões da rede

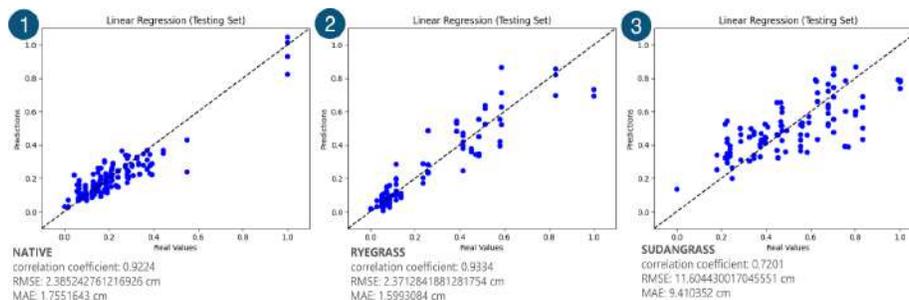


Figura 3. Gráfico de coeficientes de correlação da primeira repetição.

estão aproximadamente 1,7871 centímetros distantes dos valores reais. O azevém apresentou um RMSE de 2,4157 cm e um MAE de 1,6491 cm, indicando uma boa precisão nas previsões. Por outro lado, o capim-sudão teve um desempenho inferior, com um RMSE de 11,6090 cm e um MAE de 9,2664 cm. Esses resultados sugerem que o capim-sudão pode apresentar características que tornam sua altura mais desafiadora de ser prevista pelo modelo, em comparação com o nativo e azevém. Isso implica em necessidades adicionais de ajustes no processo de modelagem ou quantidade de dados para lidar com as particularidades dessa vegetação.

Tabela 3. Avaliação das arquiteturas finais por tipo de vegetação.

	Tipo de vegetação									
	Nativo			Azevém			Capim-sudão			
	RMSE	MAE	CC	RMSE	MAE	CC	RMSE	MAE	CC	
Repetição	1	2,3852	1,7552	0,9224	2,3713	1,5993	0,9334	11,6044	9,4104	0,7201
	2	2,3970	1,8202	0,9276	2,4269	1,6666	0,9307	11,6041	9,1906	0,7336
	3	2,4125	1,7860	0,9248	2,4489	1,6813	0,9295	11,6184	9,1983	0,7339
Média	2,3982	1,7871	0,9249	2,4157	1,6491	0,9312	11,6090	9,2664	0,7292	

5 Conclusão

Este trabalho teve foco na proposição e análise de modelos de CNN para a estimativa da altura das vegetações nativa, azevém e capim-sudão em pastagens do Sul do Brasil. A análise dos resultados revelou estimativas interessantes para a vegetação nativa e o azevém, destacadas por baixos valores de RMSE e MAE e coeficientes de correlação elevados. Em contraste, o modelo aplicado ao capim-sudão revelou a necessidade de ajustes, visto que as previsões não atingiram o mesmo nível de precisão.

A expansão da coleta de dados se apresenta como uma estratégia para refinar o treinamento dos modelos. Note-se que a vegetação possui aspectos referentes à

sazonalidade e as coletas devem ser feitas em diferentes dias do ano para garantir uma base de dados completa com uma quantidade grade de dados coletados em todas as alturas típicas da vegetação. As coletas iniciais foram motivadas para uma investigação da possibilidade de uso de CNN nesse domínio de aplicação. Por essa razão, trabalhou-se com uma base relativamente pequena e que não contemplava todos as fases fenológicas de produção vegetal. Na continuidade deste trabalho, a intensificação da coleta e um estudo focado na melhoria do modelo referente ao capim-sudão está previsto, visando adaptá-lo às características únicas dessa vegetação. Espera-se que tais iniciativas aprimorem a precisão das previsões, impulsionando o avanço de métodos agrícolas mais eficientes.

Os resultados também foram limitados pelas restrições de memória e tempo de processamento do Google Colab, que exigiu uma diminuição da resolução das imagens para o processo de treinamento. Estamos investigando alternativas para eliminar o problema, visto que os resultados iniciais do trabalho foram interessantes.

Referências

1. Abdikan, S., Sekertekin, A., Narin, O.G., Delen, A., Balik Sanli, F.: A comparative analysis of slr, mlr, ann, xgboost and cnn for crop height estimation of sunflower using sentinel-1 and sentinel-2. *Advances in Space Research* **71**(7), 3045–3059 (2023). <https://doi.org/https://doi.org/10.1016/j.asr.2022.11.046>, <https://www.sciencedirect.com/science/article/pii/S027311772201078X>, recent *Advances in Space Research in Monitoring Sustainable Development Goals*
2. Abramides, P., Alcântara, P., Stafuzza, J., Foschine, A., Dower, J.: Estimativa da quantidade de forragem em pastagens de capins prostrados tropicais, através da medida da altura média da vegetação **20**(1), 17–41 (1982)
3. Aggarwal, C.C.: *Neural Networks and Deep Learning: A Textbook*. Springer Publishing Company, Incorporated, 1st edn. (2018)
4. Allies, A., Roumiguié, A., Dejoux, J.F., Fieuzal, R., Jacquin, A., Veloso, A., Champolivier, L., Baup, F.: Evaluation of multiorbital sar and multisensor optical data for empirical estimation of rapeseed biophysical parameters. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **14**, 7268–7283 (2021). <https://doi.org/10.1109/JSTARS.2021.3095537>
5. Awwalu, J., Ogwueleka, F.: On holdout and cross validation: A comparison between neural network and support vector machine **6**, 2394–9333 (04 2019)
6. Barbosa, R.A., Nascimento Jr, D., Euclides, V.P.B., Silva, S.C., Zimmer, A.H., Torres Jr, R.A.A.: Capim-tanzânia submetido a combinações entre intensidade e frequência de pastejo. *Pesquisa Agropecuária Brasileira* **42**(3), 329–340 (2007)
7. Batistoti, J., Junior, J., Ítavo, L.C., Matsubara, E., Gomes, E., Oliveira, B., de Souza, M., Siqueira, H., Filho, G., Akiyama, T., Gonçalves, W., Liesenberg, V., Li, J., Dias, A.: Estimating pasture biomass and canopy height in brazilian savanna using uav photogrammetry. *Remote Sensing* **11**, 2447 (10 2019). <https://doi.org/10.3390/rs11202447>
8. Bencke, G.A., Chomenko, L., Sant’Anna, D.M.: *O que é o Pampa?* Fundação Zoobotânica do Rio Grande do Sul (2016)
9. Carnevalli, R.A., Silva, S.C., Bueno, A.A.O., Uebele, M.C., Bueno, F., Hodgson, J., Silva, G.N., Moraes, J.P.G.: Herbage production and grazing losses in panicum

- maximum cv. mombaça under four grazing managements. *Tropical Grasslands* **40**, 165–176 (2006)
10. Carvalho, P.C.F., Rocha, L.M., Baggio, C., Macari, S., Kunrath, T.R., Moraes, A.: Característica produtiva e estrutural de pastos mistos de aveia e azevém manejados em quatro alturas sob lotação contínua. *Revista Brasileira de Zootecnia* **39**(9), 1857–1865 (2010)
 11. Chauhan, S., Srivastava, H.S., Patel, P.: Crop height estimation using risat-1 hybrid-polarized synthetic aperture radar data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **12**(8), 2928–2933 (2019). <https://doi.org/10.1109/JSTARS.2019.2919604>
 12. Cheraïet, A., Naud, O., Carra, M., Codis, S., Lebeau, F., Taylor, J.: An algorithm to automate the filtering and classifying of 2d lidar data for site-specific estimations of canopy height and width in vineyards. *Biosystems Engineering* **200**, 450–465 (2020). <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2020.10.016>, <https://www.sciencedirect.com/science/article/pii/S1537511020302944>
 13. Chollet, F.: Xception: Deep learning with depthwise separable convolutions (2017)
 14. Dave, R., Saha, K., Kushwaha, A., Pandey, D., Vithalpara, M., Parath, N., Murugesan, A.: Application of sentinel-1 sar-derived vegetation descriptors for soil moisture retrieval and plant height prediction during the wheat growth cycle. *International Journal of Remote Sensing* **44** (01 2023). <https://doi.org/10.1080/01431161.2023.2170193>
 15. Dreisbach, C., Karunanidhi, A.P., Shimazaki, Y., Rana, N., Thornburg, L., Wang, L., Groth, S., Hollenbach, S.: Using simulated data to predict birthweight from prenatal ultrasound images. In: 2023 IEEE Western New York Image and Signal Processing Workshop (WNYISPW). pp. 1–4 (2023). <https://doi.org/10.1109/WNYISPW60588.2023.10349465>
 16. Dugas, C., Bengio, Y., Bélisle, F., Nadeau, C., Garcia, R.: Incorporating second-order functional knowledge for better option pricing. In: *Advances in Neural Information Processing Systems* (2001)
 17. Dutra, A.C., Breunig, F.M., Cassol, H.L.G., de Oliveira, M.T., Hoffmann, T.B., Arai, E., Duarte, V., Shimabukuro, Y.E.: Brazilian savanna height estimation using uav photogrammetry. In: 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. pp. 5945–5948 (2021). <https://doi.org/10.1109/IGARSS47720.2021.9553339>
 18. Franzluebbers, A.J., Stuedemann, J.A.: Soil-profile organic carbon and total nitrogen during 12 years of pasture management in the southern piedmont usa. *Agric. Ecosyst. Environ.* **129**, 28–36 (2009)
 19. Gano, B., Demebele, J.S.B., Ndour, A., Luquet, D., Beurier, G., Diouf, D., Audebert, A.: Using uav borne, multi-spectral imaging for the field phenotyping of shoot biomass, leaf area index and height of west african sorghum varieties under two contrasted water conditions. *Agronomy* **11**(5) (2021). <https://doi.org/10.3390/agronomy11050850>, <https://www.mdpi.com/2073-4395/11/5/850>
 20. Gasparoni, W., Ferreira, A.P., Genro, T.C., Silveira, M.: H-pasture: uma aplicação móvel para estimativa da disponibilidade de forragem e ajuste de carga em pastagens sob lotação contínua ou rotativa. In: *Anais do XIII Congresso Brasileiro de Agroinformática*. pp. 154–163. SBC, Porto Alegre, RS, Brasil (2021). <https://doi.org/10.5753/sbiagro.2021.18386>, <https://sol.sbc.org.br/index.php/sbiagro/article/view/18386>
 21. Genro, T.C.M., da Silveira, M.C.T.: Uso da altura para ajuste de carga em pastagens. *Comunicado Técnico 101, Embrapa Pecuária Sul* (2018)

22. Glorot, X., Bordes, A., Bengio, Y.: Deep sparse rectifier neural networks. Proceedings of the 14th International Conference on Artificial Intelligence and Statistics pp. 315–323 (2011)
23. Goodfellow, I., Bengio, Y., Courville, A.: Deep Learning. MIT Press (2016), <http://www.deeplearningbook.org>
24. HASEGAWA, F., YOSHIKAWA, S., FURUHASHI, K., KAIZU, Y., IMOU, K.: Estimation of the plant height for energy crops using uav-sfm method. Journal of the Japan Institute of Energy **101**(12), 265–269 (2022). <https://doi.org/10.3775/jie.101.265>
25. Hodgson, J.: Grazing management: science into practice. John Wiley, Longman Scientific and Technical, New York (1990)
26. Hu, L.: Image noise estimation with using pre-trained conventional neural network. In: 2020 IEEE 3rd International Conference on Automation, Electronics and Electrical Engineering (AUTEEE). pp. 492–495 (2020). <https://doi.org/10.1109/AUTEEE50969.2020.9315533>
27. Kaplan, G., Fine, L., Lukyanov, V., Malachy, N., Tanny, J., Rozenstein, O.: Using sentinel-1 and sentinel-2 imagery for estimating cotton crop coefficient, height, and leaf area index. Agricultural Water Management **276**, 108056 (2023). <https://doi.org/https://doi.org/10.1016/j.agwat.2022.108056>, <https://www.sciencedirect.com/science/article/pii/S0378377422006035>
28. Kaplan, G., Fine, L., Lukyanov, V., V S, M., Tanny, J., Rozenstein, O.: Normalizing the local incidence angle in sentinel-1 imagery to improve leaf area index, vegetation height, and crop coefficient estimations. Land **10**, 680 (06 2021). <https://doi.org/10.3390/land10070680>
29. Lathuilière, S., Juge, R., Mesejo, P., Muñoz-Salinas, R., Horaud, R.: Deep mixture of linear inverse regressions applied to head-pose estimation. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp. 7149–7157 (2017). <https://doi.org/10.1109/CVPR.2017.756>
30. Lathuilière, S., Mesejo, P., Alameda-Pineda, X., Horaud, R.: A comprehensive analysis of deep regression. IEEE Transactions on Pattern Analysis and Machine Intelligence **42**(9), 2065–2081 (2020). <https://doi.org/10.1109/TPAMI.2019.2910523>
31. Lu, W., Okayama, T., Komatsuzaki, M.: Rice height monitoring between different estimation models using uav photogrammetry and multispectral technology. Remote Sensing **14**(1) (2022). <https://doi.org/10.3390/rs14010078>, <https://www.mdpi.com/2072-4292/14/1/78>
32. Maraschin, G.E.: Estratégias para valorizar sistemas pastoris sob a ótica de políticas de segurança alimentar, bem estar animal e social, pp. 67–83. No. 20, GRUPO CAMPOS, Salto (2004)
33. Martins, A.P., aise Robinson Kunrath, Anghinoni, I., de Faccio Carvalho, P.C.: Integração Soja-Bovinos de Corte no Sul do Brasil. Grupo de Pesquisa em Sistema Integrado de Produção Agropecuária, UFRGS, Porto Alegre (2015). <https://doi.org/10.13140/RG.2.1.3576.3922>
34. Nabinger, C., Jaurena, M.A., Oliveira, L.V., Costa, J.L.B., Ilha, H.H., Eincheberger, C., Canary, A.C., Fernandes, H.S., Pinheiro, S.: Anais do I Congresso sobre o Bioma Pampa - Reunindo Saberes. UFPel (2020)
35. Nurhayati, Soekarno, I., Hadihardaja, I.K., Cahyono, M.: A study of hold-out and k-fold cross validation for accuracy of groundwater modeling in tidal lowland reclamation using extreme learning machine. In: 2014 2nd International Conference on Technology, Informatics, Management, Engineering and Environment. pp. 228–233 (2014). <https://doi.org/10.1109/TIME-E.2014.7011623>

36. Pillar, V.: Campos Sulinos: Conservação e Uso Sustentável da Biodiversidade (12 2009)
37. Romero-Puig, N., Marino, A., Lopez-Sanchez, J.M.: Application of the trace coherence to hh-vv polinsar tandem-x data for vegetation height estimation. *IEEE Transactions on Geoscience and Remote Sensing* **60**, 1–10 (2022). <https://doi.org/10.1109/TGRS.2021.3101016>
38. Rosa, F.Q., Bremm, C., Machado, D.R.: Efeito da oferta de forragem na estrutura do pasto, pp. 23–25. UFRGS, Porto Alegre (2017)
39. Savian, J.V., Schons, R.M.T., Marchi, D.E., de Freitas, T.S., Silva Neto, G.F., Mezzalira, J.C., de Faccio Carvalho, P.C.: Rotatinuous stocking: a grazing management innovation that has high potential to mitigate methane emissions by sheep. *J. Clean. Prod.* **186**, 602–608 (2018)
40. Silveira, M.C.T.d., Almeida, P.H.A.d., Andrade, C.V.P.d.A., Albuquerque Filho, M.R.d., Bremm, C., Santos, F.C.d.: Aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por vants e aplicado no manejo de pastagens. *Boletim de Pesquisa e Desenvolvimento* 51, Embrapa Pecuária Sul; Embrapa Milho e Sorgo, Bagé (12 2022), <https://ainfo.cnptia.embrapa.br/digital/bitstream/doc/1150201/1/BP-51-online.pdf>, iSSN: 1983-0467
41. Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition (2015)
42. Souza Filho, W., Nunes, P.A.d.A., Barro, R.S., Kunrath, T.R., Almeida, G.M., Genro, T.C.M., Bayer, C., de Faccio Carvalho, P.C.: Mitigation of enteric methane emissions through pasture management in integrated crop-livestock systems: trade-offs between animal performance and environmental impacts. *J. Clean. Prod.* **213**, 968–975 (2019)
43. Tan, M., Le, Q.V.: Efficientnetv2: Smaller models and faster training (2021)
44. Trindade, J.K., et al.: Composição morfológica da forragem consumida por bovinos de corte durante o rebaixamento do capim-marandu submetido a estratégias de pastejo rotativo. *Pesquisa Agropecuária Brasileira* **42**(6), 883–890 (jun 2007)
45. Trindade, J.K., Pinto, C.E., Neves, F.P., Mezzalira, J.C., Bremm, C., Genro, T.C., Tischler, M.R., Nabinger, C., Gonda, H.L., Carvalho, P.C.: Forage allowance as a target of grazing management: Implications on grazing time and forage searching. *Rangeland Ecology and Management* **65**(4), 382–393 (2012). <https://doi.org/https://doi.org/10.2111/REM-D-11-00204.1>, <https://www.sciencedirect.com/science/article/pii/S1550742412500631>
46. Viljanen, N., Honkavaara, E., Näsi, R., Hakala, T., Niemeläinen, O., Kaivosoja, J.: A novel machine learning method for estimating biomass of grass swards using a photogrammetric canopy height model, images and vegetation indices captured by a drone. *Agriculture* **8**, 70 (05 2018). <https://doi.org/10.3390/agriculture8050070>
47. Wilie, B., Cahyawijaya, S., Adiprawita, W.: Countnet: End to end deep learning for crowd counting. In: 2018 5th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI). pp. 128–132 (2018). <https://doi.org/10.1109/EECSI.2018.8752666>
48. Yang, H., Li, H., Wang, W., Li, N., Zhao, J., Pan, B.: Spatio-temporal estimation of rice height using time series sentinel-1 images. *Remote Sensing* **14**(3) (2022). <https://doi.org/10.3390/rs14030546>, <https://www.mdpi.com/2072-4292/14/3/546>