

Comparative analysis of resizing the vegetation index map and expanding the data set in the training of Artificial Neural Networks.

Análise comparativa do redimensionamento do mapa de índice de vegetação e ampliação do conjunto de dados no treinamento de Redes Neurais Artificiais.

Allan Vitor W. Toledo, Carlos Rafael N. de A. Silva, Carlos Gabriel S. Rodrigues,
Raul T. Santos, Claudia A. Martins

Instituto de Computação
Universidade Federal do Mato Grosso (UFMT) - Cuiabá, MT – Brazil
allan.toledo, carlos.silval2, carlos.rodrigues{@sou.ufmt.br},
raul, claudia{@ic.ufmt.br}

Abstract. *This article aims to make a comparative analysis of the impact of resizing vegetation maps on hardware consumption during Neural Network training and the impact of expanding the data set on the generalization of the model for predicting cotton productivity. In this work, images with resolutions of 64x64 and 128x128 of the NDVI and NDRE indices were used. As a result, we achieved a reduction in hardware consumption using resizing. Furthermore, the dataset enlargement technique had a negative impact on the Neural Network training.*

Keywords: *machine learning, precision agriculture, cotton.*

Resumo. *Este artigo tem como objetivo fazer uma análise comparativa do impacto do redimensionamento dos mapas de vegetação no consumo de hardware durante o treinamento da Rede Neural e o impacto da ampliação do conjunto de dados na generalização do modelo para previsão da produtividade do algodão. Neste trabalho foram utilizadas imagens com resoluções de 64x64 e 128x128 dos índices NDVI e NDRE. Como resultado, obtivemos uma redução no consumo de hardware utilizando o redimensionamento. Além disso, a técnica de ampliação do conjunto de dados teve um impacto negativo no treinamento da Rede Neural.*

Palavras-chave: *aprendizado de máquina, agricultura de precisão, algodão.*

1 Introdução

A Agricultura de Precisão surgiu com o objetivo de reconhecer melhor as necessidades de cada região da plantação, em comparação às técnicas tradicionais. Utilizando sensores para reconhecer as características da região e equipamentos que aplicam insumos no plantio baseado em algoritmos que analisam essas características, é possível aplicar de acordo com a demanda de recursos. Isso reduz os gastos em insumos agrícolas e prioriza o rendimento máximo da cultura (Inamasu & Bernardi, 2014).

O processamento de imagens entra nesse meio extraíndo informações de imagens da cultura e do solo, que servem para reconhecer áreas onde há deficiência de

nutrientes, presença de ervas daninhas, pragas, prever a produtividade (Habib *et al.*, 2020) e também o nível de desenvolvimento da planta (Patrício & Rieder 2018; Benos *et al.*, 2021).

A escolha de prever a produtividade a partir de um índice de vegetação parte de outros pesquisadores que demonstraram encontrar bons resultados a respeito, Johnson *et al.* (2016) chegou a conclusão que a utilização de valores MODIS-NDVI (Imagem de Espectrografia de Resolução Moderada de Índice Vegetação de Diferença Normalizada) mostrou-se possuir uma correlação boa o suficiente para prever a produtividade, confirmando os resultados que Mkhabela *et al.* (2011) obteve, que concluiu que o MODIS-NDVI poderia ser utilizado para prever a produtividade até dois meses antes da colheita.

Ambos os trabalhos utilizaram algoritmos de Inteligência Artificial, no qual é possível utilizar o Aprendizado de Máquina para treinar um modelo para realizar as previsões de produtividade. Budach *et al.* (2022), explica como em aplicações de algoritmos de Inteligência Artificial (IA), a qualidade do dado é importante para um bom aprendizado de máquina, e a IA possa ter grande precisão em suas previsões. Por isso é importante a aplicação ter algum nível de pré-processamento antes que os dados sejam usados como entrada de um algoritmo de IA. O redimensionamento dos dados e a ampliação do conjunto de dados também é uma preocupação por parte de outros pesquisadores que buscaram avaliar o impacto do redimensionamento no desempenho de suas aplicações, além de explorarem diferentes técnicas que permitiram ampliar o conjunto de dados disponível buscando melhorar a generalização de seus modelos de Redes Neurais Artificiais.

O objetivo deste trabalho é avaliar o impacto do redimensionamento e ampliação do conjunto de dados na precisão do modelo de Rede Neural para regressão utilizando mapas de índices de vegetação.

2 Revisão da Literatura

Para entender sobre técnicas de pré-processamento que poderiam ser aplicadas em mapas de índices, foi realizada uma busca primeiro por artigos que utilizam imagens em algoritmos de Inteligência Artificial voltados para a agricultura de precisão. Farooq *et al.* (2018), compararam o resultado entre os métodos de uma Rede Neural Convolutiva (CNN) e Histograma de Gradientes Orientados (HoG) para detecção de ervas daninhas, eles testaram três resoluções diferentes para redimensionar uma imagem e usar como entrada para o algoritmo de IA: 30×30 , 45×45 e 60×60 . A menor resolução conseguiu uma precisão boa e levou menos tempo para treinamento. Saponara & Elhanashi (2021) falam do impacto positivo do redimensionamento na complexidade do tempo de treinamento da RNA.

Além disso, para obtenção de melhores resultados em aplicações de Redes Neurais, é importante que haja exemplos o suficiente para a generalização do modelo sobre os dados, alcançando uma boa previsão para novos exemplos. Devido a limitação de dados, foi pesquisado sobre modos de ampliação do conjunto de dados. Khosla & Saini (2020) discutem diversas técnicas que podem ser utilizadas para ampliar o conjunto de dados para aplicações de Aprendizado Profundo. Assim a Rede Neural

consegue em alguns casos generalizar mais o modelo, obtendo melhores previsões para novos dados.

3 Metodologia

3.1 Aquisição dos Dados

Os dados utilizados neste projeto foram disponibilizados pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa) e derivam de um processo de imageamento multiespectral em 6 bandas do espectro Red, Green, Blue, NIR, RedEdge e Thermal de talhões de algodão de uma fazenda em Mato Grosso. A área mapeada pelo drone é um semicírculo de aproximadamente 100 hectares, onde metade dele foi dividida em 54 blocos de 100 m por 100 m de dimensão. No total foram feitos 4 voos para aquisição das imagens, que são relativos a fases diferentes da maturação da planta de algodão. Após obtido os ortomosaicos das 6 bandas devidamente georreferenciados, foram geradas a composição RGB e os seguintes índices de vegetação: NDVI, NDRE, SCCCI, SAVI, MCARI e GLI.

Junto com as imagens, foram obtidos os valores de produção de cada bloco do talhão em Kg/ha, os valores estão entre 4768 Kg/ha e 7610 Kg/ha, com um valor médio de 5967 Kg/ha e um desvio padrão de 607 Kg/ha.

3.2 Seleção dos blocos utilizados

Pelo fato do talhão possuir um formato de semicírculo e as subdivisões terem sido feitas em blocos quadrados, dos 54 blocos presentes 14 desses blocos estavam na borda e não foram completamente preenchidos pelo cultivo, e por essa razão foram descartados, restando 40 blocos para serem utilizados.

3.3 Seleção dos índices de vegetação

Os dados disponíveis contavam com 6 diferentes índices dos quais 2 foram escolhidos para usar como entrada para a Rede Neural, o NDVI e o NDRE. Mkhabela *et al.* (2011) mostrou que o uso do NDVI era suficientemente bom para prever a produtividade, e o NDRE por possuir alta correlação com o NDVI como mostra a Figura 1.




Figura 1. Matriz de correlação entre os índices de vegetação.

3.4 Pré-processamento das imagens

As imagens do talhão chegaram divididas em 54 blocos, e o conteúdo da imagem está orientado de acordo com suas coordenadas geográficas, de maneira que a imagem de um bloco apresentaria parte de outros blocos, no entanto essas partes foram removidas para que cada imagem representasse exclusivamente o bloco ao qual pertence. Isso resultou em regiões vazias dentro de cada imagem que ocupavam mais de 49% da quantidade de pontos na imagem como mostrado na Tabela 1. Essas regiões possuem os valores de cada pixel como NaN (*Not a Number*), como mostra a Figura 2.




Figura 2. Mapa do índice NDRE do Bloco 1.

A presença desses valores vazios poderia causar problemas no treinamento da Rede Neural Artificial. Os valores NaN poderiam ser substituídos por algum outro valor numérico, mas isso traria outra questão para ser explorada, qual valor numérico não afetaria os dados? Para evitar essa nova variável, foi aplicada uma rotação de forma que preencheria os espaços vazios com os próprios valores do bloco e exigiria a substituição dos valores NaN. Para isso foi criado um programa utilizando a linguagem Python que

encontra o ponto no canto superior e nos cantos laterais, eles são usados como referência para calcular a rotação necessária para que o quadrado interno fique paralelo aos eixos X e Y da imagem. O ponto superior é definido como sendo o novo ponto de coordenadas (0, 0). Após calcular a nova posição que o ponto terá após a rotação necessária, é calculada a distância horizontal e vertical do ponto superior e aplicada a translação necessária para mover o ponto a sua posição final. Utilizando os mesmos procedimentos para os demais pontos com valores numéricos é gerada uma nova imagem, que é totalmente preenchida pelos valores de índice de vegetação do bloco correspondente. Armazenando a rotação e translação é possível desfazer a transformação se for necessário. A Figura 3 mostra o passo a passo para gerar a nova imagem sem valores vazios e com dimensão fixa em 2048x2048 pixels.




Figura 3. Etapas para exclusão dos pixels de valores NaN

3.5 Redimensionamento das imagens

Para reduzir o consumo de hardware do modelo da Rede Neural, foi aplicado um redimensionamento que será avaliado como uma das técnicas de pré-processamento, comparando o desempenho do algoritmo nas resoluções obtidas.

O processo de redimensionamento gerou a partir da imagem original em 2048x2048 as imagens em 1024x1024, 512x512, 256x256, 128x128 e 64x64, como cada imagem seguinte possui um quarto da área em pixels da imagem anterior, o processo de redimensionamento foi calcular o valor médio entre os quatros pixels adjacentes como mostra o exemplo na figura 4.




Figura 4. Processo de redimensionamento

3.6 Ampliação do conjunto de dados

Devido à pequena quantidade de dados disponíveis, foram aplicados algoritmos para aumentar a quantidade de dados utilizados no treinamento da rede neural. Khosla & Saini (2020) reforçam a importância de que na aplicação desses algoritmos o rótulo da imagem seja preservado. Das técnicas citadas por eles, foram utilizadas duas sobre aumento de dados, a rotação de imagem em 90, 180, e 270 graus, pois o conteúdo que importa para o desempenho da rede neural artificial preenche toda a imagem, então apenas múltiplos de 90 graus, e espelhamento horizontal da imagem que quando combinados, permitiram aumentar em oito vezes a quantidade de imagens disponíveis para treinamento.

Não foi utilizado o espelhamento vertical porque o espelhamento horizontal combinado com a rotação geraria o mesmo resultado que o espelhamento vertical junto ao espelhamento horizontal, pois analisando as transformações aplicadas, usando 3 rotações e a reflexão em um dos eixos, gera-se 7 transformações únicas, enquanto o uso de um segundo eixo de reflexão repetiria as transformações anteriores, dessa forma não teria nenhum aumento de dados, apenas repetição (Florencio, 2011).

3.7 Autokeras

Para o desenvolvimento da Rede Neural Artificial, foi utilizada a função ImageRegression da biblioteca Autokeras para Python que fornece um modelo base para o treinamento da Rede Neural, na criação desse modelo é especificado as dimensões das imagens que serão tratadas, no caso foram dimensões de 64x64x1, especificado um canal de profundidade, e 128x128x1. Como parâmetros para o treinamento foram usadas 50 tentativas de ajuste dos Hiperparâmetros, que incluem alterações na sua estrutura interna de neurônios, para 50 épocas de treinamento para cada tentativa e separação de 10% para validação interna.

3.8 Avaliação do desempenho

Foram utilizadas as medidas de desempenho: Erro Absoluto Médio (MAE), que é calculado a média da diferença absoluta entre o valor predito e o valor real de produtividade, conforme mostra a figura 5.

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n}$$

Figura 5. Fórmula do Erro Absoluto Médio

E também o Coeficiente de Determinação R^2 que mede a fração da variação do conjunto de valores que é explicado pelo modelo de regressão (Budach *et al.* 2022). Se R^2 possui um valor de 1, indica que o modelo de regressão explica todas as variações do conjunto de valores, se possui um valor de 0 indica que o modelo não é melhor que um modelo que apenas utiliza o valor médio, e um R^2 negativo indica que ele é um modelo pior que um modelo que apenas utiliza o valor médio.

4 Resultados e discussões

4.1 Pré-processamento dos dados

Com a aplicação do tratamento que removeu os valores NaN nas imagens do conjunto de dados, obteve-se imagens com resoluções menores porém preenchidas completamente com valores de índice de vegetação.

Tabela 1 - Dados sobre o mapa de índice antes e após o pré-processamento.

	Antes	Depois
Dimensão	2946x2946	2048x2048
Contagem de NaN	4271258	0
Porcentagem de NaN	49,21%	0%

4.2 Redimensionamento das imagens

Com a aplicação do redimensionamento, conseguimos 6 conjuntos de dados diferentes para cada índice de vegetação, nas resoluções 2048x2048, 1024x1024, 512x512, 256x256, 128x128 e 64x64. O redimensionamento das imagens tiveram um impacto muito positivo no consumo de hardware. O uso de memória durante o treinamento chegou a níveis em que o sistema operacional precisou interromper o processo, impedindo que obtivéssemos resultados para resoluções superiores a 128x128, sendo nesse caso necessário ao menos 16GB de RAM disponível, que ia além da capacidade do computador utilizado. Além disso, o tempo de predição para imagens com resoluções menores foi melhor, como mostra a Tabela 2.

Tabela 2 - Impacto do redimensionamento no tempo de predição

dimensão	tempo médio
64x64	27 ms
128x128	45 ms

4.3 Ampliação do conjunto de dados

Após a aplicação das transformações nos 40 blocos que foram selecionados para utilização no treinamento e validação, obteve para cada bloco mais 7 imagens. Ao total 280 imagens a mais para cada conjunto de dados, totalizando 320 imagens disponíveis para treinamento e validação. A Figura 6 mostra todas as combinações resultantes de um dos blocos do talhão após aplicação da rotação e do espelhamento horizontal.

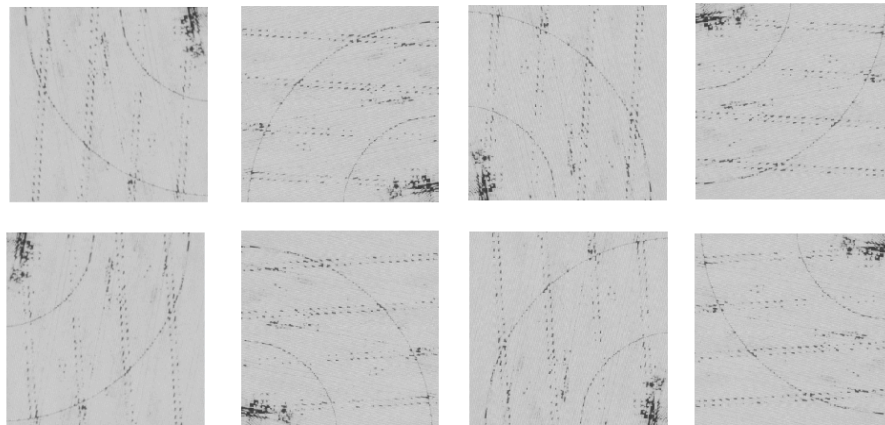


Figura 6. Combinações resultantes da ampliação do conjunto de dados

4.4 Predição dos valores da produção

A Tabela 3 mostra o Erro Absoluto Médio em kg/ha obtido pela validação após treinamento da Rede Neural Artificial. Os erros obtidos com a ampliação de dados foram significativamente maiores em todos os casos, indicando uma dificuldade maior da Rede Neural em adaptar o modelo ao conjunto de dados.

Tabela 3 - Erro Absoluto Médio em kg/ha

dimensão	NDVI		NDRE	
	sem ampliação dos dados	com ampliação dos dados	sem ampliação dos dados	com ampliação dos dados
64x64	507	560	1198	46776
128x128	524	1720	472	500

A Tabela 4 relaciona a medida de desempenho R^2 com o índice de vegetação e a resolução da imagem aplicada. Pode-se notar que todos os valores deram negativos, isso indica que a Rede Neural não conseguiu generalizar para o conjunto de dados e parâmetros fornecidos, isso pode ser causado pela baixa quantidade de amostras, apenas 40 exemplos em comparação a regressão aplicada por Budach *et al.* (2022) que contou com ao menos 1460 exemplos no conjunto de amostras 'Houses', sendo por ele considerado um conjunto de amostras pequeno.

Tabela 4 - R^2 Obtidos em cada índice de vegetação e resolução

dimensão	NDVI		NDRE	
	sem ampliação dos dados	com ampliação dos dados	sem ampliação dos dados	com ampliação dos dados

64x64	-0.32	-0.87	-5.11	-11948.54
128x128	-0.33	-10.21	-0.19	-0.22

5. Conclusão

Apesar de haver apenas resultados negativos de R^2 , o uso de redimensionamento de fato ajudou a reduzir o consumo de hardware, de maneira que fosse possível aplicar o treinamento para 64x64 e 128x128 utilizando o autokeras, enquanto para dimensões maiores é necessário dispor de um número maior de memória RAM disponível que vai além dos 8GB que a máquina utilizada no trabalho possui.

A utilização da técnica de ampliação do conjunto de dados resultou em um desempenho inferior, indicando que essa técnica para mapas de índices NDVI e NDRE não resultam em uma melhora no aprendizado da Rede Neural, sendo nesse caso importante adquirir mais dados únicos ou aprimorar a arquitetura da Rede Neural, escolhendo melhores hiperparâmetros que garantiriam que o modelo seja capaz de generalizar mais com o conjunto de dados disponível.

Para trabalhos futuros será investigado a utilização de diferentes hiperparâmetros e diferentes arquiteturas de Redes Neurais que resultam em um melhor aprendizado do modelo para o atual conjunto de dados, além de possíveis técnicas que poderiam reduzir o consumo de memória RAM.

Referências bibliográficas

- BENOS, L. *et al.* Machine learning in agriculture: A comprehensive updated review. *Sensors*, v. 21, n. 11, p. 3758, 2021.
- BUDACH, Lukas *et al.* The effects of data quality on machine learning performance. **arXiv preprint arXiv:2207.14529**, 2022.
- FAROOQ, A.; HU, J.; JIA, X. Analysis of spectral bands and spatial resolutions for weed classification via deep convolutional neural network. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 2, p. 183-187, 2018.
- FLORENCIO, Mariele Parteli. TRANSFORMAÇÕES NO PLANO E GRUPOS DE SIMETRIA. Trabalho de Conclusão de Curso, 2011.
- HABIB, M. T. *et al.* Machine vision based papaya disease recognition. **Journal of King Saud University-Computer and Information Sciences**, v. 32, n. 3, p. 300-309, 2020.
- INAMASU, R. Y.; BERNARDI, A. C. de C. Agricultura de precisão. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 21-33.
- JOHNSON, Michael D. *et al.* Crop yield forecasting on the Canadian Prairies by remotely sensed vegetation indices and machine learning methods. **Agricultural and forest meteorology**, v. 218, p. 74-84, 2016.

- KHOSLA, Cherry; SAINI, Baljit Singh. Enhancing performance of deep learning models with different data augmentation techniques: A survey. In: 2020 International Conference on Intelligent Engineering and Management (ICIEM). **IEEE**, 2020. p. 79-85.
- MKHABELA, M. S. *et al.* Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. **Agricultural and Forest Meteorology**, v. 151, n. 3, p. 385-393, 2011.
- PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and electronics in agriculture**, v. 153, p. 69-81, 2018.
- SAPONARA, Sergio; ELHANASHI, Abdussalam. Impact of image resizing on deep learning detectors for training time and model performance. In: **International Conference on Applications in Electronics Pervading Industry, Environment and Society**. Cham: Springer International Publishing, 2021. p. 10-17.