

PREVISÃO DA PRODUTIVIDADE DA CANA-DE-AÇÚCAR A PARTIR DE DADOS DE SENSORIAMENTO REMOTO E TÉCNICAS DE APRENDIZADO DE MÁQUINA

Romário Porto de Oliveira¹, Thiago Caio moura Oliveira², Bruna da Silva Brito Ribeiro³, Renata Amaral da Silva⁴, Marcelo Rodrigues Barbosa Júnior⁵, Carlos Eduardo Angeli Furlani⁶

¹ Doutorando em Agronomia (Produção Vegetal), Unesp/FCAV, romario.porto@unesp.br

² Mestrando em Agronomia (Ciência do Solo), Unesp/FCAV, thiago.caio@unesp.br

³ Graduanda de Engenharia Agrícola, UFMA, bruna.brito@discente.ufma.br

⁴ Mestranda em Agronomia (Ciência do Solo), Unesp/FCAV, renata.amaral-silva@unesp.br

⁵ Doutorando em Agronomia (Produção Vegetal), Unesp/FCAV, marcelo.junior@unesp.br

⁶ Professor Titular, Departamento de Eng. e Ciências Exatas, Unesp/FCAV, eduardo.furlani@unesp.br

Apresentado no
LII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2023
18 a 21 de outubro de 2023 – Ribeirão Preto - SP, Brasil

RESUMO: A determinação da produtividade da cana-de-açúcar apresenta diversos desafios, como a necessidade de coleta de dados em áreas extensas, em tempo hábil para o planejamento agrícola. Diante disso, neste trabalho propomos uma abordagem baseada em sensoriamento remoto aliadas a técnicas de aprendizado de máquina, para previsão da produtividade da cana-de-açúcar. A produtividade da cana-de-açúcar foi determinada em 240 linhas de plantio de 10 m. Três voos foram realizados a 80, 120 e 160 dias após transplante das mudas pré-brotadas com aeronave remotamente pilotada e com sensor multiespectral embarcado. A partir dos valores de reflectância das bandas espectrais, foram calculados índices de vegetação e para aumentar a capacidade preditiva do modelo, os dados dos três voos foram avaliados em conjunto. Avaliou-se o algoritmo de aprendizado de máquina Extreme Gradient Boosting. Os resultados indicaram elevado potencial da utilização de dados multiespectrais para mapeamento da produtividade da cana-de-açúcar. O modelo desenvolvido obteve elevada acurácia para previsão da produtividade seis meses antes da colheita, com erros inferiores a 17%.

PALAVRAS-CHAVE: índices de vegetação, séries temporais, imagens aéreas.

SUGARCANE YIELD FORECASTING FROM REMOTE SENSING DATA AND MACHINE LEARNING TECHNIQUES

ABSTRACT: The determination of sugarcane productivity presents several challenges, such as the need for data collection in extensive areas and in a timely manner for agricultural planning. In this study, we propose an approach based on remote sensing combined with machine learning techniques for predicting sugarcane productivity. Sugarcane productivity was determined in 240 planting rows of 10 m each. Three flights were conducted at 80, 120, and 160 days after the transplanting of pre-sprouted seedlings, using a remotely piloted aircraft with an onboard multispectral sensor. Vegetation indices were calculated based on the reflectance values of the spectral bands, and to enhance the predictive capacity of the model, data from all three flights were evaluated together. The Extreme Gradient Boosting machine learning algorithm was employed. The results indicated a high potential for the use of

multispectral data in mapping sugarcane productivity. The developed model achieved high accuracy in predicting productivity six months before harvest, with errors below 17%.

KEYWORDS: vegetation indices, time series, aerial images.

INTRODUÇÃO: A determinação da produtividade da cana-de-açúcar é de grande relevância para o setor agrícola, visto a importância dessa cultura para as indústrias sucroalcooleiras e para a economia. No entanto, a determinação da produtividade dessa cultura ainda apresenta diversos desafios a serem superados. Entre as dificuldades, destaca-se a necessidade de coletar uma grande quantidade de dados em áreas extensas, além da necessidade de obtenção de informações em tempo hábil para realizar um planejamento agrícola mais adequado da produção. Diante dessas dificuldades, evidencia-se a importância de buscar novas abordagens para a estimativa da produtividade da cana-de-açúcar. O Sensoriamento Remoto tem se mostrado uma tecnologia inovadora no campo das avaliações agrícolas, possibilitando a obtenção de dados em larga escala de forma rápida e precisa. Sensores embarcados em satélites e aeronaves remotamente pilotadas (ARP) vêm sendo cada vez mais utilizados para diversos tipos de avaliações (Amarasingam et al., 2022). Pesquisas têm explorado a aplicabilidade de imagens de satélite para avaliar o desenvolvimento da cana-de-açúcar ao longo do ciclo, possibilitando relacionar esses dados com dados reais de produtividade (Dimov et al., 2022). Outras colaborações têm utilizado algoritmos de inteligência artificial, permitindo estimativas mais precisas da produtividade (Saini et al., 2023). No entanto, é importante destacar que é necessário mais estudo nesse campo, pois ainda não temos métodos ou padrões estabelecidos, e o desenvolvimento de abordagens mais robustas é fundamental para aumentar a confiabilidade e precisão dessas avaliações. Diante disso, propomos uma abordagem baseada em dados multiespectrais obtidos por ARP e técnicas de aprendizado de máquina aplicadas à previsão da produtividade da cana-de-açúcar.

MATERIAL E MÉTODOS: O estudo foi realizado em campo experimental localizado na Faculdade de Ciências Agrárias e Veterinárias (FCAV/UNESP), São Paulo, Brasil. Foram avaliadas as cultivares de cana-de-açúcar RB966928, RB867515, IACSP95-5094, CTC9001 e CTC-4. Para determinação da produtividade, 240 linhas de cultivo de 10 m foram avaliadas. Dessa forma, para cada linha, a produtividade foi determinada a partir do número de colmos e peso médio do colmo (por variedade) (Somard et al., 2018), avaliado 20 dias antes da colheita, de acordo a Eq. (1):

$$Y = NS \times W \quad (1)$$

Em que,

Y é a produtividade da cana-de-açúcar (unidade: t);

NS é o número de colmos por linha, e

W é o peso médio do colmo (unidade: t).

Foram realizados três voos a 80, 120 e 160 dias após transplântio (DAT) das mudas pré-brotadas. Utilizou sensor multiespectral (MicaSense RedEdge-M, MicaSense Inc., Seattle, Washington, EUA) embarcado em ARP multirrotor. Foram obtidas cinco bandas espectrais: Blue, Green, Red, RedEdge e NIR. Os softwares Agisoft Metashape (Professional 1.5.5, Agisoft, São Petersburgo, Rússia) e QGIS 3.10.9 (QGIS Development Team) foram utilizados para processamento das imagens. A partir dos valores de reflectância das bandas espectrais, foram calculados cinco índices de vegetação, Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação por Diferença Normalizada da Borda Vermelha (NDRE), Índice

de Vegetação Aprimorado (EVI), Índice de Vegetação de Diferença Renormalizado (RDVI) e Índice de Pigmento de Estrutura Intensiva (SIPI). Para aumentar a capacidade preditiva do modelo, os dados dos três voos foram utilizados em conjunto como variáveis de entrada no modelo de previsão. Foi avaliado o algoritmo de aprendizado de máquina, Extreme Gradient Boosting (XGBoost). O modelo foi processado utilizando a biblioteca ‘scikit-learn’ de código aberto em linguagem de programação Python v3.8.10 no ambiente do Jupyter Notebook. Os dados foram divididos em treinamento (80%) e teste (20%). O desempenho do modelo foi avaliado considerando o erro médio absoluto (MAE), raiz quadrada do erro quadrático médio (RMSE), coeficiente de determinação (R^2) e erro percentual médio absoluto (MAPE).

RESULTADOS E DISCUSSÃO: O modelo de previsão da produtividade da cana-de-açúcar, obteve precisão de 0,60 e acurácia (MAPE) de 17% (Tabela 1). Como o valor do R^2 é limitado entre zero e um, quanto maior o R^2 indica que a maior parte da variância nos valores da variável de resposta é explicado pela variação da variável independente (Mariadass et al., 2022). O nosso modelo obteve uma precisão relativamente elevada ($R^2 = 0,60$) com erros inferiores a 18%, sendo considerado um modelo com elevado potencial de previsão, já que a previsão foi realizada seis meses antes da colheita da cana-de-açúcar.

Tabela 1. Métricas de avaliação do modelo de previsão da produtividade da cana-de-açúcar.

MÉTRICAS			
MAE (t)*	RMSE (t)	R^2	MAPE
0,04	0,05	0,60	17%

* t – Peso em toneladas.

Na figura 1, é apresentada as previsões para cada variedade estudada. Os menores erros foram observados para as variedades RB966928, IACSP95-5094 e CTC-4. Esses resultados indicam o alto potencial da utilização de dados multitemporais obtidos por ARP no mapeamento da produtividade das lavouras de cana-de-açúcar.




Figura 1. Média de produtividade observada e predita (por linha) de cada variedade estudada.

CONCLUSÕES: Com base a avaliação das métricas de desempenho, verificou-se que a utilização de dados espectrais obtidos por ARP aliadas com o modelo XGBoost, são ferramentas poderosas para a previsão da produtividade da cana-de-açúcar. Nossos resultados obtiveram elevada acurácia para a previsão da produtividade da cana-de-açúcar seis meses antes da colheita.

AGRADECIMENTOS: Agradecimentos a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio fornecido.

REFERÊNCIAS:

Amarasingam, N., Salgadoe, A. S. A., Powell, K., Gonzalez, L. F., & Natarajan, S. A review of UAV platforms, sensors, and applications for monitoring of sugarcane crops. *Remote Sensing Applications: Society and Environment*, v. 26, p. 100712, 2022.

Dimov, D., Uhl, J. H., Löw, F., & Seboka, G. N. Sugarcane yield estimation through remote sensing time series and phenology metrics. *Smart Agricultural Technology*, v. 2, p. 100046, 2022.

Mariadass, D. A., Mounq, E. G., Sufian, M. M., & Farzamia, A. Extreme Gradient Boosting (XGBoost) Regressor and Shapley Additive Explanation for Crop Yield Prediction in Agriculture. In: *2022 12th International Conference on Computer and Knowledge Engineering (ICCKE)*. IEEE, 2022. p. 219-224.

Saini, P., Nagpal, B., Garg, P., & Kumar, S. CNN-BI-LSTM-CYP: A deep learning approach for sugarcane yield prediction. *Sustainable Energy Technologies and Assessments*, v. 57, p. 103263, 2023.

Som-ard, J., Hossain, M. D., Ninsawat, S., & Veerachitt, V. Pre-harvest sugarcane yield estimation using UAV-based RGB images and ground observation. *Sugar Tech*, v. 20, n. 6, p. 645-657, 2018.