

ESTIMATIVA DE PRODUTIVIDADE DO AMENDOIM EM DIFERENTES ÁREAS COM USO DE SENSORIAMENTO REMOTO

Jarlyson Bruno Costa Souza¹, Renata Amaral da Silva², Samira Luns Hatum de Almeida³,
Thiago Caio Moura Oliveira⁴, Armando Lopes de Brito Filho⁵, Rouverson Pereira da Silva⁶

¹ Doutorando em agronomia (produção vegetal), FCAV/UNESP, jarlyson.brunno@unesp.br

² Mestranda em agronomia (ciência do solo), FCAV/UNESP, renata.amaral-silva@unesp.br

³ Pós-doutoranda em agronomia (produção vegetal), FCAV/UNESP, samira.lh.almeida@unesp.br

⁴ Mestrando em agronomia (ciência do solo), FCAV/UNESP, thiago.caio@unesp.br

⁵ Doutorando em agronomia (produção vegetal), FCAV/UNESP, armando.brito@unesp.br

⁶ Eng. Agrícola, Prof. Doutor, Depto. de Engenharia Rural, FCA/UNESP, rouverson.silva@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 estimativa de produtividade ajuda no planejamento, para melhor decisão e o gerenciamento de recursos da cultura. Com isso, objetivou-se desenvolver uma nova metodologia para predição de produtividade da cultura do amendoim, que utilizem ferramentas de sensores remotos e técnicas de aprendizado de máquina e determinar o melhor índice de vegetação para estimativa e predição da produtividade. Os experimentos foram conduzidos em áreas comerciais na região da Alta Mogiana, no estado de São Paulo, durante a safra 2020/2021. Com a cultivar de amendoim IAC-OL3, grupo runner. Os modelos que apresentaram acurácia de até 1% são considerados excelentes. Já os modelos com acurácia entre 1% e 5% foram considerados como de bom potencial de estimativa de predição da produtividade. Os dois modelos de redes neurais (MLP e RBF) mostraram-se capazes de prever a produtividade com boa acurácia e precisão, mas é necessário mais estudo para que o método se torne robusto, a fim de validar os melhores modelos levando em consideração características de outras regiões.

PALAVRAS-CHAVE: solo; aprendizado profundo; agricultura.

PEANUT CROP PRODUCTIVITY ESTIMATION IN DIFFERENT AREAS USING REMOTE SENSING

ABSTRACT: The productivity estimation helps in planning, for better decision and management of crop resources. With this, the objective was to develop a new methodology for predicting the productivity of the peanut crop, using information from remote sensors and machine learning techniques and to determine the best vegetation index for estimating and predicting productivity. The experiments were conducted in commercial areas in the Alta Mogiana region, in the state of São Paulo, during the 2020/2021 harvest. In each experimental field, 20 sampling points were installed to evaluate productivity and maturation, each plot consisting of half a hectare (0.5 ha) with the peanut cultivar IAC-OL3, runner group. The models that presented an accuracy of up to 1% are considered excellent. Models with accuracy between 1% and 5% were considered as having good potential for estimating productivity prediction. The two models of neural networks (MLP and RBF) were able to

predict productivity with good accuracy and precision, but further study is needed for the method to become robust, to validate the best models taking into account characteristics of other regions.

KEYWORDS: ground; deep learning; agriculture

INTRODUÇÃO:

O amendoim (*Arachis hypogaea* L.) se destaca como a quarta oleaginosa que mais se cultiva no mundo, na safra 22/23 o Estado de São Paulo aparece como sendo o maior produtor nacional produzindo 179,4 mil hectares (FAO, 2023). A estimativa de produtividade para a cultura do amendoim pode ser realizada por meios tecnológicos mais avançados. Como o sensoriamento remoto (SR) (BORÉM; MIRANDA; NETO, 2021). Isso se dá, em grande parte, pela utilização de ferramentas, como o índice de vegetação da diferença normalizada – NDVI, que facilitam a identificação de problemas na lavoura (RIZZI; FONSECA, 2010). A utilização de técnicas de aprendizado de máquina seja por meio da utilização de aprendizado profundo ou redes neurais artificiais (RNA's) tem sido alvo de esforços científicos para a criação de soluções para Agricultura Digital (AD) e aliada ao sensoriamento remoto, pode trazer avanços significativos à cultura do amendoim (Atzberger, 2013; Mulla, 2013; Kattenborn et al., 2020). Com isso, objetivou-se desenvolver uma nova metodologia para predição de produtividade da cultura do amendoim, utilizando informações de sensores remotos e técnicas de aprendizado de máquina e determinar qual o melhor índice de vegetação para estimativa e predição da produtividade.

MATERIAL E MÉTODOS:

Os experimentos foram conduzidos em áreas comerciais na região da Alta Mogiana, no estado de São Paulo, durante a safra 2020/2021. Em cada campo experimental foram instalados 20 pontos amostrais para avaliação da produtividade. As áreas experimentais (Figura 1) foram selecionadas em parceria com a equipe técnica da COPLANA, considerando áreas com características de solos distintas, sendo cada parcela composta por meio hectare (0,5 ha) com a cultivar de amendoim IAC-OL3, grupo runner, de ciclo curto (125-130 dias após a semeadura - DAS), com três áreas em solos arenosos (Ibitinga, Santa Gertrudes e Granja) e três áreas em solos argilosos (Santa Adélia, Capão da Cruz e Frutal).




Figura 1. Áreas de estudo para predição da produtividade do amendoim por meio de imagens de satélites.

Para as imagens de satélite foram utilizados dados do sensor da plataforma PlanetScope CubeSat (Planet Team, 2019). Neste trabalho foram utilizados índices de vegetação já descritos na bibliografia e que são utilizados para prever o parâmetro agrônômico de produtividade (tabela 1). (Souza et al., 2022).

Tabela 1. Índices de vegetação (IV) utilizados para o UAV e satélite. (tabela 1).

IV	Equação	Referência
NDVI	$(NIR - Red) / (NIR + Red)$	Rouse et al. (1974)
GNDVI	$(NIR - Green) / (NIR + Green)$	Gitelson e Merzlyak (1996)

Produtividade

Em cada parcela foi coletada, em um ponto amostral, a produtividade em uma área de 2 m², após a operação de arranquio. Em seguida essas plantas foram levadas para o laboratório onde foram removidas as vagens das plantas para mensuração da massa, e, posteriormente, foram colocadas para secar em estufa a 65°C por 72 horas. Foi realizada a correção da umidade para 8% (umidade comercial) para todas as amostras. Para análise dos dados inicialmente foram realizadas análises de regressão, não sendo possível, entretanto, estimar a produtividade de forma acurada por meio de modelos lineares. Então realizou-se análises com modelos não-lineares a partir do uso de Redes Neurais Artificiais (RNA's), visando a estimativa e a predição da produtividade.

RESULTADOS E DISCUSSÃO:

Na Figura 2, apresentamos os dois modelos de RNA para estimativa de produtividade (MLP e RBF). As Figuras demonstram a acurácia dos modelos em cada área (campo de produção), medidas pelos erros médios absolutos (MAE), sendo que o tamanho das bolhas representa a magnitude dos erros. Os modelos que apresentaram acurácia de até 1% são considerados excelentes. Já os modelos com acurácia entre 1% e 5% foram considerados como de bom potencial de estimativa de predição da produtividade.

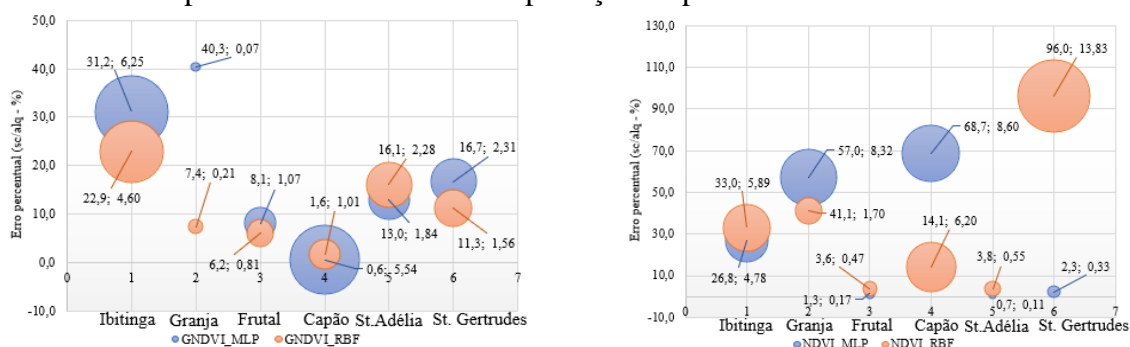


Figura 2. Erro das estimativas de produtividade por área. Para cada área e índice os valores indicam, respectivamente, o erro em sc alq⁻¹ e em %, representado pelo tamanho da bolha.

Em Ibitinga e Granja os modelos não foram adequados para estimar a produtividade com acurácia boa ou excelente. Já em Santa Gertrudes, o NDVI para a rede MLP, foram os melhores modelos de estimativa dessa área. O GNDVI também merece destaque, pois, a rede RBF para este índice apresentou erro de 1,01%. Isso pode ser explicado pela prevalência do solo mais arenoso que apresenta características melhores para o desenvolvimento da cultura

(NETO; COSTA; CASTRO, 2012). O NDVI em Santa Adélia, foi o único IV que estimou a produtividade com erro abaixo de 1% utilizando as duas redes. Para Capão da Cruz, os IV's que apresentaram modelos com boa ou excelente acurácia para estimativa da produtividade foram o GNDVI e NDVI. Os principais destaques foram o GNDVI (MLP e RBF), O NDVI apresentou modelo com MAE de 145 kg ha⁻¹ (14,0 sc alq⁻¹) ou 1,7% com a rede RBF. Em Frutal, o NDVI conseguiu estimar a produtividade de forma acurada, com os índices apresentando modelos excelentes, exceto a rede MLP para o GNDVI que apresentou bom modelo, com MAE de 84 kg ha⁻¹ (8,1 sc alq⁻¹) ou 1,07%. Para essas últimas áreas os solos apresentam características argilosas podendo ter sido fator para acurácia abaixo do esperado (NETO; COSTA; CASTRO, 2012). Porém este estudo consegue mostrar que apesar da cultura se desenvolver melhor em solos arenosos ela conseguiu se adaptar a solos mais argilosos também. Analisando de maneira geral, os índices que mais criaram modelos adequados para estimativa da produtividade foi o GNDVI que criou modelos em cinco áreas. O NDVI esteve presente em modelos de estimativa para quatro áreas.

CONCLUSÕES:

Este trabalho apresentou os primeiros estudos de predição e estimativa da produtividade do amendoim utilizando Sensoriamento Remoto e Inteligência Artificial. Além dos modelos de redes neurais para prever a produtividade. Os dois modelos de redes neurais (MLP e RBF) mostraram-se capazes de prever a produtividade com boa acurácia e precisão, mas é necessário mais estudo para que o método se torne robusto, a fim de validar os melhores modelos levando em consideração características de outras regiões.

REFERÊNCIAS:

- Atzberger, C. (2013). Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. *Remote sensing*, 5(2), 949-981. <https://doi.org/10.3390/rs5020949>
- Borém, A.; Miranda, G. V.; Fritsche-Neto, R. **Melhoramento de plantas**. Oficina de Textos, 2021.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24-49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114(4), 358-371. <https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Rizzi, R.; Fonseca, E. L. Análise da variação espacial e temporal do NDVI no Estado do Rio Grande do Sul através de imagens AVHRR. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 10, p. 1735-1737, 2001.
- Santos Dias, M.; Reis, L. S.; Lima, I. R. V.; de Oliveira, A. W.; dos Santos, R. H. S.; de Almeida, C. A. C.; Da Silva, V. M. (2019). Santos, A. F. D. (2019). Método não destrutivo para predição da maturação de amendoim (*arachis hypogaea* l.) utilizando sensoriamento remoto. Tese. Souza, J. B. C., De Almeida, S. L. H., Freire De Oliveira, M., Santos, A. F. D., Filho, A. L. D. B., Meneses, M. D., & Silva, R. P. D. Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. *Agronomy*, 12(7), 1512, 2022.