

## INTEGRANDO INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO: É POSSÍVEL PREVER A PRODUTIVIDADE DO AMENDOIM ANTECIPADAMENTE?

JARLYSON BRUNNO COSTA SOUZA<sup>1</sup>, SAMIRA LUNS HATUM DE ALMEIDA<sup>2</sup>,  
ARMANDO LOPES DE BRITO FILHO<sup>3</sup>, THIAGO CAIO MOURA OLIVEIRA<sup>4</sup>, RENATA  
AMARAL DA SILVA<sup>5</sup>, ROUVÉRSO PEREIRA DA SILVA<sup>6</sup>

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

<sup>2</sup>Pós-doutoranda em agronomia (produção vegetal), FCAV/UNESP, samira.lh.almeida@unesp.br

<sup>3</sup>Doutorando em agronomia (produção vegetal), FCAV/UNESP, armando.brito@unesp.br

<sup>4</sup>Mestrando em agronomia (ciência do solo), FCAV/UNESP, Thiago.caio@unesp.br

<sup>5</sup>Mestranda em agronomia (ciência do solo), FCAV/UNESP, renata.amaral-silva@unesp.br

<sup>6</sup>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 auxilia no planejamento, a tomada de decisão e o gerenciamento de recursos da cultura. Diante disto, objetivou-se desenvolver modelos de predição da produtividade do amendoim utilizando técnicas de SR e aprendizado de máquinas. Os experimentos foram conduzidos no estado de São Paulo na safra 2021/2022. Em cada campo experimental foram instalados 20 pontos amostrais para produtividade e maturação, sendo cada parcela composta por meio hectare (0,5 ha) com a mesma cultivar de amendoim. As áreas estudadas foram escolhidas em função do tipo de solo, em que três áreas apresentaram características de solos argilosos e as demais solos arenosos. Foram utilizadas imagens de satélites para calcular três índices de vegetação (NDVI, GNDVI e SAVI). Para gerar os modelos preditivos utilizou-se o algoritmo de redes neurais artificiais (MLP). Todos os índices de vegetação mostraram-se capazes de prever a produtividade do amendoim com erros baixos.

**PALAVRAS-CHAVE:** *Arachis hypogaea* L., Redes Neurais Artificiais, Sensoriamento Remoto, Inteligência Artificial, Agricultura Digital.

## INTEGRATING ARTIFICIAL INTELLIGENCE AND REMOTE SENSING: IS IT POSSIBLE TO PREDICT PEANUT PRODUCTIVITY IN ADVANCE?

**ABSTRACT:** Productivity estimation helps in planning, decision making and management of crop resources. In view of this, the objective was to develop predictive models of peanut productivity using SR techniques and machine learning. The experiments were conducted in the state of São Paulo in the 2021/2022 harvest. In each experimental field, 20 sampling points were installed for productivity and maturation, each plot consisting of half a hectare (0.5 ha) with the same peanut cultivar. The studied areas were chosen according to the type of soil, in which three areas presented characteristics of clayey soils and the others sandy soils. Satellite images were used to calculate three vegetation indices (NDVI, GNDVI and SAVI).

To generate the predictive models, the algorithm of artificial neural networks (MLP) was used. All vegetation indices were able to predict peanut yield with low errors

**KEYWORDS:** *Arachis hypogaea* L., Artificial Neural Networks, Remote Sensing, Artificial Intelligence, Digital Agriculture.

**INTRODUÇÃO:** A estimativa de produtividade é peça fundamental para o sucesso das lavouras, pois auxilia o planejamento, a tomada de decisão e o gerenciamento de recursos da cultura (Qi Sun et al., 2021). Um dos principais gargalos para a cultura do amendoim é o gerenciamento da logística para o recebimento da produção dentro das cooperativas, tendo em vista que, nem o produtor nem as cooperativas conseguem estimar com precisão e acurácia a produtividade das áreas de amendoim. Em culturas pouco exploradas cientificamente, como o amendoim, estimar a produtividade considerando as particularidades de cultivo é de suma importância, pois permite gerar modelos de estimativa mais precisos, uma vez que possibilita a análise da interação entre genótipo e ambiente.

A estimativa de produtividade para a cultura do amendoim pode ser realizada por métodos tradicionais destrutivos, que são demorados, trabalhosos e pouco eficientes, ou de forma empírica, por meio de avaliação visual do estado da lavoura. A abordagem no monitoramento da produtividade para a maioria das culturas é baseada em modelos matemáticos agrometeorológicos (Silva et al., 2011). Entretanto, este método tem restrições para determinar a influência de fatores de produção importantes como, pragas e doenças, déficit nutricional e sanidade da lavoura. Além disso, o grande número de parâmetros que devem ser calibrados traz incertezas relacionadas às estimativas (Wallach e Genard, 1998).

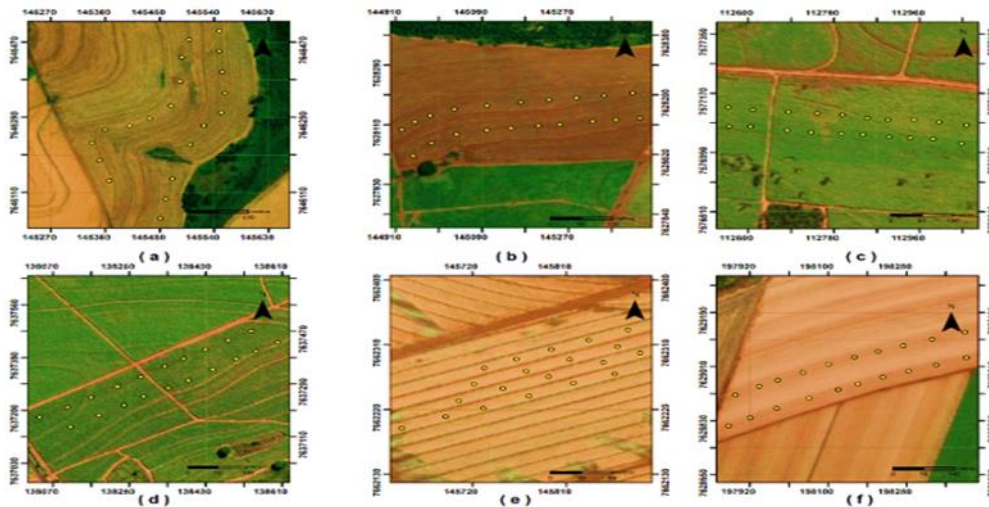
Neste cenário, o Sensoriamento Remoto (SR) e Inteligência Artificial surge com grande potencial e já vem sendo utilizado em diversas aplicações agrícolas, com o monitoramento não destrutivo, visando avaliar as condições adversas da lavoura, para otimizar as práticas de gestão de forma mais sustentável (Wolanin et al., 2019; Wheeler e Von Braun, 2013). Isso é possível, pois o SR é fundamentado na interação entre radiação e o alvo. Alterações na vegetação que afetam diretamente a atividade fotossintética e a estrutura celular, acarretam em mudanças na reflectância nos diferentes comprimentos de onda, condição esta captada pelos sensores remotos a bordo de plataformas como satélites (Pôças et al., 2020). De toda forma, atualmente é desconhecido o uso destas ferramentas para predição da produtividade do amendoim.

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, como a predição da produtividade da cultura. Diante disto, objetivou-se avaliar o uso de técnicas de SR e aprendizado de máquinas no desenvolvimento de método inovador de predição da produtividade na cultura do amendoim antes da colheita.

**MATERIAL E MÉTODOS:** Os experimentos foram conduzidos no estado de São Paulo na safra 2021/2022. Em cada campo experimental foram instalados 20 pontos amostrais para produtividade, sendo cada parcela composta por meio hectare (0,5 ha) com a mesma cultivar de amendoim (IAC OL3).

As áreas experimentais determinadas em parceria com a Cooperativa Agroindustrial (COPLANA), foram avaliadas com características de solos distintas, em que, três áreas foram em solos mais argilosos (Capão, Santa Adélia e Frutal) e três áreas com solos arenosos (Ibitinga, Santa Gertrudes e Granja). A cultivar utilizada foi padronizada para todos os

campos experimentais (IAC-OL3, grupo runner), de ciclo curto (125-130 dias após a semeadura - DAS).



**Figura 1.** Áreas de estudo para predição da produtividade do amendoim por meio de imagens de satélites em que: A) Frutal, B) Granja, C) Ibitinga, D) Santa Gertrudes, E) Santa Adélia, F) Capão.

Para as imagens de satélite foram utilizados dados do sensor da plataforma PlanetScope CubeSat. Atualmente, o PlanetScope possui 148 satélites em órbita solar, os quais possuem capacidade de coletar imagens diariamente em qualquer lugar do planeta com resolução de 3 m e possuem 4 bandas espectrais (RGB + NIR) (Planet Team, 2019).

Os índices de vegetação utilizados neste estudo são os que já foram descritos na literatura e que são aplicados para prever diferentes parâmetros agrônômicos para a cultura do amendoim, tais como, biomassa e maturação (Santos et al., 2021; Souza et al., 2022).

**Tabela 1.** Índices de vegetação (IV) utilizados para geração dos modelos de predição da produtividade.

IV *	Equação	Referência
NDVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Rouse et al. (1974)
GNDVI	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson e Merzlyak (1996)
SAVI	$(1+L) (\text{NIR} - \text{Red}) / (L+ \text{NIR} + \text{Red})$	Huete (1988)

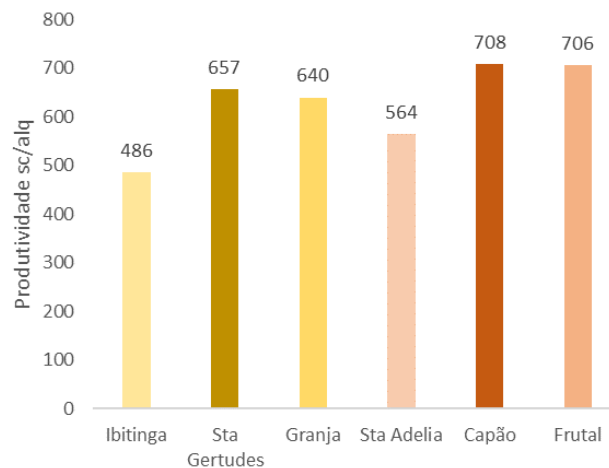
Em cada parcela foi coletado um ponto amostral de produtividade em uma área de 2 m<sup>2</sup> antes da operação de arranquio. Em seguida essas plantas foram levadas para o laboratório onde foi removido as vagens das plantas para serem pesadas e colocadas para secar em estufa a 65°C por 72 horas. Foi realizada a correção da umidade para 8% (umidade comercial) para todas as amostras.

Para prever a produtividade por meio de índices de vegetação foram utilizadas técnicas de modelagem de dados por meio de Redes Neurais Artificiais (RNAs). Foram testadas as redes MLP e RBF. As redes foram treinadas em duas situações, na primeira, todas as variáveis de entrada (índices de vegetação) foram utilizadas para estimar a produtividade (camada de saída) em cada área. Posterior a isto, foram selecionados os melhores índices de predição por área para gerar os modelos e verificar qual é a melhor data e quais os melhores IV's para prever a produtividade.

Para o treinamento e teste dos modelos, o banco de dados foi dividido em 80% para o treinamento e 20% para teste, durante a fase de treinamento 5000 RNA's foram treinadas, as dez melhores RNA's foram retidas (5 MLP). Os procedimentos de treinamento e teste dos modelos neurais foram implementados no pacote Neural Networks do software de análise de dados Statistica (Statistica 7,0, Statsoft Inc, Tulsa, OK).

A eficiência das redes foi analisada por meio de gráficos em função da acurácia a partir do erro das previsões pelo MAE (Mean Absolute Error), demonstrando por meio destes cálculos a confiabilidade dos dados obtidos das previsões das variáveis.

**RESULTADOS E DISCUSSÃO:** Este trabalho apresentou os primeiros estudos de predição da produtividade do amendoim utilizando Sensoriamento Remoto e Inteligência Artificial. Além dos modelos de redes neurais para prever a produtividade, realizou-se análises de produtividade em diferentes áreas a fim de identificar se os diferentes tipos de solos iriam influenciar na produtividade final, o que não foi evidenciado neste estudo.



**Figure 2.** Produtividade média das áreas avaliadas. Ibitinga, Sta Gertrudes e Granja (solos arenosos); Sta Adélia, Capão e Frutal (solos argilosos).

Para predição da produtividade do amendoim, inicialmente foram realizadas análises de regressão, em que, não foi possível estimar a produtividade de forma acurada utilizando modelos lineares. Então realizou-se análises com modelos não-lineares a partir do uso de Redes Neurais Artificiais (RNA's), visando a predição da produtividade (Figura 3).

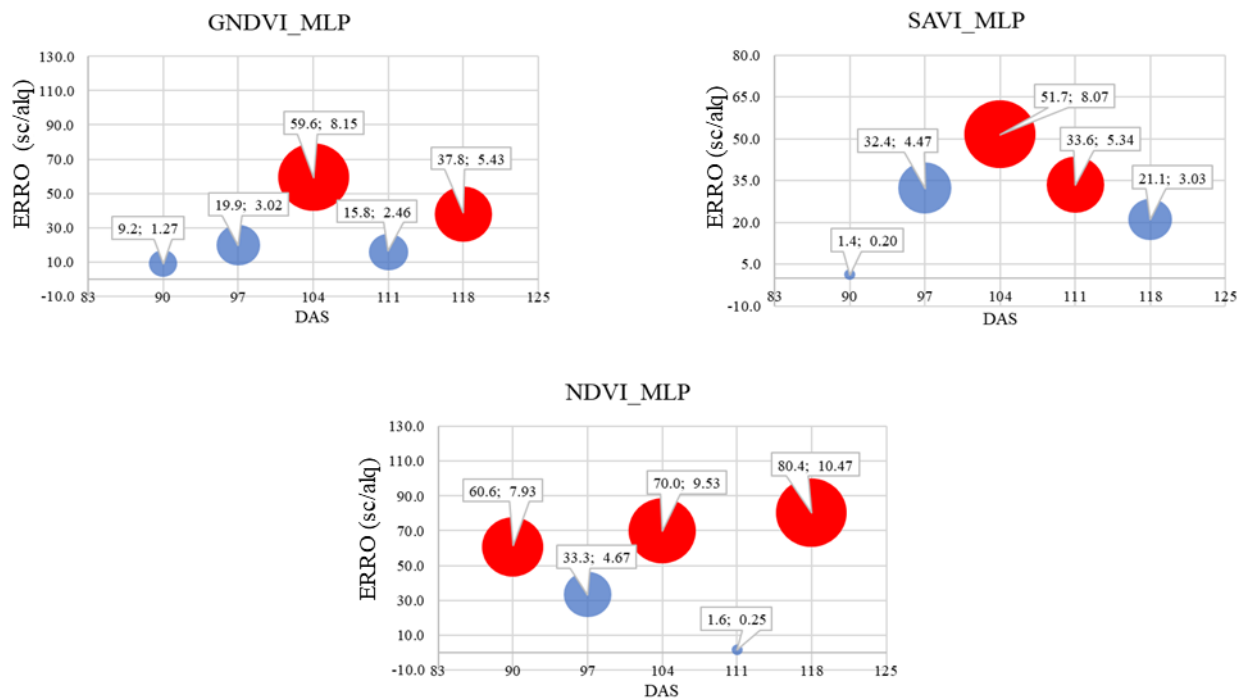
Apenas o NDVI não foi capaz de prever a produtividade para a data de 90 DAS com boa acurácia, sendo que os melhores modelos de predição nesta data foram os que usaram como entrada o GNDVI, e SAVI. A melhor rede para predição aos 90 DAS foi a MLP com o SAVI que apresentou erro na predição de 0,20%.

Aos 97 DAS, todos os índices, para ambas as redes, demonstraram bom potencial de predição de produtividade ( $1\% < \text{erro} \leq 5\%$ ). O NDVI já demonstrou grande potencial no estudo da vegetação da cultura do amendoim, sendo o principal índice na predição da maturação do amendoim utilizando imagens de satélite (Souza et al., 2022).

O GNDVI também apresentou modelos capazes de prever a produtividade aos 111 DAS do amendoim utilizando as duas redes. Tedesco et al., (2021) estudando modelos de estimativas de produtividade para cultura da batata doce, verificam erros baixos de estimativas utilizando os índices de vegetação SAVI, GNDVI e NDVI, o que demonstra que estes índices são capazes de identificar o comportamento espectral de culturas subterrâneas para fins de estimativas e previsões de produtividade.

Aos 118 DAS apenas o índice SAVI foi capaz de prever a produtividade do amendoim, enquanto o NDVI e O GNDVI apresentaram erros acima de 5%, o que para este estudo foi considerado como acurácia ruim para a predição da maturação.

Devido às características distintas da cultura do amendoim, avaliações em diferentes condições são ideais para criar modelos mais robustos, logo, a predição realizada neste estudo permite gerar boas expectativas em relação aos modelos desenvolvidos, tendo em vista que as áreas apresentaram características heterogêneas de solo, manejo e condições climáticas.



**Figure 3.** Erro de predição da produtividade por data. Para cada índice os valores indicam respectivamente, o erro em  $sc\ alq^{-1}$  e em %, representado pelo tamanho da bolha.

**CONCLUSÕES:** As médias de produtividade foram distintas entre as áreas, mas sem relação com o tipo de solo, tendo em vista que, tanto as áreas argilosas como arenosas tiveram altas e baixas produtividades.

O modelo de redes neurais (MLP) mostraram-se capaz de prever a produtividade com boa acurácia.

Todos os índices analisados neste estudo foram capazes de prever a produtividade do amendoim até 30 dias antes da colheita, o que pode auxiliar o produtor e as cooperativas de forma significativa na gestão e tomada de decisão para a cultura do amendoim.

É importante ressaltar que estes resultados são promissores, mas são necessários mais estudos para que o método se torne o mais robusto possível, a fim de validar os melhores modelos levando em consideração características de outras regiões e até mesmo diferentes cultivares.

**AGRADECIMENTOS:** Agradecemos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro (código 001) bem como a Cooperativa Agroindustrial – COPLANA e ao Laboratório de Máquinas e Mecanização

Agrícola (LAMMA) do Departamento de Engenharia e Ciências Matemáticas para a suporte de infraestrutura.

**REFERÊNCIAS:** GITELSON, A.A.; MERZLYAK, M.N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. *J. Plant Physiol*, 148, 494–500, 1996.

HUETE, A.R. A Soil-Adjusted Vegetation Index (SAVI). **Remote sensing of environment**, 25, 295–309, 1988.

PÔÇAS, I., CALERA, A., CAMPOS, I., & CUNHA, M. Remote sensing for estimating and mapping single and basal crop coefficients: A review on spectral vegetation indices approaches. **Agricultural Water Management**, 233, 106081, 2020.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. **NASA Spec. Publ**, 351, 309, 1974.

SILVA, A. S., DE SOUZA LIMA, J. S., & DE OLIVEIRA, R. B. Modelo agrometeorológico na estimativa da produtividade de duas variedades de café arábica considerando a variabilidade espacial. **Revis Irriga**, 1-10, 2011.

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.

TEDESCO, D., DE OLIVEIRA, M. F., DOS SANTOS, A. F., SILVA, E. H. C., DE SOUZA ROLIM, G., & DA SILVA, R. P. Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons. **European Journal of Agronomy**, 129, 126337, 2021.

-WHEELER, T., & VON BRAUN, J. Climate change impacts on global food security. **Science**, 341(6145), 508-513, 2013.

WOLANIN, A., CAMPS-VALLS, G., GÓMEZ-CHOVA, L., MATEO-GARCÍA, G., VAN DER TOL, C., ZHANG, Y., & GUANTER, L. Estimating crop primary productivity with Sentinel-2 and Landsat 8 using machine learning methods trained with radiative transfer simulations. **Remote sensing of environment**, 225, 441-457, 2019.