

## Uso de redes neurais para predição da maturação do amendoim com imagens de UAV

Submetido - 04 jul. 2021

Aprovado - 31 jul. 2021

Publicado - \_\_ set. 2021



[http://dx.doi.org/10.52755/sas.v.2i\(edesp2\)129](http://dx.doi.org/10.52755/sas.v.2i(edesp2)129)

**Jarlyson Brunno Costa Souza**

Doutorando no programa de Pós-graduação em Produção Vegetal pela Universidade Estadual Paulista "Júlio de Mesquita Filho". E-mail: jarlyson.brunno@unesp.br

**Samira Luns Hatum de Almeida**

Doutorando no programa de Pós-graduação em Produção Vegetal pela Universidade Estadual Paulista "Júlio de Mesquita Filho". E-mail: samira.lh.almeida.unesp.br.

**Armando Lopes de Brito de Filho**

Doutorando no programa de Pós-graduação em Ciência do Solo pela Universidade Estadual Paulista "Júlio de Mesquita Filho". E-mail: armando.brito@unesp.br.

**Mirla Silva Monteles**

Graduando em Engenharia Agrícola pela Universidade Federal do Maranhão. E-mail: mirla-s2@hotmail.com

**Leonardo Barbosa Silva**

Graduando em Agronomia pela Universidade Federal do Maranhão. E-mail: leonardoagronomo@hotmail.com

**Rouverson Pereira da Silva**

Prof. Dr. Livre-Docente da UNESP/FCAV (Produção Vegetal), Jaboticabal-SP. E-mail: rouverson.silva@unesp.br.

### RESUMO

*Técnicas de sensoriamento remoto e o aprendizado de máquinas são ferramentas importantes para o setor agropecuário, e podem trazer melhorias significativa no gerenciamento agrícola. Diante disto, objetivou-se criar um método de predição da maturação do amendoim a partir de imagens de veículo aéreo não tripulado (UAV), utilizando redes neurais artificiais (RNA). O experimento foi conduzido em talhão comercial na safra do ano 2019/20 no município de Dumont – SP. A coleta das imagens foi obtida através da câmera multiespectral Micasense RedEdge. Dois modelos de RNA's (RBF e MLP) foram utilizados para prever o índice de maturação do amendoim, com as bandas espectrais e 7 índices de vegetação sendo utilizados na camada de entrada. Para validação dos modelos, foram utilizados 20% dos dados e para treinamento 80%. O NDRE foi capaz de prever o PMI com precisão (0.90 e 0.88) e acurácia (0.06 e 0.06) para as redes MLP e RBF respectivamente. A avaliação de desempenho dos modelos indica que as redes RBF e MLP são semelhantes para prever a maturação do amendoim. Conclui-se com este trabalho que o índice de maturação pode ser previsto utilizando índices de vegetação a partir de imagens de UAV.*

**Palavras-chave:** Agricultura digital; Inteligência Artificial; Sensoriamento remoto.

## Using neural networks for peanut maturity prediction with UAV images

### ABSTRACT

*Remote sensing techniques and machine learning are important tools for the agricultural sector, and can bring significant improvements in agricultural management. In view of this, the*

Este é um trabalho de acesso aberto e distribuído sob os Termos da Creative Commons Attribution Attribution-NonCommercial-ShareAlike 4.0 International.



*objective was to create a method to predict peanut maturity from unmanned aerial vehicle (UAV) images, using artificial neural networks (ANN). The experiment was conducted in a commercial field in the 2019/20 crop year in the municipality of Dumont - SP. The collection of images was obtained through the Micasense RedEdge multispectral camera. Two ANN models (RBF and MLP) were used to predict the peanut maturity index, with the spectral bands and 7 vegetation indices being used in the input layer. For validation of the models, 20% of the data were used and for training 80%. The NDRE was able to predict the PMI with accuracy (0.90 and 0.88) and precision (0.06 and 0.06) for the MLP and RBF networks respectively. The performance evaluation of the models indicates that the RBF and MLP networks are similar for predicting peanut maturity. It is concluded from this work that maturity index can be predicted using vegetation indices from UAV images.*

**Keywords:** Digital Agriculture; Artificial Intelligence; Remote Sensing.

## Uso de redes neuronales para la predicción de la madurez del amendoim con imágenes de UAV

### RESUMEN

*Las técnicas de teledetección y el aprendizaje automático son herramientas importantes para el sector agrícola, y pueden aportar mejoras significativas en la gestión agrícola. Por ello, se ha querido crear un método para predecir la madurez del cacahuete a partir de imágenes de vehículos aéreos no tripulados (UAV), utilizando redes neuronales artificiales (RNA). El experimento se realizó en un rodal comercial en la campaña 2019/20 en el municipio de Dumont - SP. La colección de imágenes se obtuvo mediante la cámara multiespectral Micasense RedEdge. Se utilizaron dos modelos de RNA (RBF y MLP) para predecir el índice de madurez del cacahuete, utilizando las bandas espectrales y los 7 índices de vegetación en la capa de entrada. Para la validación de los modelos se utilizó el 20% de los datos y para el entrenamiento el 80%. El NDRE fue capaz de predecir el PMI con una exactitud (0,90 y 0,88) y precisión (0,06 y 0,06) para las redes MLP y RBF respectivamente. La evaluación del rendimiento de los modelos indica que las redes RBF y MLP son similares para predecir la madurez del cacahuete. De este trabajo se concluye que el índice de madurez puede predecirse utilizando índices de vegetación a partir de imágenes de UAV.*

**Palabras clave:** Agricultura digital; inteligencia artificial; teledetección.

### Introdução

O sensoriamento remoto e o aprendizado de máquinas são duas importantes ferramentas para o setor agropecuário, e podem contribuir de forma significativa com o gerenciamento dos recursos e o processo de tomada de decisão. Isso é possível devido à grande disponibilidade de dados obtidos a partir destas tecnologias, que quando transformadas em informação são de grande relevância para o monitoramento agrícola (KATTENBORN et al., 2020).

Na cultura do amendoim, um dos gargalos é a dificuldade na definição do momento ideal do arranquio baseada na maturação das vagens, uma vez que interfere diretamente na quantidade e qualidade do

produto e conseqüentemente no retorno financeiro ao produtor (ROWLAND et al., 2006). Diante da importância da maturação do amendoim, diversos métodos foram criados ao longo dos anos. No entanto, a metodologia mais difundida e aceita pelos produtores de amendoim, o quadro de maturação de Williams e Drexler (1981) é extremamente subjetiva. Além disso, a alta variabilidade presente no campo exige a coleta de muitas amostras destrutivas de amendoim, o que é trabalhoso e prejudica a produção final (ASHAPURE et al., 2019).

Visando desenvolver método mais eficiente e preciso para determinar o PMI (Peanuty Maturity Index) do amendoim, pesquisas envolvendo tecnologias de Redes Neurais Artificiais (RNA's) e Sensoriamento Remoto (SR) podem revolucionar o setor. O uso do SR oferece alternativas com sensores embarcados em UAV (Unmanned Aerial Vehicle), que permite o estudo da vegetação com alta resolução espacial por meio de técnicas (índices de vegetação) que são sensíveis às propriedades fisiológicas e morfológicas das plantas (KATTENBORN et al., 2021). Logo, o uso de plataformas de SR com o auxílio de RNA's podem criar modelos capazes de prever o PMI do amendoim de forma precisa e acurada.

Com base nisso, objetivou-se com este trabalho avaliar o potencial do UAV para prever a maturação do amendoim, utilizando técnicas de aprendizado de máquinas; além de validar o desempenho de predição da maturação utilizando bandas espectrais e índices de vegetação com dois tipos de RNA's: a perceptron multicamadas (MLP) e a função de ativação de base radial (RBF).

## **Material e métodos**

O experimento foi conduzido em talhão comercial na safra do ano 2019/20 no município de Dumont – SP. A cultivar utilizada foi a IAC OL3 tipo Runner. O solo da área experimental possui textura argilosa, sendo classificado como LATOSSOLO VERMELHO de acordo com Embrapa (2013). O experimento foi realizado em área de aproximadamente 8 ha, com

30 pontos equidistantes a 50 metros. Realizou-se avaliações da maturação do amendoim aos 75, 105, 120 e 125 dias após a semeadura (DAS).

Para a análise de maturação utilizou-se o método Peanut Maturity Index (PMI), que calcula a porcentagem de vagens maduras para cada amostra (Rowland et al. 2006). Foram retiradas todas as vagens das plantas contidas na amostra (5 plantas por ponto), obtendo-se em média 150 a 250 vagens para análise de maturação em cada ponto amostral. Em seguida, todas as vagens foram submetidas ao processo de remoção do exocarpo com o auxílio de lavadora de alta pressão em laboratório para expor a coloração das vagens (WILLIAMS E DREXLER, 1981).

Para obtenção das imagens aéreas foi realizado voo com aeronave remotamente pilotada (UAV) modelo DJI Matrice 100 (Shenzhen, China) com a câmera Micasense RedEdge-M, que captura imagens em 5 bandas espectrais: Azul (465-485nm), Verde (550-570 nm), Vermelho (658-678 nm), Infravermelho (820-860 nm) e Red Edge (712-722 nm). Os voos foram realizados à 90 m de altitudes com sobreposição lateral e frontal de 90%. Para esta altura de voo a resolução espacial da câmera foi de 7,96 cm.

Para fazer o processamento das imagens foi utilizado o software Pix4D, versão Student, que foi aplicado para gerar os ortomosaicos e a correção radiométrica das imagens. Foi realizada a extração do solo nas imagens por meio de classificação não supervisionada, a fim de evitar influências da refletância do solo nas informações geradas pelo alvo (Planta). O software utilizado foi o Qgis (QGIS Development Team, Open-Source Geospatial Foundation, Chicago, IL, EUA).

A partir dos valores de refletância extraídos dos ortomosaicos para as imagens aéreas, foram calculados os seguintes índices de vegetação: NDVI, GNDVI, MNDLI, EVI, NLI, SAVI e NDRE. Todos esses índices foram escolhidos por apresentarem grande aplicação na previsão de parâmetros agrônômicos em diversas culturas.

Dois modelos de RNA's foram utilizados para prever o índice de maturação do amendoim. As arquiteturas utilizadas foram do tipo função de

ativação de base radial (RBF) e perceptron de multicamadas (MLP). As camadas de entrada para as duas redes (RBF e MLP), foram compostas pelos índices de vegetação e bandas espectrais e a camada de saída pelo PMI. O número de neurônios variou de 1 a 20 para as redes. Foram classificados 10 modelos (5 RBF e 5 MLP) de 1000 testados

Para validação e treinamento dos modelos, o banco de dados foi dividido em 80% para treinamento e 20% para validação. Os procedimentos de treinamento e validação dos modelos das redes neurais foram implementados no pacote Neural Networks do software de análise de dados Statística (Statistica 7.0, Statsoft Inc., Tulsa, OK).

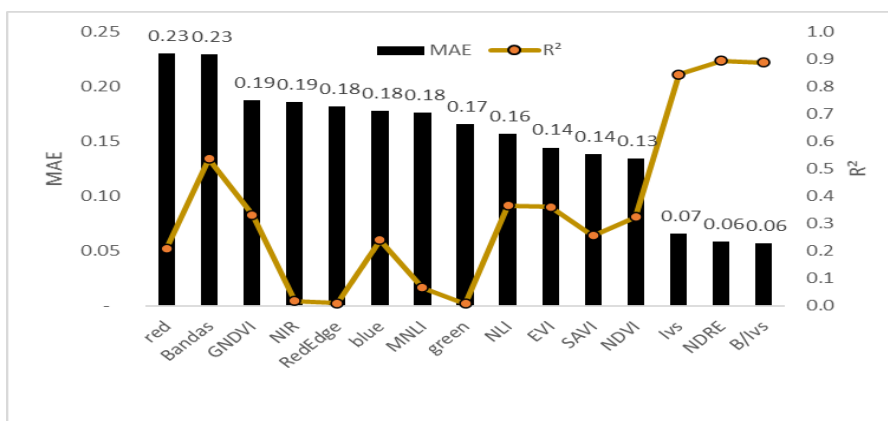
A eficiência das redes foi analisada por meio de gráficos com a relação 1:1 (SOARES et al., 2014). A acurácia foi analisada a partir do erro absoluto (MAE) e o coeficiente de determinação ( $R^2$ ) para precisão, demonstrando por meio destes cálculos a confiabilidade dos dados obtidos para prever o PMI, e ainda, foram realizadas análises comparativas entre os dados preditos com os reais.

## Resultados e discussão

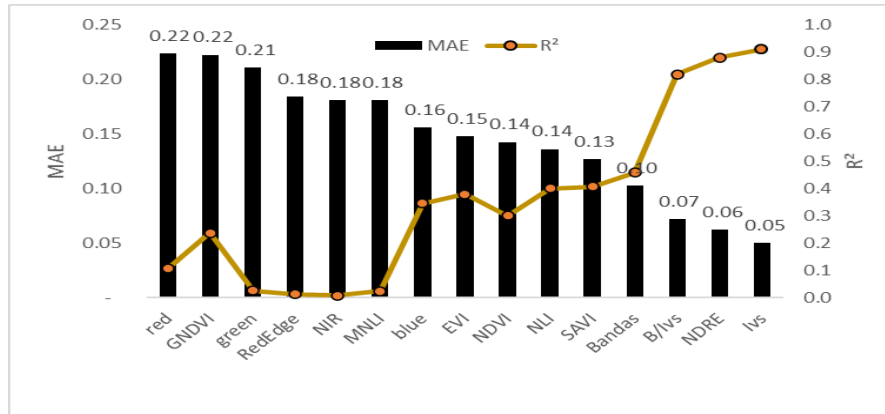
Dentre os resultados obtidos, considerou-se a melhor arquitetura de rede aquelas que apresentaram acurácia (MAE) entre 0.05 e 0.06 e precisão ( $R^2$ ) acima de 0.85. Diante disto, apenas 4 modelos demonstraram potencial para prever a maturação do amendoim (**Figura 1**). A rede RBF utilizou 3 entradas para o modelo com índices de vegetação, enquanto o modelo com bandas espectrais e índices de vegetação para a rede MLP, utilizou 5 entradas. Logo, o perfil do modelo da rede MLP foi 5:5-11-10-1:1 e para rede RBF foi 3:3-20-1:1.

Para o modelo que utilizou somente IVs, a análise de sensibilidade na **Tabela 1**, indicou o NDRE como sendo a variável mais importante da rede, seguido do NLI e SAVI. Já para a MLP que combinou índice com bandas, o NLI foi a variável mais importante seguido dos índices NDRE, MNLI, EVI e green.

A rede utilizou apenas a banda do green para prever a maturação que foi classificada como a quinta variável mais importante. A banda do green já demonstrou em diversos estudos, maior sensibilidade ao conteúdo de clorofila (clorofila a e b) e biomassa no monitoramento da produção do milho, soja, batata e trigo (SKAKUN et al., 2021; GITELSON et al., 1996; GITELSON et al., 2003; NGUY ROBERTSON et al., 2014; VINÃ et al., 2011).



(A)



(B)

**Figura 1.** Acurácia (Mean Absolute Error) e precisão (R<sup>2</sup>) da validação dos modelos para as redes MLP (A) RBF (B).

Quando os modelos foram treinados e validados utilizando as variáveis separadamente, somente o NDRE foi capaz de prever o PMI com precisão (0.90 e 0.88) e acurácia (0.06 e 0.06) para as redes MLP e RBF respectivamente (Figura 1). Este índice de vegetação já demonstrou em estudos anteriores, potencial para avaliar o comportamento de culturas com alta densidade de biomassa, pois a borda do vermelho (RedEdge - RE) o

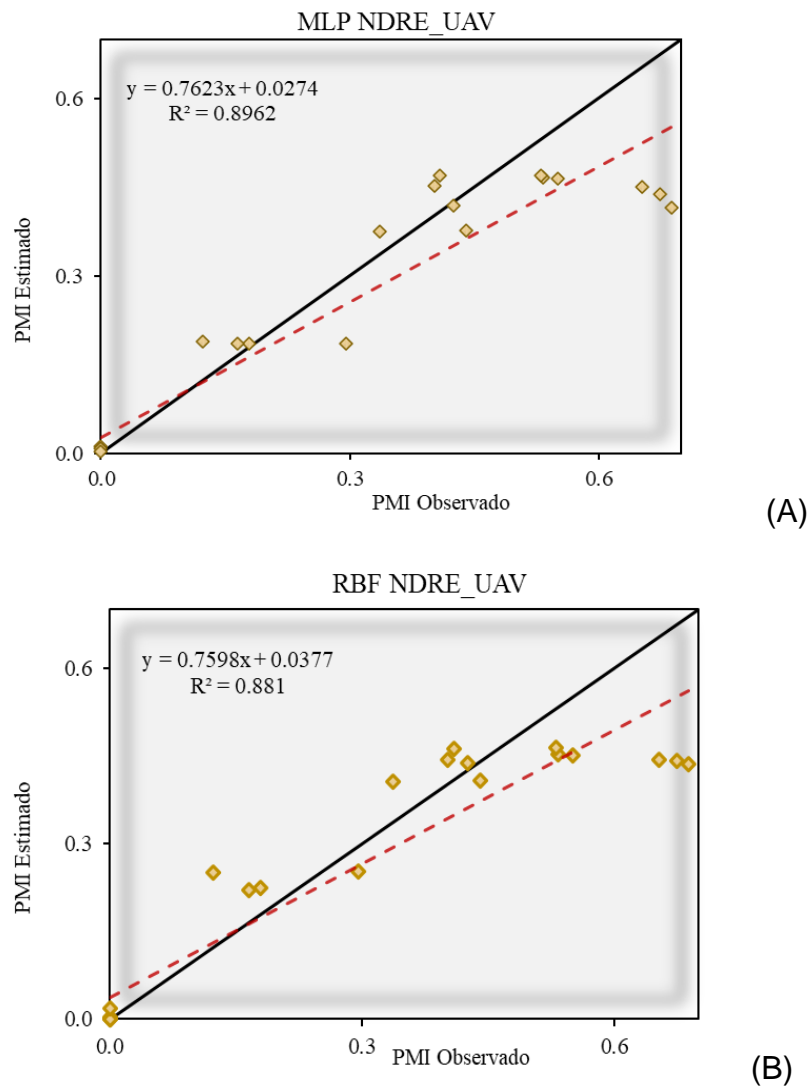
deixa menos sensível a estrutura do dossel da planta, o que torna o NDRE bastante eficiente para o estudo da vegetação (MORLIN, 2019). Estudos demonstraram que a banda RE tem alta correlação com diversos parâmetros fisiológicos da vegetação, como teor de nitrogênio, clorofila e biomassa (CLEVERS; GITELSON 2013). Outro fator que pode ter influenciado para os resultados com o NDRE é que a banda do RE também apresenta menos sensibilidade a ruídos espectrais que são gerados pela radiação e condições atmosféricas (CHO *et al.* 2008).

**Tabela 1.** Análise de sensibilidade com nível de importância das variáveis de entrada para combinações das redes MLP e RBF.

Bandas e IV's	Combinações	
	Bandas/IV's (MLP)	Índices de Vegetação (RBF)
green	5	
NDRE	2	1
NLI	1	2
MNLI	3	
EVI	4	
NDVI		
SAVI		3

V's = Índices de vegetação; MLP = Perceptron Multicamadas; RBF = Função de base de ativação radial.

Na **Figura 2** é demonstrada a avaliação de desempenho dos modelos RBF e MLP para o NDRE. O índice de maturação estimado pelo modelo resultante foi comparado com o PMI determinado pelo método Hull Scrap (método de campo). A avaliação de desempenho dos modelos indica que as redes RBF e MLP são semelhantes para predizer a maturação do amendoim com o NDRE.



**Figura 2.** Desempenho dos modelos do NDRE para as redes neurais MLP (A) e RBF (B).

## Conclusões

Este trabalho demonstrou o potencial uso de imagens de UAV para prever a maturação do amendoim utilizando o índice de vegetação NDRE. Os modelos de redes MLP e RBF mostraram-se capazes de prever o PMI com boa acurácia e precisão. Visando desenvolver métodos robustos, é importante a realização de estudos futuros que possam observar o comportamento das bandas espectrais e IV's em diferentes condições de cultivo e cultivares. Desta forma, seria possível desenvolver um software capaz de determinar o momento ideal de colheita com base em imagens de UAV.



## Referências

- Ashapure, A., Jung, J., Chang, A., Oh, S., Maeda, M., & Landivar, J. (2019). A comparative study of RGB and multispectral sensor-based cotton canopy cover modelling using multi-temporal UAS data. *Remote Sensing*, 11(23), 2757. <https://doi.org/10.3390/rs11232757>
- Cho, MA, Skidmore, AK, & Atzberger, C. (2008). Em direção a posições de borda vermelha menos sensíveis aos parâmetros biofísicos do dossel para estimativa de clorofila foliar usando dados simulados de propriedades optique Spectrales des feuilles (PROSPECT) e espalhamento por folhas inclinadas arbitrariamente (SAILH). *International Journal of Remote Sensing*, 29 (8), 2241-2255. <https://doi.org/10.1080/01431160701395328>
- Clevers, J. G., & Gitelson, A. A. (2013). Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3. *International Journal of Applied Earth Observation and Geoinformation*, 23, 344-351. <https://doi.org/10.1016/j.jag.2012.10.008>
- Embrapa—Empresa Brasileira de Pesquisa Agropecuária. (2013). *Sistema Brasileiro de Classificação de Solos* (3rd ed. Rev. ampl., p. 353). Brasília, DF: Empresa Brasileira de Pesquisa Agropecuária (Embrapa).
- Gitelson, A. A., Viña, A., Arkebauer, T. J., Rundquist, D. C., Keydan, G., & Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical research letters*, 30(5).
- Gitelson, Anatoly A.; Kaufman, Yoram J.; Merzlyak, Mark N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, v. 58, n. 3, p. 289-298, [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Kattenborn, T., Eichel, J., Wiser, S., Burrows, L., Fassnacht, F. E., & Schmidlein, S. (2020). Convolutional Neural Networks accurately predict cover fractions of plant species and communities in Unmanned Aerial Vehicle imagery. *Remote Sensing in Ecology and Conservation*, 6(4), 472-486. <https://doi.org/10.1002/rse2.146>
- 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>
- Nguy-Robertson, A. L., Peng, Y., Gitelson, A. A., Arkebauer, T. J., Pimstein, A., Herrmann, I., ... & Bonfil, D. J. (2014). Estimating green LAI in four crops: Potential of determining optimal spectral bands for a universal algorithm. *Agricultural and forest meteorology*, 192, 140-148. <https://doi.org/10.1016/j.agrformet.2014.03.004>
- Rowland, D. L., Sorensen, R. B., Butts, C. L., & Faircloth, W. H. (2006). Determination of maturity and degree day indices and their success in

predicting peanut maturity. *Peanut Science*, 33, 125–136.  
<https://doi.org/10.3146/0095->

Skakun, S., Kalecinski, NI., Brown, MGL., Johnson, DM., Vermote, EF., Roger, J.-C.; Franch, B. (2021) Avaliando a variação de rendimento de milho e soja no campo a partir de imagens de satélite WorldView-3, Planet, Sentinel-2 e Landsat 8. *Remote Sens.* 13, 872.  
<https://doi.org/10.3390/rs13050872>

Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468-3478. <https://doi.org/10.1016/j.rse.2011.08.010>

Williams, E. J., & Drexler, J. S. (1981). A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2), 134–141.  
<https://doi.org/10.3146/i0095-3679-8-2-15>