

ESTIMATIVA DE PRODUTIVIDADE DE ARROZ A PARTIR DE IMAGENS MULTIESPECTRAIS REGISTRADAS COM AERONAVES REMOTAMENTE PILOTADAS

Gabriella Santos Arruda de Lima¹, Manuel Eduardo Ferreira¹, Joelson de Souza Passos¹, João Vitor Silva Costa¹, Jepherson Correia Sales², Maik Leão dos Santos³

¹ Universidade Federal de Goiás – Laboratório de Processamento de Imagens e Geoprocessamento, Campus Samambaia, Almeida Palmeiras, s/n – Chácaras Califórnia, gabriella.arruda.lima@gmail.com, manuel@ufg.br, joelson3000@gmail.com, joaovsc17@gmail.com

² Universidade Federal de Rondonópolis, Av. dos Estudantes, 5055 - Cidade Universitária, Rondonópolis - MT, 78736-900, jepherson.sales@ufr.edu.br;

³ Universidade Federal de Viçosa – MG, Laboratório de Manejo de Doenças de Plantas, Departamento de Fitopatologia, maik.santos@ufv.br

RESUMO

O sensoriamento remoto realizado por plataformas aéreas remotamente pilotadas (RPAS, ou drone) é uma geotecnologia reconhecidamente eficaz no monitoramento agrícola, com ganhos na resolução espacial e temporal, provendo estimativas de produtividade mais precisas. Nesse trabalho busca-se comparar a acurácia de dois índices de vegetação gerados com câmera multiespectral embarcada em um RPAS para estimar a produtividade em cultivos de arroz alagado. Os índices adotados foram o tradicional NDVI e o MPRI (Índice de refletância fotoquímica modificado – específico para bandas RGB). O modelo selecionado, utilizando duas cultivares de arroz no estágio do início reprodutivo, foi baseado no NDVI, com maior correlação com a produtividade ($R^2 = 0,77$; RMSE = $0,99 \text{ t ha}^{-1}$). No entanto, evidenciou-se que o MPRI também possui alta correlação com a produtividade ($R^2 = 0,75$; RMSE = $1,11 \text{ t ha}^{-1}$), indicando que sensores baseados no espectro do visível também possuem elevado potencial na estimativa da produtividade do arroz.

Palavras-chave — RPAS, drone, produtividade, índice de vegetação.

ABSTRACT

Remote sensing performed by remotely piloted aerial platforms (RPAS or drone) is a recognized geotechnology in agricultural monitoring, with spatial and temporal resolution gains, providing more accurate productivity estimates. This work aims to compare the accuracy of two vegetation indices generated with a multispectral camera aboard an RPAS to estimate productivity in flooded rice crops. The indices adopted were the traditional NDVI and the MPRI (Modified Photochemical Reflectance Index – specific for RGB bands). The selected model, using two rice cultivars in the reproductive stage, was based on the NDVI, with the highest correlation with productivity ($R^2 = 0.77$; RMSE = 0.99 t ha^{-1}). However, it was evidenced that the MPRI also has a high correlation with productivity ($R^2 = 0.75$; RMSE = 1.11 t ha^{-1}).

¹⁾, indicating that sensors based on the visible spectrum also have a high potential to estimate the rice yield.

Keywords — RPAS, drone, productivity, vegetation index.

1. INTRODUÇÃO

A produtividade do arroz (*Oryza sativa* L.) no Brasil é em média 6,2 toneladas por hectare, com potencial produtivo superior a 10 toneladas por hectare. Na safra 2020/2021, o estado do Rio Grande do Sul atingiu recorde de produção com a menor área semeada desde as últimas onze safras. Esse significativo aumento de produção de grãos é atribuído, além das favoráveis condições meteorológicas, ao melhoramento das técnicas de manejo [1].

O aumento da produtividade de culturas agrícolas é pauta governamental, estimulada por pesquisas e extensão nos municípios. Estimar parâmetros de produção antes da colheita permite a intervenção em partes específicas das parcelas, com possibilidade de correções agrônomicas e aumento da produtividade [2]. O manejo agrônomico sustentável também visa a redução de poluentes ambientais, com respectivo ganho de produtividade. Nestes casos, o sensoriamento remoto (SR) tem sido uma poderosa ferramenta para acompanhamento das culturas agrícolas, permitindo um manejo mais preciso e oportuno [3].

A radiação registrada pelos sensores remotos (embarcados em satélites ou em RPAS) pode ser relacionada à aspectos da planta, como estado nutricional e fenológico [4]. O SR baseado em RPAS, por exemplo, aplicado na previsão de produtividade, deve abordar a interação das bandas espectrais com as plantas, por meios dos índices de vegetação (IVs), com a vantagem de obter dados em escala de detalhe (centimétrica). Neste caso, o IV passa a representar o vigor vegetativo da cultura, com alta correlação com a biomassa, atividade fotossintética, rendimento, entre outros parâmetros biofísicos [5]. Portanto, são explorados métodos de aproximação de bandas espectrais ou IVs para estimar parâmetros biofísicos da cultura, visando otimizar o monitoramento de um cultivo, ao passo que também propicia aprimoramentos do manejo agrícola [2,3].

O SR baseado em satélite ou sensor proximal (i.e., sensor de campo) possui como vantagem a possibilidade de altas resoluções espectrais com relativo baixo custo. No entanto, apresentam limitações, sendo a primeira quanto à cobertura de nuvens e resolução espacial, e a segunda quanto ao tempo gasto no manuseio e na impossibilidade da cobertura de grandes áreas, pois depende de um operador percorrer toda a área com o equipamento. A adoção de um RPAs ultrapassa tais limitações. Estudos anteriores já foram realizados utilizando dados de satélite ou sensores proximais para relacionar variáveis espectrais e produtividade. Em geral, estes apresentam resultados promissores, principalmente com o uso do NDVI, correlações e regressões [6, 7, 8]. Mais recentemente, as pesquisas estão avançando com o uso de RPAs em aplicações semelhantes [9, 10, 11, 12], explorando distintos estágios de desenvolvimento e bandas espectrais.

Neste contexto, o objetivo desse estudo foi comparar a acurácia de dois índices de vegetação, o NDVI e o MPRI, na estimativa da produtividade de arroz, baseado no uso de um RPA embarcado com câmera multiespectral.

2. MATERIAL E MÉTODOS

2.1. Local de estudo

O estudo foi conduzido na área experimental da Embrapa Arroz e Feijão, localizada na Fazenda Palmital (16° 26' 14" S, 49° 23' 50" W) no município de Goianira, Goiás (Figura 1).

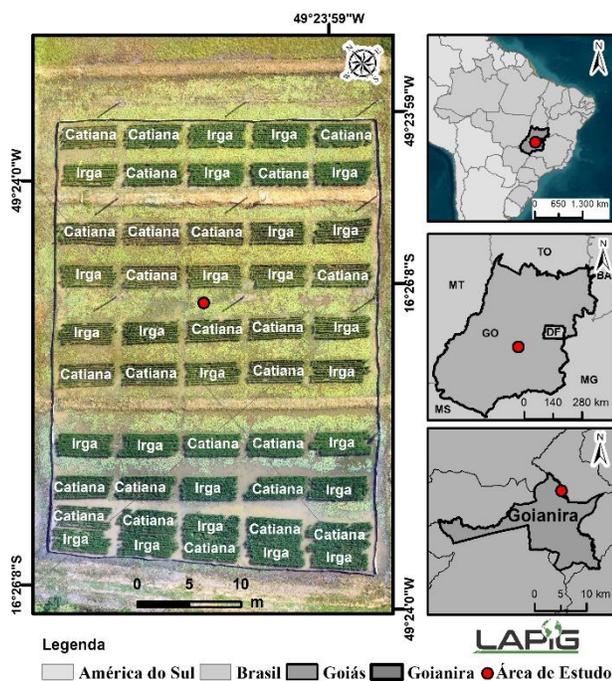


Figura 1. Localização da área de estudo no município de Goianira, Goiás, Brasil.

Esta região possui solo Gleissolo Háplico distrófico, clima do tipo Aw, Tropical Úmido, com média de 1.600 mm

de chuva anual e temperatura média de 19,30 °C. Os tratamentos constaram de duas cultivares do arroz de terras baixas (BRS Catiana e IRGA 424), cultivado em um campo inundado. Foram utilizados três níveis de Nitrogênio: 0, 50 e 180 kg ha⁻¹ em delineamento experimental de parcela subdividida com blocos casualizados com quatro repetições para cada tratamento. A semeadura ocorreu no dia 9 de novembro de 2020, com 80 sementes por metro linear espaçadas em 17 cm; a colheita foi realizada em quatro datas (01, 11, 18 e 25 de março de 2021), conforme a maturação.

2.2. Coleta e processamento de dados

Para a coleta das imagens aéreas, foi utilizado um drone multi-rotor da marca/modelo Parrot/Bluegrass, embarcado com um sensor multiespectral Parrot Sequoia, que registra imagens em quatro bandas do espectro eletromagnético, nas regiões do visível (Green e Red) e infravermelho próximo (Red Edge e NIR). Para o plano de voo, foi utilizado o software gratuito PIX4D Capture instalado em smartphone ou tablet. O processamento das fotos digitais foi realizado no software comercial Pix4D Mapper (Pix4D Inc., <https://www.pix4d.com/>), visando gerar os mosaicos aerofotogramétricos (ortoretificados e georreferenciados), base para os índices de vegetação.

Os voos foram realizados em quatro datas na safra 2020/2021 (14 e 30 de dezembro de 2020, 22 de janeiro de 2021 e 19 de fevereiro de 2021), ao longo do ciclo da cultura do arroz, a uma altitude de 30 metros acima do nível do solo, GSD (*Ground Sampling Distance*) de 3,5 cm, com 70% de sobreposição frontal e lateral, em horários sempre entre 10:00 e 14:00 para o melhor aproveitamento da incidência solar.

A partir de cada imageamento, foram gerados os índices NDVI (*Normalized Difference Vegetation Index*, Equação 1) e MPRI (*Modified Photochemical Reflectance Index*, Equação 2). O valor da média de cada um dos índices foi utilizado para correlacionar à produtividade de grãos para cada parcela em três estágios de desenvolvimento do arroz. A produtividade do arroz foi determinada a partir da coleta manual e pesagem dos grãos em torno de pontos amostrais em cada parcela agrícola.

$$NDVI = \frac{\rho_{iv} - \rho_r}{\rho_{iv} + \rho_r} \quad 1$$

$$MPRI = \frac{\rho_g - \rho_r}{\rho_g + \rho_r} \quad 2$$

Onde: ρ_{iv} é a reflectância no infravermelho próximo; ρ_r é a reflectância no vermelho; ρ_g é a reflectância no verde.

As relações lineares de melhor ajuste entre IVs e produtividade foram avaliadas por meio da análise de ajuste de curvas com o coeficiente de determinação (R^2) e a raiz quadrada do erro quadrático médio (RMSE).

3. RESULTADOS E DISCUSSÃO

3.1. Relações entre produtividade e índices de vegetação

De forma prática, os modelos que envolvem todas as cultivares do experimento são mais usuais, pois facilita o manejo agrícola. Na presente investigação foram adotadas as análises das duas cultivares do arroz, de modo separado, para verificar se havia grandes diferenças entre elas e o impacto de utilizar ambas. Além disso, foram avaliados quatro estágios do ciclo, com a finalidade de eleger o melhor momento de previsibilidade de produtividade.

Em Geral, os modelos baseados no NDVI ou no MPRI foram altamente correlacionados à produtividade ($p = 0,01$). A correlação foi inferior no início do ciclo, com pico no estágio “início reprodutivo”, e decresceu até a colheita. Com exceção das cultivares BRS Catiana, no “reprodutivo”, e Irga 424, no “início reprodutivo”, nos demais estágios de desenvolvimento os modelos que utilizaram o NDVI ($R^2 = 0,54$ a $0,83$) apresentaram resultados ligeiramente superiores aos MPRI ($R^2 = 0,41$ a $0,80$).

O NDVI obteve o melhor desempenho no estágio “início reprodutivo” para a cultivar BRS Catiana ($R^2 = 0,83$; $RMSE = 0,92 \text{ t ha}^{-1}$). No entanto, o modelo que utiliza as duas cultivares e o NDVI no período do “início do reprodutivo” ($R^2 = 0,77$; $RMSE = 0,99 \text{ t ha}^{-1}$) foi selecionado, pois também apresenta bom desempenho e favorece a aplicação em toda a área de manejo, independente da cultivar presente na parcela. Logo, o modelo selecionado é baseado na seguinte equação ($y = 21,579 \text{ NDVI} - 12,946$) do período do início do reprodutivo considerando as duas cultivares (Catiana e Irga).

Cultivar	Estágios de crescimento	NDVI		MPRI	
		R ²	RMSE (t ha ⁻¹)	R ²	RMSE (t ha ⁻¹)
Catiana	Vegetativo	0,62	2,04	0,52	2,55
	Início reprodutivo	0,83	0,92	0,80	1,04
	Reprodutivo	0,74	1,36	0,78	1,17
	Enchimento de grãos	0,59	2,16	0,47	2,79
Irga	Vegetativo	0,59	1,45	0,46	1,88
	Início reprodutivo	0,72	0,97	0,72	0,95
	Reprodutivo	0,67	1,13	0,65	1,21
	Enchimento de grãos	0,48	1,83	0,34	2,31
Duas cultivares	Vegetativo	0,60	1,74	0,51	2,23
	Início reprodutivo	0,77	0,99	0,75	1,11
	Reprodutivo	0,70	1,31	0,68	1,40
	Enchimento de grãos	0,54	2,01	0,41	2,57

Tabela 1. Coeficientes de ajustes entre IVs e produtividade em quatro estágios de desenvolvimento do arroz.

A precisão do modelo é boa em comparação a outros estudos de estimativa de produtividade com método linear. Por exemplo, [13] fizeram a correlação entre NDVI obtido de imagens de satélite, e a produtividade da cultura da soja, e relataram um ajuste com valor médio ($R^2 = 0,69$). Outros autores [14], usando um sensor terrestre na cultura do

amendoim, obtiveram correlação máxima entre NDVI e a produtividade de $R^2 = 0,60$. Semelhante a este estudo, outros autores [15], a partir de um modelo de regressão linear utilizando o NDVI proveniente de um RPAS e a produtividade do arroz no estágio de iniciação da panícula, relataram um coeficiente de regressão $R^2 = 0,73$ e $RMSE = 0,46 \text{ t ha}^{-1}$.

Na presente investigação, nas cultivares analisadas (BRS Catiana e Irga 424), o estágio “início do reprodutivo” obteve resultado superior para definir o potencial produtivo do arroz. Nesse estágio, onde o arroz tem o encabeçamento, as folhas cobrem parcial ou totalmente o solo ou a água, reduzindo assim os efeitos de fundo, principalmente na faixa do infravermelho próximo; no entanto, essa influência ainda é relatada em outros estudos [16]. Em relação à fase vegetativa, as fases “reprodutiva” e de “enchimento de grãos” possui maior requerimento de fotoassimilados, devido ao maior número de panículas, o que pode incorrer em uma maior correlação com os IVs.

Estudos anteriores revelam estágios de desenvolvimento finais com melhor desempenho na estimativa de produtividade [17]. No entanto, corroborando com os resultados aqui descritos, [5] descreveram as melhores correlações entre IV e produtividade no início do ciclo reprodutivo da cultura da soja. Logo, resultados como os descritos, que apontaram o estágio reprodutivo, representa um facilitador na estimativa de produtividade antecipada, além da possibilidade do acompanhamento real da expectativa de produção.

3.2. Mapeamento de produtividade

A produtividade estimada com o uso do modelo baseado no NDVI é apresentada em escala cartográfica de detalhe, onde a produtividade varia *pixel a pixel*, com valores entre $1,11 \text{ t ha}^{-1}$ e $8,12 \text{ t ha}^{-1}$. É possível visualizar a variabilidade espacial entre as parcelas agrícolas, bem como dentro de cada parcela (Figura 2).

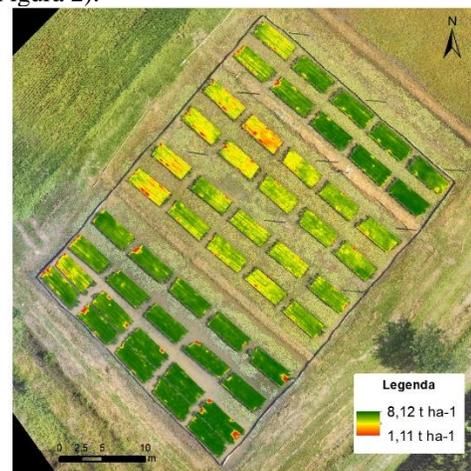


Figura 2. Produtividade estimada a partir do modelo baseado no NDVI com as duas cultivares no estágio “início do reprodutivo”.

5. CONCLUSÕES

O principal objetivo desse estudo foi abordar a diferença entre os IVs NDVI e MPRI na estimativa de produtividade do arroz, a partir de dados obtidos com um RPAS embarcado com câmera multiespectral. Foi possível gerar o modelo de estimativa de produtividade baseado na reflectância das plantas com o uso da banda do infravermelho próximo e vermelho; no entanto, o uso apenas de bandas do visível (verde e vermelho) também produziu resultados satisfatórios. De forma geral, o NDVI apresentou resultados ligeiramente superiores ao MPRI na estimativa de produtividade do arroz em cultivo alagado.

A abordagem de gerar relações significativas com a produtividade de modo espacializado pode ser empregada no manejo em taxa variável, observando as zonas de maior variabilidade espacial, contribuindo com o uso racional de nutrientes em uma escala de tempo e em nível de *pixel*.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código Financeiro 001.

8. REFERÊNCIAS

- [1] FAOSTAT, Production, Crops. Conab. Série histórica. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras?start=10>. Acesso em: Out. 2019.
- [2] Y. Hang, S. Huan, Y. Ziyang, L. Huanjun, G. Haixiang, and K. Fanchang. Estimation of rice leaf area index combining UAV spectrum, texture features and vegetation coverage. Volume (37), Issue 9, p. 64-71, 2021. <https://doi.org/10.11975/j.issn.1002-6819.2021.09.008>.
- [3] J. L. Hatfield, A. A. Gitelson, J. S. Schepers, and C. L. Walthall. Application of Spectral Remote Sensing for Agronomic Decisions. *J. Agron*, volume (100): pp. 117–131. 2008.
- [4] L. S. Shiratsuchi, Z. N. Brandao, L. E. Vicente, D. C. Victoria, J. R. Ducati, R. P. Oliveira, and M. F. Vilela. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: A. C. C. Bernardi, J. M. Naime, A. V. Resende, L. H. Bassoi, and R. Y. Inamasu. (Ed.). *Agricultura de precisão: resultados de um novo olhar*. Brasília, DF: Embrapa, 2014. p. 58-73.
- [5] F. S. Trindade, M. C. Alves, R. Noetzold, I. C. Andrade, and A. A. Pozza. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. *Revista de Ciências Agrárias*, Belém, v. 62, 2019.
- [6] N. O. Bertolin, R. Filgueiras, L. P. Venancio, and E. C. Mantovani. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. *Revista Brasileira de Agricultura Irrigada*

v.11, nº.4, p. 1627 - 1638, 2017. ISSN 1982-7679 (On-line). <https://doi.org/10.7127/rbai.v11n400567>

- [7] F. O. T. Sandrini, F. T. Leal, A. P. Coelho, L. B. Lemos, and D. L. Rosalen. *Revista Brasileira de Ciências Agrárias*. ISSN (on line) 1981-0997. Volume (1) 4, número (4), e7310, 2019. <https://doi.org/10.5039/agraria.v14i4a7310>
- [8] V. R. K. Murthy. Crop growth modeling and its applications in agricultural meteorology. In: M. V. K. Sivakumar, P. S. Roy, K. Harmsen, and S. K. Saha, (Eds). *Satellite remote sensing and GIS applications in agricultural meteorology*. Geneva: WMO, 2003. p. 235-261.
- [9] R. Mehdaoui, and M. Anane. Exploitation of the red-edge bands of Sentinel 2 to improve the estimation of durum wheat yield in Grombalia region (Northeastern Tunisia). *Int. J. Remote Sens.*, 41, 8986-9008, 2022.
- [10] A. Feng, J. Zhou, E. D. Vories, K. A. Sudduth, and M. Zhang. Quantifying the effects of soil texture and weather on cotton development and yield using UAV imagery. *Biosist. Eng.*, 193, 101-114, 2020.
- [11] M. Zhang, J. Zhou, K.A. Sudduth, and N.R. Kitchen. Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB. *Biosist. Eng.*, 189, 24-35, 2020.
- [12] Y. Gong, B. Duan, S. Fang, R. Zhu, X. Wu, Poderia. Y. And Peng. Remote estimation of rapeseed yield with unmanned aerial vehicle (UAV) imaging and spectral mixture analysis. *Plantar. Métodos*, 14, 1–14, 2018.
- [13] E. Mercante, R. A. C. Lamparelli, M. A. Uribeopazo, and J. V. Rocha. Modelos de regressão lineares para estimativa de produtividade da soja no oeste do Paraná, utilizando dados espectrais. *Engenharia Agrícola*, Jaboticabal, v. 30, n. 3, p. 504-517, 2010.
- [14] J. Deghaid, D. L. Rosalen, C. Zerbato, and C. E. A. Furlani. Correlação entre o índice de vegetação por diferença normalizada (NDVI) e características agronômicas da cultura do Amendoim. *XLII Congresso Brasileiro de Engenharia Agrícola - CONBEA* 2013.
- [15] K. C. Swain, S.J. Thomson, and H. P. W. Jayasuriya, Adoption of an unmanned helicopter for low-altitude remote sensing to estimate yield and total biomass of a rice crop. *Trans. ASABE*, 53, 21-27, 2010.
- [16] N. Yuan, Y. Gong, S. Fang, Y. Liu, B. Duan, K. Yang, X. Wu, and R. Zhu. UAV Remote Sensing Estimation of Rice Yield Based on Adaptive Spectral Endmembers and Bilinear Mixing Model. *Remote Sens.*, 13, 2190, 2021. <https://doi.org/10.3390/rs13112190>
- [17] J. Jiang, Z. Zhang, Q. Cao, Y. Liang, B. Krienke, Y. Tian, Y. Zhu, W. Cao, and X. Liu. Use of an Active Canopy Sensor Mounted on an Unmanned Aerial Vehicle to Monitor the Growth and Nitrogen Status of Winter Wheat. *Remote Sens.*, 12, 3684, 2020. <https://doi.org/10.3390/rs12223684>