

IMAGENS RGB PARA ESTIMATIVA E AVALIAÇÃO DA VARIABILIDADE ESPACIAL DA PRODUTIVIDADE DO CAFEIEIRO

Gustavo Moreira Ribeiro¹, Neiliane Aparecida da Silva¹, Hugo Gabriel Peres¹, Marco Iony dos Santos Fernandes¹, Leticia Gonçalves do Nascimento¹, Renan Zampiroli¹

¹ Universidade Federal de Uberlândia, Monte Carmelo, MG (gustavo.m.01@ufu.br)

RESUMO: O Brasil se destaca na produção de café sendo maior produtor e exportador do grão. Os cafeicultores têm aprimorado o manejo das lavouras e empregado tecnologias, como agricultura de precisão necessitando de estratégias para monitoramento e identificação da variabilidade espacial dos cultivos. Diante da necessidade de modelos para estimar a produtividade do cafeieiro e entender a variabilidade dentro da área de produção. Objetivou-se avaliar modelos de estimativa de produtividade por meio de imagem RGB para definir a variabilidade espacial desse atributo. O estudo foi conduzido em uma lavoura da cultivar Mundo Novo no município de Monte Carmelo-MG, Brasil. Foi avaliado a produtividade em 44 pontos amostrais georreferenciados. Essas medidas foram correlacionadas com a dependência espacial, as bandas RGB e índices, extraídos por meio do levantamento de imagens por drone em duas épocas de avaliação (novembro/2021) corresponde a fase de chumbinho e (janeiro/2022) granação dos frutos. A partir dos dados foram gerados modelos de regressão linear para estimativa das variáveis e posteriormente foram criados mapas de distribuição espacial da produtividade estimada e observada. A época de novembro de 2021 foi mais eficiente para estimativa da produtividade subsequente e apresentou maior relação com a variabilidade espacial da produtividade real. Modelos gerados por meio de imagens RGB de veículos aéreos não tripulados são eficientes para o monitoramento da produtividade do cafeieiro e aplicação e técnicas de agricultura de precisão.

Palavras-chave: sensoriamento remoto, veículos aéreos não tripulados, *Coffea arabica* L.

INTRODUÇÃO

O Brasil se destaca na produção de café sendo o maior produtor e exportador da *commodity*, representando um papel importante no agronegócio brasileiro (CONAB, 2024). Os cafeicultores têm cada vez mais aprimorado o manejo e empregado tecnologias, buscando maior rentabilidade no processo produtivo. Uma dessas tecnologias é o emprego de estratégias para monitorar e identificar as variabilidades espaciais da produtividade da cultura. O sensoriamento remoto é uma alternativa para estimar componentes de rendimento da cultura por meio de imagens e avaliar a distribuição espacial desse componente no talhão.

Algoritmos de aprendizado de máquina empregados para estimar NDVI por meio de imagem RGB coletados por VANT em diferentes cultivares de café, apresentaram correlação

com dados de campo sendo eficientes para avaliar o vigor vegetativo do cafeeiro e sua correlação com a produção (Campos *et al.* 2022).

Silva *et al.* (2022), avaliando a variabilidade espacial da produtividade de café encontraram uma dependência espacial forte, efeito pepita igual a zero indicando que os modelos conseguem explicar a variabilidade espacial observada e um alcance de 91,3 m.

Em um trabalho avaliando a distribuição espacial do desequilíbrio nutricional, características físicas do solo e produtividade do café conilon, observou-se que áreas de maior desequilíbrio nutricional corresponderam a áreas de baixa produtividade. Além disso área de baixa produtividade apresentavam espacialização correspondente a áreas com maior teor de areia que influencia no estresse hídrico e nutricional das plantas (Silva *et al.* 2020).

Em razão da necessidade de modelos para estimar a produtividade do cafeeiro e entender a variabilidade dentro da área de produção, objetivou-se avaliar modelos de estimativa de produtividade por meio de imagem RGB para definir a variabilidade espacial desse atributo em duas épocas de avaliação.

MATERIAL E MÉTODOS

Os dados foram coletados em uma propriedade de café na Fazenda Jataí localizada no município de Monte Carmelo-MG, na mesorregião do Triângulo Mineiro e Alto Paranaíba, Brasil (18°52'12.0"S, 47°21'43.9"O e 960 m). A lavoura avaliada foi da cultivar Mundo Novo com espaçamento de 3,8 x 0,5m, plantada em 05/12/2016 onde foram avaliados parâmetros de crescimento e colheita.

Avaliou-se 44 pontos amostrais distribuídos em blocos casualizados com 5 repetições, definidos 11 parcelas com 12 plantas sendo consideradas três plantas centrais para estimativa da produtividade. Essas plantas foram georreferenciadas por meio de GPS (Sistema de Posicionamento Global, do inglês Global Position System) por posicionamento cinemático em tempo real (RTK).

Foram realizados dois vôos nas duas épocas de avaliação com veículo aéreo remotamente pilotado (Phanthon 4 PRO) equipada com uma câmera nativa que capta azul (B) (430–460 nm), comprimentos de onda verde (G) (550–570 nm) e vermelho (R) (640–680 nm). A época do levantamento E1 (novembro/2021) corresponde a fase de chumbinho aos 21 dias após a florada, e a E2 (janeiro/2022) granação dos frutos aos 60 dias após a florada. As imagens foram processadas para a geração dos ortomosaicos no software Pix4D.

A produtividade foi avaliada por meio da colheita de três plantas em cada parcela em maio de 2022, coletando o volume e peso do café colhido, em seguida foi realizado a secagem em terreiro e posterior beneficiamento dos grãos. Por meio do peso colhido e beneficiado mensurou-se o kg/planta e realizou-se uma estimativa em (sacas/ha) considerando a população plantas/ha para cada ponto avaliado.

A partir dos ortomosaicos gerados de cada época esses foram processados no software ENVI 5.1 utilizando a ferramenta Band Math para gerar imagens dos índices estimado por meio das bandas RGB, com indicado na Tabela 1.

Tabela 1. Índices gerados a partir de imagens RGB

Índice	Equação
EXG – Excess of Green	$2G - R - B$
EXR – Excess of Red	$1,4 * R - G$
GLI - Green Leaf Index	$2G - R - B / 2G + R + B$
MGVRI - Modified Green Red Vegetation Index	$(G)^2 - (R)^2 / (G)^2 + (R)^2$
MPRI - Modified photochemical reflectance Index	$G - R / G + R$
NDVI – Normalized Difference Vegetation Estimate	$0,04 * R - 0,03 * G - 119,5 \text{ NPGR} + 118,2 \text{ NPGB} + 123,8 \text{ NPRB} + 0,25$
	$\text{NPGR} = G - R / G + R$
	$\text{NPGB} = G - B / G + B$
	$\text{NPRB} = R - B / B + R$
RGBVI - Red green blue vegetation Index	$G - (B * R) / (G)^2 + (B * R)$
TGI – Green Triangular Index	$G - (0.39 * R) - (0.61 * B)$
VEG - Vegetation	$G / (R)^{0,667} * B^{(1-0,667)}$

R=red, G=green e B=blue

Após a geração dos índices essas imagens foram submetidas a separação de bandas no Software QGIS por meio da ferramenta SCP Split. E, posteriormente, foi realizada a estimativa das respostas espectrais dos índices e das bandas para cada ponto georreferenciado. Logo após, esses dados foram tabulados associando a produtividade para cada ponto amostral. De posse dos dados foram gerados modelos baseados em aprendizado de máquina supervisionado por meio de regressão linear. Foi relacionando a dependência espacial coordenadas N e E, as bandas espectrais RGB e os índices com a produtividade, no software Minitab 19. Os modelos geraram um coeficiente de determinação R^2 e erro médio quadrático RMSE utilizado para comparar as épocas de avaliação.

Por meio dos valores de produtividade observados e estimados para cada ponto foi realizado a confecção de mapas de distribuição espacial por meio de geoestatística utilizando o plugin Smart- Map no QGIS.

RESULTADOS E DISCUSSÃO

Analisando os modelos de regressão linear gerados para a produtividade podemos observar que a E1 que corresponde a fase de chumbinho em novembro de 2021 foi mais eficiente na estimativa apresentando R^2 de 0,5816 comparado ao voo da E2 que apresentou R^2 de 0,2663, fase de granação dos frutos em janeiro de 2022. O modelo da E1 apresentou um menor erro de predição do modelo de 10,0395 sacas ha^{-1} comparado a época E2 que apresentou um erro de 13.3659 sacas ha^{-1} . Conforme descrito na Tabela 2.

Tabela 2. Métricas dos modelos lineares em função das épocas de voo para predição de parâmetros de produtividade

Voo	R^2	RMSE
E1	0.5816	10.0395
E2	0.2663	13.3659

R^2 = coeficiente de determinação, RMSE = erro médio quadrático

Em estudo avaliando a correlação de índices NDVI, SAVI e NDWI com a produtividade de café gerados por meio de imagem do satélite, observou-se que a fase de dormência dos botões florais e início da floração (julho a setembro) foi melhor para determinar a produtividade, e o NDVI foi o melhor com R^2 variando de 58 a 89% (Nogueira et al., 2018).

Analisando os mapas de produtividade, observa-se que a real apresentou maior produtividade na região sudeste (SE) dentro da classe maior que 80 sacos ha^{-1} , na porção mediana da área a produtividade esteve dentro da classe de 70 a 75 sacos ha^{-1} e na porção noroeste (NW) de 65 a 70 sacos ha^{-1} . Conforme observado na Figura 1.

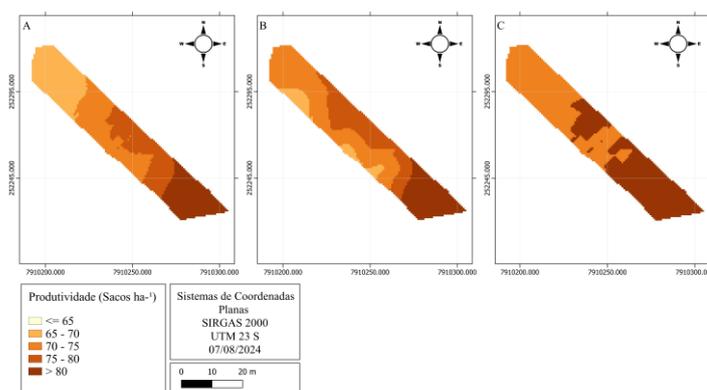


Figura 1. Mapa de interpolação da produtividade real (A) e obtida por modelos de predição na época 1 (B) e época 2 (C)

A época 1 foi mais próxima da produtividade real. Discriminando bem as regiões de alta produtividade acima de 80 sacas ha⁻¹ na porção sudeste (SE), a porção mediana esteve entre 70 a 75 sacas ha⁻¹, porém a região noroeste da área (NW) foi superestimada na ordem de 70 a 65 sacas.

A época 2 foi menos eficiente em estimar a produtividade real classificando a área em duas classes de produtividade maior que 80 sacas ha⁻¹ em metade da área na porção sudeste (SE) e na ordem de 70 a 75 sacas ha⁻¹ na porção mediana noroeste (NW).

A estimativa da época mostra que imagens RGB obtidas por meio de VANT's são eficientes na estimativa da produtividade da área. Além disso pode ser utilizada como ferramenta de espacialização da variabilidade da produção nos talhões, para suportar a investigação dessa variação e definir zonas de manejo nos talhões de café.

CONCLUSÕES

A análise de imagens RGB obtidas através de veículos remotamente pilotados são uma alternativa para estimativa da produtividade e predição de ambientes de manejo na lavoura cafeeira, podendo ser empregadas nas técnicas de agricultura de precisão para a cultura.

O levantamento de imagens da E1 em novembro de 2021, que corresponde a 21 dias após a florada do café foi mais eficiente para estimativa da produtividade subsequente.

REFERÊNCIAS

CAMPOS, G. A. De O. *et al.* The coffee NDVI modeling using built-in RGB passive sensor in UAS. **Theoretical And Applied Engineering**, v. 6, n. 3, p. 1-11, 2022.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira de café**. Segundo levantamento. Brasília, DF, v.11, n.2, maio 2024. Disponível em: <https://www.conab.gov.br/info-agro/safra/cafe>. Acesso em: 15 jul. 2024.

SILVA, H. G. da *et al.* Análise espacial dos atributos químicos do solo e geração de mapas de aplicação de fertilizantes e corretivos na Cultura do Café. **Research, Society And Development**, v. 11, n. 12, p. e524111234997, 2022.

SILVA, M. B. da *et al.* Nutritional balance and its relationship to yield in a coffee field: inferences from geospatial analysis. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 24, n. 12, p. 834-839, 2020.

Nogueira, S. M. C. *et al.* Relationship between coffee crop productivity and vegetation indexes derived from oli / Landsat-8 sensor data whit and without topographic. **Engenharia Agrícola**, v. 38, n. 3, p. 387-394, 2018.