

Estudo de Caso 7 - Imagens Aéreas na Avaliação do Vigor e Estimativa de Produtividade do Algodoeiro na Fazenda Pamplona, Cristalina, GO

Ziany Neiva Brandão
Célia Regina Grego
João Henrique Zonta

Introdução

Nas últimas décadas, a Agricultura de Precisão (AP) tem feito uso dos avanços nas áreas de engenharia. Isso tem facilitado a obtenção de dados para aplicações em sensoriamento remoto, com o fornecimento contínuo de imagens de satélite e o uso de sensores altamente precisos na aerofotogrametria, em vôos tripulados, ou com sensores de resolução elevada instalados em veículos aéreos não-tripulados (VANTs). Imagens de satélites estão disponíveis gratuitamente, com resolução temporal cada vez melhor. Essas imagens fornecem dados para gerenciamento de áreas florestadas e de culturas agrícolas, com estimativa da produtividade/rendimento de grãos no mundo inteiro.

Embora a média resolução de satélites gratuitos, em geral, não seja suficiente para estimar a produtividade por si só, em algumas culturas, satélites comerciais possuem resoluções de apenas alguns centímetros, como exemplos, o GeoEye-1, com imagens pancromáticas de 40 cm, atualizadas a cada três dias, ou o WorldView-3, que fornece imagens pancromáticas com 31 cm, fornecidas diariamente (Liu et al., 2006, 2016; Wang et al., 2016; European Space Agency, 2021). Entretanto, mesmo as imagens de satélite de média resolução, quando combinadas com imagens suborbitais, como as adquiridas por câmeras instaladas em VANTs, podem fornecer correlações significativas com produtividade/rendimento de grãos da cultura agrícola em observação, desde que sejam usadas técnicas específicas, como a fusão de imagens, e poderosas ferramentas computacionais como *machine learning*, por exemplo, melhorando muito a classificação e os índices de vegetação (IVs) obtidos (Yang et al., 2017; Tang et al., 2018; Padró et al., 2019; Zhao et al., 2019).

Atualmente, os VANTs comerciais têm usado câmeras de alta-resolução e ferramentas on-line de tratamento dos dados que permitem o monitoramento de uma cultura no momento desejado, reduzindo alguns problemas na aquisição de imagens de satélites como a presença de nuvens ou com data de passagem fora do estágio fenológico que se quer avaliar. Mesmo equipados com sensores de alta resolução, a coleta de dados baseada em Vants ainda é de baixo custo, enquanto que os *orthomosaicos* (imagens aéreas de alta resolução, adquiridas com sensores instalados em aviões pilotados) possuem também custo-benefício adequado para produtores com grandes áreas (Yang et al., 2017).

Câmeras RGB instaladas em VANTs comerciais têm sido usadas na avaliação da germinação e no monitoramento do vigor das plantas, além da estimativa da produtividade do algodoeiro (Brandão et al., 2014a; Chu et al., 2016; Chen et al., 2018; Mazzia et al., 2020). E as informações, quando combinadas com alguns sensores, ou informações adicionais obtidas por sensores proximais no campo, podem oferecer melhor resposta espectral.

Os dados obtidos por sensoriamento remoto têm sido usados no desenvolvimento de IVs como indicadores do crescimento das plantas, avaliação nutricional e predição da produtividade/rendimento de grãos da cultura (Eitel et al., 2008; Brandão et al., 2014a; Mahajan et al., 2014). O gerenciamento da adubação nitrogenada em grandes áreas é uma atividade complexa. Devido à alta exigência do algodoeiro (*Gossypium hirsutum*) em nitrogênio (N), a gestão desse nutriente é uma das mais

importantes práticas em sistemas de alta produtividade, pois tanto a deficiência como o excesso de N influenciam negativamente o crescimento da planta, a retenção de frutos, a qualidade da fibra e a produtividade (Reddy et al., 2004; Rochester et al., 2012; Huang et al., 2013; Brandão et al., 2014b; Zonta et al., 2017).

Para avaliação das condições da cobertura vegetada e estimativa da produtividade, muitos pesquisadores utilizam os IVs obtidos por meio da refletância espectral. Esses índices são sensíveis às diferenças do vigor da cultura, e muitas vezes, dependendo da resolução do sensor e do estágio fenológico da cultura, podem explicar até 90% da variabilidade espacial do cultivo com relação às características bioquímicas e biofísicas do mesmo (Zhao et al., 2005; Shiratsuchi, et al., 2014).

O objetivo deste trabalho foi avaliar a capacidade de índices de vegetação obtidos através de imagens do satélite Sentinel-2, por imagens aéreas de alta resolução e imagens RGB obtidas em VANTs, na estimativa da produtividade do algodoeiro no cerrado de Goiás, monitorando o vigor das plantas através da variabilidade espacial de dois IVs, o MPRI (*Modified Photochemical Reflectance Index*) e o NDVI (*Normalized Difference Vegetation Index*) em diferentes estádios fenológicos.

Material e Métodos

Localização e cultura

O trabalho foi conduzido em condições de campo na Fazenda Pamplona, localizada no município de Cristalina, GO, no nordeste do estado. As áreas experimentais utilizadas em dois anos foram de 31,8 ha em 2019 (Lavoura G) e 30,8 ha em 2020 (Lavoura E), cujas coordenadas centrais são 16°15'06"S/47°38'18"W e 16°10'15"S/47°38'02"W, respectivamente. Por motivos didáticos, neste trabalho trataremos apenas da primeira área (G).

A Fazenda Pamplona utiliza o Sistema de Plantio Direto (SPD) e faz rotação de culturas em seus talhões, usando sempre os sistemas em sucessão de milho-soja-algodão, ou apenas soja-algodão, em anos intercalados, o que, naturalmente, deixa um efeito residual cumulativo das adubações no solo. Com tecnologia elevada, a fazenda mantém o histórico de adubações, mapas de produtividade/rendimento de grãos e captura de imagens aéreas, o que facilita as avaliações.

Os solos da região são, predominantemente, classificados como Latossolo vermelho-amarelo, de argiloso a muito argiloso, e a altitude média na área experimental é de 968 m. O período chuvoso vai de outubro a março, tendo sido registrada, durante o ciclo da cultura na safra 2019, altura total de 670,5 mm, sendo esta apenas a metade da pluviometria média anual para a região.

Planejamento e coleta de dados

Antes do preparo do solo para instalação do experimento, foram analisadas as imagens da safra anterior e os mapas de produtividade, conforme ilustrado na Figura 1A para o talhão G. Assim, após reunião com agrônomos, equipe técnica e a gerência da fazenda, foram escolhidas áreas e tratamentos para experimentação, usando quatro doses de N (0, 100 kg de N ha⁻¹, 200 kg de N ha⁻¹ e 300 kg de N ha⁻¹). Durante a safra 2019, foi usado o sistema de aplicação em faixas, onde, em cada uma delas, foi aplicada apenas uma dose de N, sendo consideradas quatro repetições em uma faixa. Essa divisão facilitou o trabalho da aplicação para a fazenda, enquanto que, para a pesquisa, considerou-se que a variabilidade do solo na faixa de 575 metros de comprimento fosse suficiente para as quatro repetições.

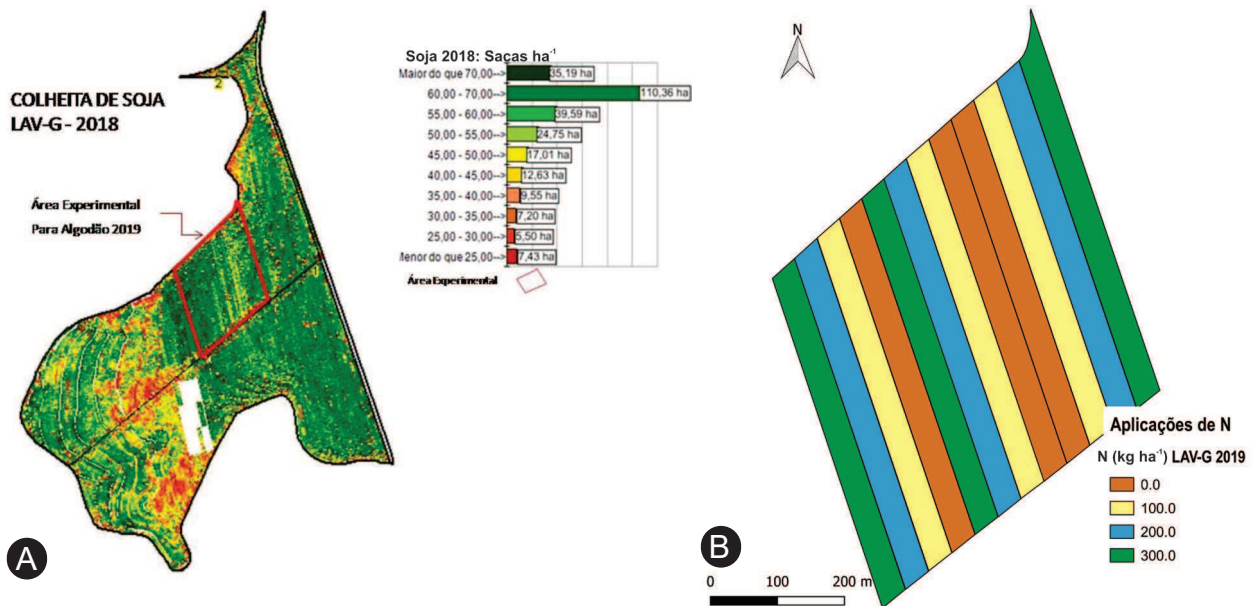


Figura 1. Planejamento do experimento on-farm no Talhão G da Fazenda Pamplona, Cristalina, GO: A) Mapa de rendimento de grãos da soja (sacas ha⁻¹) em 2018. Fonte: SLC Agrícola; B) Projeto de aplicação de nitrogênio (N) no experimento, com uma malha de 48 pontos.

Nessa área de 31,8 ha foram programadas 12 faixas de aplicação, conforme faixas coloridas apresentadas na Figura 1B, com a divisão em uma malha de 48 subáreas, medindo aproximadamente 0,66 ha cada, que foram georreferenciadas com um GPS 76CSx da Garmim, e tiveram seus pontos centrais determinados, sendo esses a base para a coleta de solos e de todas as informações referentes à subárea. As dimensões foram definidas conforme as bitolas do maquinário disponível e visando a que as parcelas tivessem tamanho suficiente para a obtenção de imagens com resolução espacial adequada às modalidades de sensoriamento remoto para fins de AP, como as advindas dos sensores gratuitos dos satélites Sentinel-2A e B. Para a geração dos *shapfiles* de contorno da área, foi utilizado inicialmente o software GPSTrackmaker® e a confecção dos mapas de prescrição foi realizada no QGIS 2.18, software SIG *opensource*. Os mapas de prescrição da adubação em taxa variável foram enviados à fazenda desde a primeira aplicação, na semeadura.

Antes da semeadura, foram coletadas oito subamostras de solo, na profundidade de 0-20 cm, em torno do ponto central georreferenciado, e o material foi levado ao Instituto Brasileiro de Análises (IBRA) para realização das análises dos atributos químicos e físicos do solo (areia, silte e argila). As metodologias de quantificação dos teores desses atributos do solo foram as mesmas utilizadas pela Claessen (1997). A adubação nitrogenada foi realizada em três épocas (na semeadura, aos 45 dias e aos 70 dias após a emergência - DAE). Os outros nutrientes foram aplicados de maneira uniforme para a área, tendo sido seguida a indicação de adubação da fazenda baseada na análise de solo e na expectativa de produtividade da cultura.

O algodão foi semeado em dezembro de 2018 com espaçamento de 0,76 m e 15 plantas m⁻¹, em regime de sequeiro. Os dados diários de temperatura (máxima, média e mínima), umidade relativa, radiação solar e precipitação pluvial foram obtidos na estação meteorológica localizada dentro da fazenda Pamplona.

A escolha das épocas de avaliação levou em conta as datas de passagem de satélites e o estágio fenológico em que as plantas se encontravam. Assim, foram coletadas amostras foliares e realizadas medições com sensores proximais em três épocas distintas, aos 60 DAE, 100 DAE e 140 DAE quando foram adquiridas imagens do sensor Sentinel-2 (A e B). Cada data representou uma fase fenológica distinta do algodoeiro, com a primeira registrando o início da floração, a segunda, a frutificação

(enchimento das maçãs) e a terceira, a abertura dos capulhos. Imagens RGB foram obtidas nas duas primeiras medições, usando equipamento Phantom 4[®] comercial. A orthophoto de alta resolução foi obtida em março do ano anterior, na semeadura da soja (Figura 2A), e serviu de comparativo para as imagens obtidas por meio de drone e as imagens de satélite.



Figura 2. (A) Imagem aérea da área utilizada para realização de ensaio on-farm com cultivo de soja na safra 2018. (B) Imagem do algodoeiro obtida com câmera RGB aos 60 DAE, em experimento na Fazenda Pamplona, Cristalina, GO.

Tratamento e geração de índices de vegetação

As bandas espectrais do Sentinel-2 usadas neste trabalho corresponderam aos canais 3, na faixa de 540 nm-570 nm, cuja reflectância, neste trabalho, associamos à denominação de ρ_G , canal 4 operando em 650 nm-680 nm (ρ) e 8,780 nm-900 nm (ρ_{NIR}).

Após a correção do georreferenciamento, foi feita a calibração radiométrica das imagens e as mesmas foram posicionadas no hemisfério sul. Posteriormente, foi corrigido o georreferenciamento de todas as imagens, tomando como base uma imagem orthorretificada. As refletâncias foram quantificadas nas regiões do visível e infravermelho próximo, que serviram para caracterização dos IVs. Neste trabalho, para fins comparativos com as imagens e a produtividade, foram usados o NDVI (*Normalized Difference Vegetation Index*) criado por Rouse Junior et al. (1974) e sendo, até hoje, o índice de referência para avaliação do vigor de uma cultura, dado pela seguinte equação:

$$NDVI = (\rho_{NIR} - \rho_R) / (\rho_{NIR} + \rho_R) \quad (1)$$

e o MPRI (*Modified Photochemical Reflectance Index*), proposto por Yang et al. (2008). O MPRI usa as bandas do verde, B3 (G) e Vermelho, B4 (R), sendo usado para comparar imagens de satélite com imagens RGB obtidas por câmeras digitais. Foi desenvolvido para estimativa do estágio fenológico de culturas e áreas florestadas devido a sua sensibilidade aos tons de verde e amarelo. Muito usado para classificação em imagens multiespectrais, esse índice pode também ser chamado de Green NDVI (GRVI) e é dado pela seguinte expressão (Yang et al., 2008):

$$MPRI = (\rho_G - \rho_R) / (\rho_G + \rho_R) \quad (2)$$

Colheita e mapa de produtividade

A produtividade do algodão foi quantificada com colheita mecanizada, utilizando a colhedora de algodão modelo John Deere[®] 9996, que possui sistema GreenStar[®] HarvestDoc[®] integrado.

Esse sistema é composto de sensor de rendimento do tipo fluxo ultrassônico, monitor de dados (Monitor GreenStar™ 2), cartão de armazenamento de dados (Keycard) e antena receptora de Sistema de Posicionamento Global (GPS) com sinal diferencial, receptor StarFire™. Os dados de produtividade, latitude, longitude e altitude (m) foram gravados em intervalos de 3 segundos. Os dados foram exportados em formato *shapefile* para tratamento, limpeza e filtragem. A colheita do algodoeiro ocorreu em julho de 2019, sendo gerado um mapa geoespacializado, com a produção convertida em kg por hectare.

Resultados e Discussão

Em 2019 houve poucas chuvas na região, embora na época de semeadura (dezembro de 2018) ocorreu precipitação pluvial elevada, tendo sido registrados 153,8 mm no mês de dezembro e 254,5 mm em novembro, na área do experimento. Isso permitiu que, em fevereiro de 2019, o algodoeiro já estivesse com uma média de altura de 84,8 cm e em início da floração (Figura 2B). Em fevereiro de 2019, durante a primeira medição, não foi possível obter imagens de satélites, pois havia grande formação de nuvens, levando a análise da imagem na data mais próxima, ou seja, dia 03 de março, sendo a mesma seis dias após a medição em campo. Como exemplo, uma imagem na época da medição com o Sentinel-2 apresenta nuvens a sudoeste, prejudicando a análise de parte do experimento, como mostrado na Figura 3 para o índice MPRI.

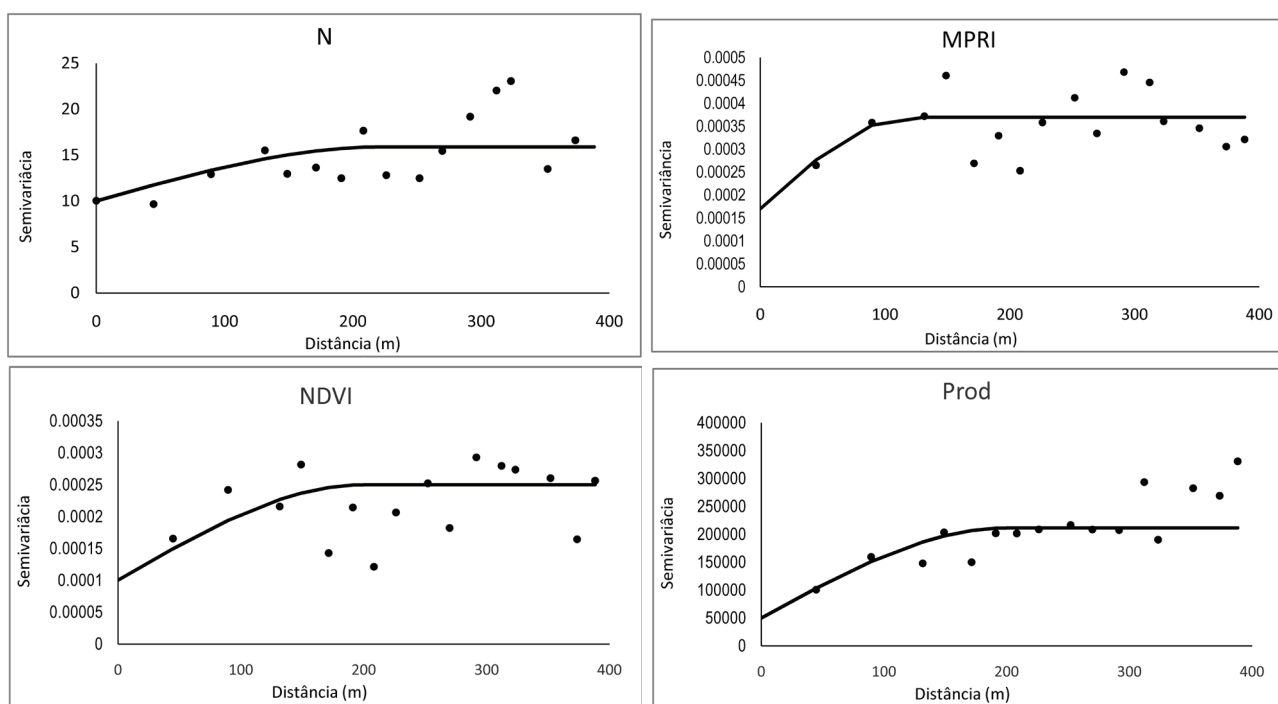


Figura 3. Semivariogramas preditos e ajustados dos dados de produtividade do algodoeiro (Prod), índices de vegetação (*Modified Photochemical Reflectance Index* – NDVI e *Modified Photochemical Reflectance Index* - MPRI), obtidos por imagens do Sentinel-2, e conteúdo foliar de nitrogênio no algodoeiro (N) em experimento on-farm na Fazenda Pamplona, Cristalina, GO.

Os dados foram submetidos à análise estatística descritiva, para verificar possíveis discrepâncias, e à normalidade nos dados (Tabela 1). Foram quantificadas as correlações entre os dados de nitrogênio foliar, produtividade e índices de vegetação obtidos por satélite e por aerofotogrametria. A análise geoestatística foi realizada por meio da construção e ajuste de semivariogramas (representação gráfica da variação de um conjunto de dados em relação à distância indicando ou não a existência de variabilidade espacial, segundo Grego et al., 2014) e interpolação por *krigagem* (método utilizado

em geoestatística para interpolação de dados) ordinária utilizando o software R (Oliver; Webster, 2014; R Foundation..., 2021).

Tabela 1. Estatística descritiva para dados produtividade (PROD), índices de vegetação (*Modified Photochemical Reflectance Index* – NDVI e *Modified Photochemical Reflectance Index* - MPRI), obtidos por imagens do Sentinel-2, e conteúdo foliar de nitrogênio (N) no algodoeiro em experimento on-farm na Fazenda Pamplona, Cristalina, GO, para uma malha de 48 subáreas.

| Variável | Média | Variância | Desvio padrão | Coefficiente de variação CV | Minímo | Máximo | Skewness | Kurtosis |
|----------|-------|-----------------------|-----------------------|-----------------------------|--------|--------|----------|----------|
| N | 38,63 | 14,75 | 3,841 | 10,01 | 31,05 | 44,10 | -0,3007 | -0,4347 |
| NDVI | 0,879 | 2,05x10 ⁻⁴ | 1,40x10 ⁻² | 1,659 | 0,846 | 0,918 | -0,3227 | -0,3874 |
| MPRI | 0,476 | 3,30x10 ⁻⁴ | 1,18x10 ⁻² | 16,65 | 0,430 | 0,493 | -0,0234 | -0,3136 |
| PROD | 4.937 | 2,93x10 ⁵ | 541,4 | 10,97 | 3.890 | 6.028 | 0,2973 | -0,7517 |

A análise da variabilidade espacial foi realizada por meio da geoestatística. Os semivariogramas foram ajustados com o modelo matemático de melhor correspondência (Tabela 2). Os programas computacionais e procedimentos para construção e ajuste do modelo do semivariograma foram baseados nos softwares R e GEOEST. O grau de dependência espacial foi classificado como fraco, moderado e forte (Vieira et al., 2002; Oliver; Webster, 2014; R Foundation..., 2021).

Tabela 2. Parâmetros de ajuste dos semivariogramas das variáveis produtividade (PROD), índices de vegetação (*Modified Photochemical Reflectance Index* – NDVI e *Modified Photochemical Reflectance Index* - MPRI), obtidos por imagens do Sentinel-2, e conteúdo foliar de nitrogênio no algodoeiro (N), obtidas para 48 pontos em experimento on-farm na Fazenda Pamplona, Cristalina, GO.

| Variável | Modelo | Efeito Pepita (Co) | (C1) | Alcance (a) | r ² | gd | RMSE |
|----------|----------|--------------------|---------|-------------|----------------|-------|-----------------------|
| N | esférico | 10,01 | 6,196 | 231,27 | 0,236 | 38,74 | 0,208 |
| NDVI | esférico | 0,0001 | 0,00015 | 200 | -0,166 | 60,00 | 6x10 ⁻¹¹ |
| MPRI | esférico | 0,00016 | 0,00019 | 120 | 0,131 | 55,15 | 6,6x10 ⁻¹¹ |
| PROD | esférico | 5.000 | 15.000 | 200 | 0,409 | 75,00 | 1.067,10 |

As variáveis apresentaram dependência espacial para os valores próximos entre si a uma distância de até 232 m, aproximadamente, conforme apresentado na Tabela 2 para os valores dos ajustes dos parâmetros dos semivariogramas que estão apresentados na Figura 3. Após a identificação da dependência espacial, foram estimados os valores para toda a área experimental por meio da *krigagem* ordinária.

Os valores estimados formaram a base para a criação dos mapas interpolados, em função das coordenadas geográficas, permitindo a visualização da variabilidade para cada variável, em toda a área de estudo. Os mapas construídos no QGIS 2.18 são apresentados na Figura 4 para os índices de vegetação obtidos por imagem de satélite, com passagem em 16 de março, o nitrogênio foliar e a produtividade, coletados na área experimental.

Mesmo com o algodoeiro ainda no início da floração, pôde-se observar, por meio dos mapas interpolados, a resposta adequada dos índices de vegetação, mostrando-se como estimadores adequados da produtividade. Essa capacidade preditiva foi confirmada por meio das equações de regressão, que seguiram o modelo polinomial para todas as variáveis. É importante observar que nem sempre foi possível obter imagens de satélite na data planejada, pois pôde haver presença de nuvens, como apresentado na Figura 5A para o MPRI obtido na imagem de satélite do dia 24-02-2019, onde o canto inferior, à sudoeste, teve sua área coberta por nuvens.

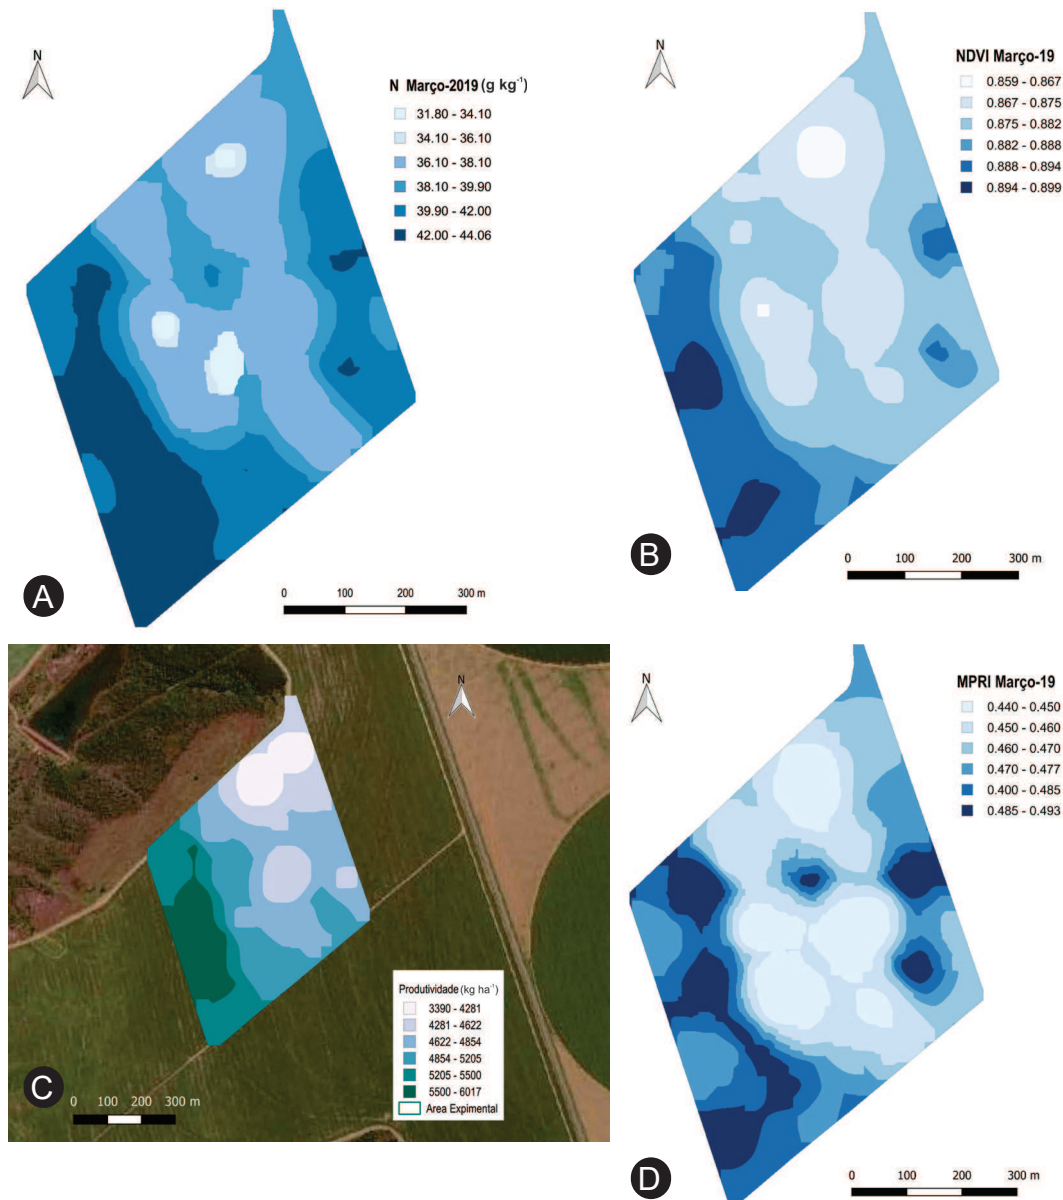


Figura 4. Mapas com dados obtidos por *krigagem* ordinária após análise geoestatística. Dados do campo ou imagens de satélite no experimento on-farm, do Talhão G da Fazenda Pamplona, Cristalina, GO: A) Nitrogênio foliar do algodoeiro; B) Índice de Vegetação Por Diferença Normalizada (NDVI) de imagem Sentinel-2; C) Mapa da produtividade; D) *Modified Photochemical Reflectance Index* - MPRI de imagem Sentinel-2.

Fonte: (C) Google Earth (2021).

Os mapas de produtividade e as imagens de alta resolução geraram grandes quantidades de dados e, por isso, os dados foram cuidadosamente preparados e seus erros retirados, antes de qualquer análise, sob pena de haver uma avaliação errônea. Assim, na preparação dos dados, foi necessário avaliar a distribuição dos mesmos, optando-se por usar análise multivariada, e nela a análise das componentes principais, que tem sido muito usada em AP (Ivosev et al., 2008; Manly; Alberto, 2016).

Inicialmente, foi avaliada a distribuição dos valores, como o histograma apresentado na Figura 5 para a produtividade. Nesse caso, foi possível observar a ocorrência de distribuição normal dos valores, indicando variação adequada para o procedimento de *krigagem*. Após a primeira avaliação da distribuição dos dados, foram localizados possíveis *outliers*. Para isso, utilizou-se o método de seleção de pontos que ultrapassaram o segundo e o quarto quartil do conjunto de dados (Oliver; Webster, 2014). Foi, então, realizada uma análise da correlação de Pearson entre a produtividade

e a imagem RGB obtida por VANT durante a última semana de fevereiro. Dessa imagem, depois de limpa e recortada, foram extraídas as três bandas (R, G e B), possibilitando a preparação do mapa do MPRI, conforme apresentado na Figura 5C.

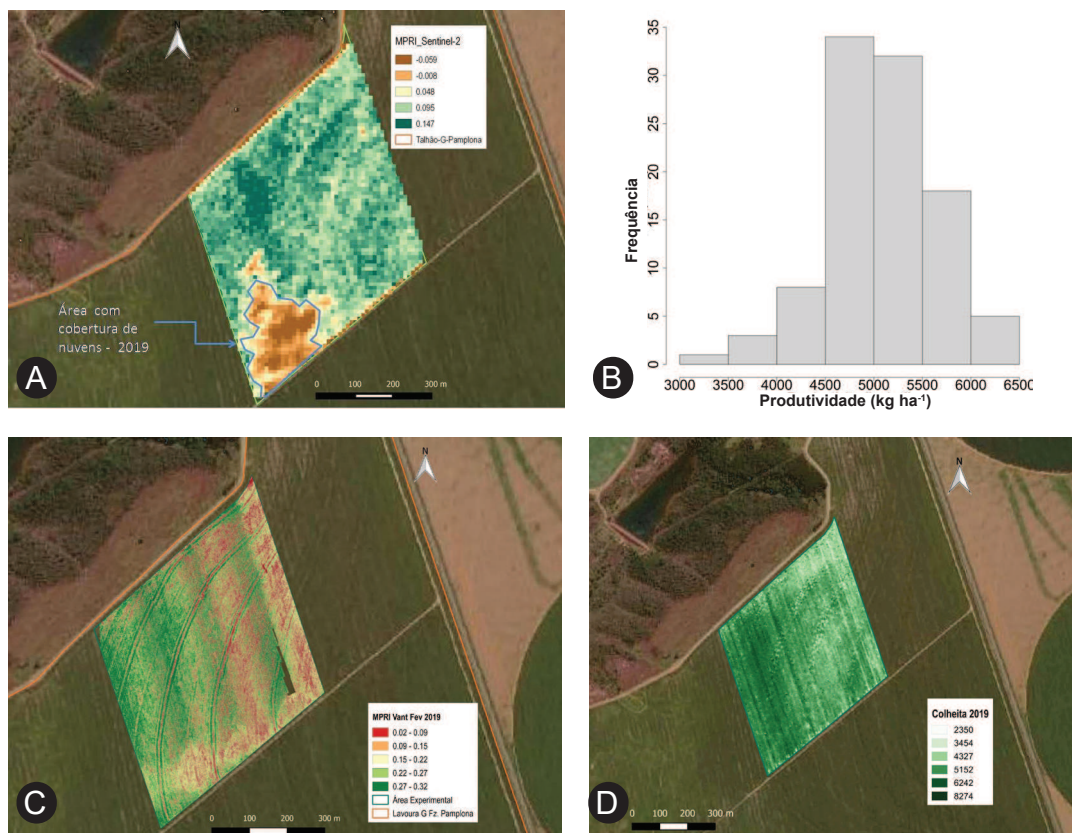


Figura 5. A) Modified Photochemical Reflectance Index - MPRI obtido por imagem com nuvem; B) Histograma: pré-análise dos dados; C) Mapa de MPRI de imagem RGB obtida por câmera em veículo aéreo não tripulado (VANT); D) Mapa interpolado da produtividade do algodoeiro sem retirada de erros. Experimento on-farm na Fazenda Pamplona, Cristalina, GO.

Fonte: (A, C e D) Google Earth (2021).

Para a modelagem da produtividade, foram testadas todas as combinações possíveis de covariáveis de imagens, MPRI, e NDVI para predição dos valores de produtividade via regressão utilizando o modelo linear. A melhor combinação selecionada foi aquela que apresentou maior valor de R^2 ajustado.

Mesmo em imagem adquirida apenas aos 60 DAE, as imagens da câmera em VANT mostraram-se bem correlacionadas com a produtividade da cultura, tendo sido reportadas correlações superiores a 0,85 em diversas pesquisas para o algodoeiro tanto na estimativa da produtividade quanto no crescimento e desenvolvimento do algodoeiro, com a avaliação do índice de área foliar (IAF) (Haboudane et al., 2004; Zhao et al., 2007; Huang et al., 2013; Brandão et al., 2015). Assim, a possibilidade de predição do IAF do algodoeiro por meio do MPRI pode ser útil na delimitação de zonas de manejo para a área estudada.

Foram muitos os fatores responsáveis pela variabilidade espacial da produtividade (alguns controláveis e outros não), e incluem a quantidade de água disponível às plantas, topografia, uniformidade na aplicação de fertilizantes, variação genética, propriedades nutricionais do solo, bem como a infestação de pragas e doenças (Zhang et al., 2002), entre outros. Todos esses fatores influenciam o arranjo e distribuição das plantas no campo bem como o vigor das mesmas, sendo realçados pela refletância (Zhao et al., 2007). Essas características têm sido utilizadas para definição de ZMs e podem ser recuperadas por meio do MPRI (Motohka et al., 2010; Lyle et al., 2013). O mais importante

é a observação constante da área de produção e delimitação de áreas de manejo considerando as variações observadas ano a ano (Diker et al., 2004), uma vez que interferências provocadas por manejo ou aplicação de fertilizantes vão alterando as características morfológicas e nutricionais observadas na área estudada.

Considerações Finais

O monitoramento do vigor das culturas, no campo, pode ser facilitado por meio do uso de imagens obtidas por satélite ou VANT. Os IVs obtidos por imagens do Sentinel-2 mostram-se apropriados para predição da produtividade, desde que consideradas e conhecidas as condições nas quais a cultura foi estabelecida.

As imagens RGB obtidas em VANTs, ou imagens da aerofotogrametria, podem ser usadas na avaliação do vigor da cultura e na estimativa da produtividade, desde que os dados sejam adequadamente tratados.

Agradecimentos

À Rede de Agricultura de Precisão da Embrapa, que nos apoiou e deu suporte aos trabalhos, e à SLC Agrícola pela excelente parceria, sem a qual esse trabalho não teria êxito.

Referências

BRANDÃO, Z. N.; GREGO, C. R.; INAMASU, R. Y.; JORGE, L. A. Spectral reflectance of satellite images using geostatistics methods to estimate growth and cotton yield. **Proceedings of SPIE**, v. 9239, p. 9239201-9239208, 2014a. Presented at the 16th Remote Sensing for Agriculture, Ecosystems, and Hydrology.

BRANDÃO, Z. N.; OLIVEIRA, R. P.; SANA, R. S.; SOFIATTI, V.; ZONTA, J. H.; MEDEIROS, J. C.; Uso de imagens orbitais e suborbitais na caracterização da variabilidade espacial da produtividade. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (org.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014b. p. 306-314.

BRANDÃO, Z. N.; SOFIATTI, V.; BEZERRA, J. R. C.; FERREIRA, G. B.; MEDEIROS, J. C. Spectral reflectance for growth assessment and yield estimate of irrigated cotton. **Australian Journal of Crop Science**, v. 9, n. 1, p. 75-84, 2015. Disponível em: http://www.croptj.com/brandao_9_1_2015_75_84.pdf. Acesso em: 20 jul. 2022.

CHEN, R.; CHU, T.; LANDIVAR, J. A.; YANG, C.; MAEDA, M. M. Monitoring cotton (*Gossypium hirsutum* L.) germination using ultrahigh-resolution UAS images. **Precision Agriculture**, v. 19, n. 1, p. 161-177, 2018. Disponível em: <https://doi.org/10.1007/s11119-017-9508-7>. Acesso em: 20 jul. 2022.

CHU, T.; CHEN, R.; LANDIVAR, J. A.; MAEDA, M. M.; YANG, C.; STAREK, M. J. Cotton growth modeling and assessment using unmanned aircraft system visual-band imagery. **Journal of Applied Remote Sensing**, v. 10, n. 3, 36018, 2016. Disponível em: <https://doi.org/10.1117/1.jrs.10.036018>. Acesso em: 20 jul. 2022.

CLAESSEN, M. E. C. (org.). **Manual de métodos de análise de solo**. 2. ed. rev. e atual. Rio de Janeiro: EMBRAPA-CNPS, 1997. 212 p. (EMBRAPA-CNPS. Documentos, 1).

DIKER, K.; HEERMANN, D. F.; BRODAHL, M. K. Frequency analysis of yield for delineating yield response zones. **Precision Agriculture**, v. 5, p. 435-444, 2004. Disponível em: <https://link.springer.com/content/pdf/10.1007/s11119-004-5318-9.pdf>. Acesso em: 20 jul. 2022.

EITEL, J. U. H.; LONG, D. S.; GESSLER, P. E.; HUNT, E. R. Combined spectral index to improve ground-based estimates of nitrogen status in dryland wheat. **Agronomy Journal**, v. 100, n. 6, p. 1694-1702, 2008. Disponível em: <https://doi.org/10.2134/agronj2007.0362>. Acesso em: 20 jul. 2022.

EUROPEAN SPACE AGENCY. Earth online. GeoEye-1 full archive and tasking. Disponível em: <https://earth.esa.int/eogateway/catalog/geoeye-1-full-archive-and-tasking>. Acesso em: 1º out. 2021.

GREGO, C. R.; RODRIGUES, C. A. G.; VICENTE, L. E.; BOLFE, E. L.; VICTORIA, D. de C. Agricultura. In: TÔSTO, S. G.; RODRIGUES, C. A. G.; BOLFE, E. L.; BATISTELLA, M. (ed.). **Geotecnologias e geoinformação: o produtor**

pergunta, a Embrapa responde. Brasília, DF: Embrapa, 2014. p. 135-148. (Coleção 500 perguntas, 500 respostas). Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/103408/1/Cap.-9.pdf>. Acesso em: 20 abr. 2022.

HABOUDANE, D.; MILLER, J. R.; PATTEY, E.; ZARCO-TEJADA, P. J.; STRACHAN, I. B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, p. 337-352, 2004. Disponível em: <https://doi.org/10.1016/j.rse.2003.12.013>. Acesso em: 20 jul. 2022.

HUANG, Y.; SUI, R.; THOMSON, S. J.; FISHER, D. K. Estimation of cotton yield with varied irrigation and nitrogen treatments using aerial multispectral imagery. **International Journal of Agricultural and Biological Engineering**, v. 6, n. 2, p. 37-41, 2013. Disponível em: <https://ijabe.org/index.php/ijabe/article/view/706>. Acesso em: 20 jul. 2022.

IVOSEV, G.; BURTON, L.; BONNER, R. Dimensionality reduction and visualization in principal component analysis. **Analytical Chemistry**, v. 80, p. 4933-4944, 2008. Disponível em: <https://doi.org/10.1021/ac800110w>. Acesso em: 20 jul. 2022.

LIU, L.; WANG, J.; BAO, Y.; HUANG, W.; MA, Z.; ZHAO, C. Predicting winter wheat condition, grain yield and protein content using multi-temporal EnviSat-ASAR and Landsat TM satellite images. **International Journal of Remote Sensing**, v. 27, n. 4, p. 737-753, Feb. 2006. Disponível em: <https://doi.org/10.1080/01431160500296867>. Acesso em: 20 jul. 2022.

LIU, S.; LV, Y.; TONG, X.; XIE, H.; LIU, J.; CHEN, L. An alternative approach for registration of high-resolution satellite optical imagery and ICESat laser altimetry data. **Sensors**, v. 16, n. 12, Dec. 2016. DOI: 10.3390/s16122008.

LYLE, G.; LEWIS, M.; OSTENDORF, B. Testing the temporal ability of Landsat imagery and precision agriculture technology to provide high resolution historical. **Remote Sensing**, v. 5, p. 1549-1567, 2013. Disponível em: <https://doi.org/10.3390/rs5041549>. Acesso em: 20 jul. 2022.

MAHAJAN, G. R.; SAHOO, R. N.; PANDEY, R. N.; GUPTA, V. K.; KUMAR, D. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur, and potassium in wheat (*Triticum aestivum* L.). **Precision Agriculture**, v. 15, n. 5, p. 499-522, 2014. Disponível em: <https://doi.org/10.1007/s11119-014-9348-7>. Acesso em: 20 jul. 2022.

MANLY, B. F.; ALBERTO, J. A. N. **Multivariate statistical methods: a primer**. Boca Raton; London; New York: CRC Press Group; Taylor and Francis, 2016. 252 p.

MAZZIA, V.; COMBA, L.; KHALIQ, A.; CHIABERGE, M.; GAY, P. UAV and machine learning based refinement of a satellite-driven vegetation index for precision agriculture. **Sensors**, v. 20, 2530, 2020. DOI: 10.3390/s20092530.

MOTOHKA, T.; NASHAHARA, K. N.; OGUMA, H.; TSUCHIDA, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, v. 2, p. 2369-2387, 2010. Disponível em: <https://doi.org/10.3390/rs2102369>. Acesso em: 20 jul. 2022.

OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **Catena**, v. 113, n. 1, p. 56-69, 2014. Disponível em: <https://doi.org/10.1016/j.catena.2013.09.006>. Acesso em: 20 jul. 2022.

PADRÓ, J. C.; MUÑOZ, F. J.; PLANAS, J.; PONS, X. Comparison of four UAV georeferencing methods for environmental monitoring purposes focusing on the combined use with airborne and satellite remote sensing platforms. **International Journal of Applied Earth Observation and Geoinformation**, v. 75, p. 130-140, 2019. DOI: 10.1016/j.jag.2018.10.018.

R FOUNDATION FOR STATISTICAL COMPUTING. **R: a language and environment for statistical computing**. Vienna, Austria, 2021. Disponível em: <<http://www.R-project.org/>>. Acesso em: 12 fev. 2021.

REDDY, K. R.; KOTI, S.; DAVIDONIS, G. H.; REDDY, V. R. Interactive effects of carbon dioxide and nitrogen nutrition on cotton growth, development, yield, and fiber quality. **Agronomy Journal**, v. 96, p. 1148-1157, 2004. Disponível em: <https://doi.org/10.2134/agronj2004.1148>. Acesso em: 20 jul. 2022.

ROCHESTER, I. J.; CONSTABLE, G. A.; OOSTERHUIS, D. M.; ERRINGTON, M. Nutritional requirements of cotton during flowering and fruiting. In: OOSTERHUIS, D. M.; COTHREN, J. T. (org.). **Flowering and fruiting in cotton**. Cordova: The Cotton Foundation Publisher, 2012. p. 35-50. Disponível em: <https://www.cotton.org/foundation/upload/F-F-Chapter-4.pdf>. Acesso em: 20 jul. 2022.

ROUSE JUNIOR, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: ERTS SYMPOSIUM, 3., 1973. **Proceedings...** Greenbelt: NASA, 1974. p. 309-317.

SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICENTE, L. E.; VICTORIA, D. C.; DUCATI, J. R.; OLIVEIRA, R. P.; VILELA, M. F. Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (org.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 58-73.