INDICAÇÃO DE BANDAS E ÍNDICES DE VEGETAÇÃO PROVENIENTES DE IMAGENS DE RPA PARA A ESTIMATIVA DE CLOROFILA EM LAVOURAS DE CAFÉ

Marley Lamounier Machado[1], Gabriela carvalho Franco [2], Margarete Lordelo Volpato [3], Vanessa Castro Figueiredo [4], Sthéfany Airane dos Santos[5], Vania Aparecida Silva[6], Maria Helena Ramos[7]

[1]Epamig, Av. Jose Cândido da Silveira, 1647, bairro União, BH, MG, marley@epamig.br; [2]Bolsista Embrapa Café, Av. Jose Cândido da Silveira, 1647, bairro União, BH, MG, gabicarvalhofranco@gmail.com; [3]Epamig, Campus da Universidade Federal Lavras – UFLA, Rodovia Lavras/Ijaci Km 02, Lavras, MG, margarete@epamig.br; [4]Epamig, Rodovia Três Pontas, Santana da Vargem, Km 06, Zona Rural Três Pontas, MG, vcfigueiredo@epamig.br>; [5]Doutoranda UFLA, Campus da Universidade Federal Lavras – UFLA, Rodovia Lavras/Ijaci Km 02, Lavras, MG, thethsantos@hotmail.com; [6]Epamig, Campus da Universidade Federal Lavras - UFLA. Rodovia Lavras/Ijaci Km 02, Lavras, MG, vania.silva@epamig.br; [7]Embrapa Café, Campus da Universidade Federal Lavras - UFLA. Rodovia Lavras/Ijaci Km 02, Lavras, MG, helena.alves@embrapa.br.

RESUMO

O objeto desse trabalho foi a identificação de bandas e IV´s provenientes de imagens multiespectrais de RPA para a estimativa níveis de clorofila em plantio de café. Foi utilizado regressão PLS em diferentes índices e bandas. Foi concluído que é possível inferir sobre o nível de clorofila total na cultura de café por imagens RPA com câmera multiespectral, identificando os melhores índices de vegetação por técnicas de regressão linear múltipla. Há indícios que os índices GOSAVI e MCARI2, melhor representam a clorofila total.

Palavras-chave — VANT, Drone, Agricultura de Precisão, Nitrogênio, Multivariada.

ABSTRACT

The object of this work was the identification of bands and vegetation index from multispectral RPA images to estimate chlorophyll levels in coffee crop. PLS regression was used in different index and bands. It was concluded that it is possible to infer about the level of total chlorophyll in the coffee crop by RPA images with a multispectral camera, identifying the best vegetation index by multiple linear regression techniques. There are indications that the GOSAVI and MCARI2 indexes best represent total chlorophyll.

Key words *— VANT, Drone, Precision Agriculture, Nitrogen, Multivariate.*

1. INTRODUÇÃO

A fotossíntese é um processo complexo pelo qual plantas e certos tipos de bactérias sintetizam compostos orgânicos na presença de luz. Já a radiação fotossinteticamente ativa, compreendida entre 400 e 700 nm, corresponde a 45% da radiação solar que chega à superfície da planta. Este espectro da radiação é o único que esta envolvido na fotossíntese. No entanto a radiação entre 300 e 400 nm e entre 700 e 1000 nm tem efeitos fisiológicos na planta (Marenco e Lopes; 2009).

As medidas de clorofila podem ser feitas de forma indireta e imediata por sensores ópticos, evitando assim a extração da folha. Esses sensores são relativamente simples e possibilitam avaliar o conteúdo relativo de clorofila da folha, medindo a absorbância diferencial e a transmitância de diferentes comprimentos de onda de radiação pela folha. Dado que o teor de clorofila da folha geralmente está relacionado ao teor de Nitrogênio (N) da cultura, as medidas de clorofila podem ser usadas para avaliar o status de N da cultura (de Souza et al., 2019). O Nitrogênio, por sua vez, é o mineral mais abundante nas plantas. Sua falta representa folhas com clorose, sendo que em casos mais severos essas folhas tornam-se completamente amarelo-pardas e logo morrem. Com isso há uma inutilização da luz do sol como energia pela folha, que é de fundamental importância para a ativação de funções primordiais, como a absorção de nutrientes.

Diferentes formas de estresses ocorridos da lavoura relacionados à falta de N e a outros elementos nutricionais, bem como de fatores relacionados à presença de pragas e doenças e à aspectos climáticos e de solo, podem promover diferentes formas de estresses distribuídos na sua área. Com isso, diferentes formas de estresse na lavoura podem promover níveis de produtividade variados na mesma área, onde a quantificação e a identificação da perda de produção

resultante de múltiplos estresses são, na maioria das vezes, imprecisas (Faria et al. 2015).

Nesse sentido, o diagnóstico por caminhamento terrestre nos locais de ocorrência de estresse pode não ser perceptível em toda sua extensão. Uma solução seria a utilização de imagens da lavoura tomadas por plataformas aéreas portando tecnologias que permitam identificar as áreas de estresse de forma rápida e com exatidão. Neste sentido, a aeronave remotamente pilotada (RPA) pode ser uma solução tecnológica de mapeamento de auto rendimento e baixo custo de implantação, além de apresentar baixo custo em função dos resultados obtidos; portabilidade e facilidade de lançamento e aterrisagem; a possibilidade de voar a baixas altitudes e de portar câmeras multiespectrais, o que permite realizar um mapeamento com melhor resolução espacial e espectral (Hunt Jr. e Daughtry 2018).

Imagens multiespectrais e Índices de Vegetação (IV) constituem uma importante alternativa à estimativa tradicional de clorofila, pois permitem a estimativa in situ do pigmento, e assim encontrar a variabilidade e as relações entre o conteúdo localizado de clorofila na lavoura.

Portando, O objeto desse trabalho foi a identificação de bandas e IV´s provenientes de imagens multiespectrais de RPA para a estimativa níveis de clorofila.

2. MATERIAL E MÉTODOS

O estudo foi conduzido em uma área de 1,2100 ha, sob o cultivo de cafeeiros da espécie Coffea arabica L., cultivar Topázio MG 1190, no Campo Experimental da Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG), situada no município de Três Pontas, Minas Gerais, coordenada 21°20'27.69"S / 45°29'11.95"O. A coleta de dados foi realizada em período seco (agosto/2020).

Na área de estudo foi estabelecido uma grade amostral de 30 pontos equidistantes. Estes foram georreferenciados utilizando GNSS RTK Trimble, modelo R8. Em cada ponto foram obtidas medidas de teor de clorofila foliar (terço médio, inferior e superior da planta), obtidas utilizando o medidor Clorofilog (Falker Automação Agrícola), cuja escala de medição vai de 0 a 100, com resolução de 0.1, com área de medição foliar de 50,3 mm^2. Esse equipamento utiliza o Índice de Clorofila Falker (ICF) que corresponde à mensuração da quantidade de radiação transmitida através das folhas em três diferentes comprimentos de onda, sendo dois na faixa do vermelho, próximos aos picos de absorção da clorofila e um no infravermelho próximo.

Foram obtidas imagens utilizando a RPA EBBE-SQ Sensefly equipada com sensor multiespectral (Parrot modelo Sequoia) para bandas Red, Nir, Green e Red Edge com resolução de 7 cm px^{-1}. O voo foi realizado entre 11:00 hs e 13:00 hs para evitar para minimizar a influência da geometria de iluminação (ângulo solar zenital e azimutal). A sobreposição entre as imagens foi de 70%. As imagens foram mosaicadas (unidas) pelo software Pix4D Mapper, dando origem a 4 imagens (uma para cada banda).

Com base no mosaico das imagens do RPA foram calculados os índices de vegetação : Green Chlorophyll Index (CIgreen), Red-Edge Chlorophyll Index (CIredege), Difference Vegetation Index (DVI), Green Difference Vegetation Index (GDVI), Red-Edge Difference Vegetation Index (REDVI), Global Environmental Monitoring Index (GEMI), Green Normalized Difference Vegetation Index (GNDVI), Green Optimal Soil Adjusted Vegetation Index (GOSAVI)(L=0.16), Green Soil Adjusted Vegetation Index (GSAVI) (L=0.5), Modified Chlorophyll Absorption in Reflectance Index (MCARI), Modified Chlorophyll Absorption in Reflectance Index 2 (MCARI 2), Modified Soil-adjusted Vegetation Index (MSAVI 1 e 2), Modified Simple Ratio (MSR), Red-Edge Modified Simple Ratio (MSRRE), MERIS Terrestrial Chlorophyll Index (MTCI), Normalized Difference Red-Edge (NDRE), Normalized Difference Vegetation Index (NDVI), Normalized Difference Water Index (NDWI), Optimized SAVI (OSAVI), Green Optimized SAVI (OSAVIGRE), Red-Edge Optimized SAVI (OSAVIREG), Renormalized Difference Vegetation Index (RDVI), Red-Edge Renormalized Difference Vegetation Index (RDVIREG), Ratio Vegetation Index (RVI), Green Ratio Vegetation Index (RVIGRE), Soil-Adjusted Vegetation Index (SAVI), Green Soil-Adjusted Vegetation Index (SAVIGRE), Transformed Chlorophyll Absorption Ratio (TCARI), Transformed Normalized Vegetation Index (TNDVI), TCARI/OSAVI e MCARI/OSAVI. Índices disponíveis em IDB (2022). Amostras de cada IV foram feitas nas plantas identificadas na grade amostral.

Foi utilizado a regressão por Mínimos Quadrados Parciais (PLS) para definição do conjunto de bandas e IV´s que melhor explique a variabilidade da clorofila medida na grade. A regressão por Mínimos Quadrados Parciais (PLS) é capaz de lidar com um grande número de variáveis respostas altamente correlacionados (indicadores ou descritores) e com pequenos conjuntos de observações (TEÓFILO et al., 2009). A base para construção de modelos por regressão PLS é a PCA, onde os dados originais (X) são decompostos em matriz de scores e loadings. Score é a coordenada de cada objeto ao longo de um eixo (componente principal). Loading é a participação de cada medida em um eixo, ou quanto cada variável antiga contribui. A função dos componentes principais (PC) é descrever a variação ou espalhamento entre os pontos usando o menor número possível de eixos.

Os valores de banda / IV considerados como melhores foram aqueles acima da mediana dos valores absolutos da contribuição / carga referentes às componentes principais (CP).

3. RESULTADOS E DISCUSSÃO

A Figura 1 apresenta o mosaico na área em estudo.

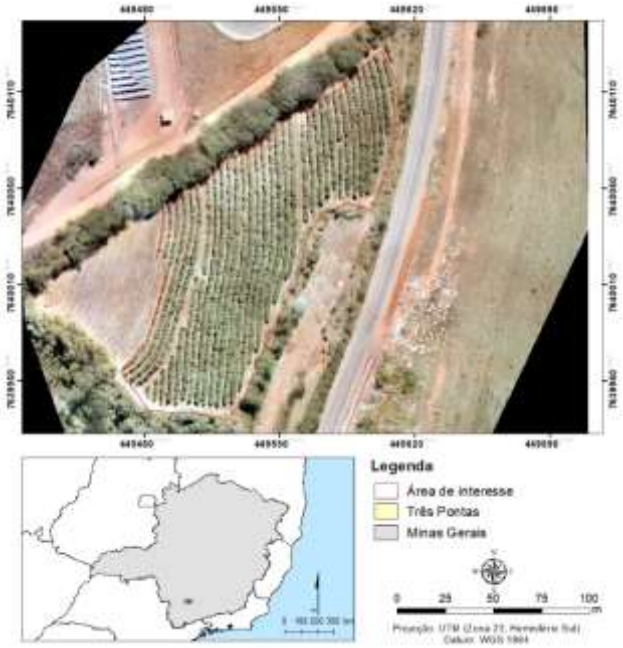


Figura 1. Mosaico de imagens RPA da área de estudo.

A Tabela 1 apresenta os valores de contribuição (variância) e o coeficiente de determinação (R^2) dos componentes principais pela regressão PLS entre bandas e IV´s. Observa-se nesta Tabela que a partir do segundo componente o modelo respectivo desses modelos representaram mais de 90% da variabilidade dos dados (CP2 = 91,6% e CP3 = 93,5%), permitindo assim a redução da dimensionalidade dos dados originais. Considerando o valor do coeficiente de correlação (r) apresentado na Tabela 1 tem-se que o modelo dos componentes com a variável resposta é classificado como moderado.

CP	Variância	R^2	r
1	0,674631	0,1746	0,4170
2	0,915096	0,2234	0,4727
3	0,935072	0,3273	0,5721

Tabela 1. Variância, coeficiente de determinação e de correlação por modelo de componente principal.

A Tabela 2 apresenta os valores de contribuição / carga das bandas e IV´s provenientes da regressão PLS para os CP's 1, 2 e 3. Foram destacados em cada banda e IV as contribuições das componentes superior à sua respectiva mediana absoluta (CP1=0,18807, CP2=0,11926, CP3=0,17733).

	Carga		
Banda / IV	CP1	CP2	CP3
Green	-0,16041	-0,22309	-0,16317
Nir	0,04777	-0,33997	-0,02346
Red	-0,18734	-0,14603	-0,23699
RedEdge	-0,05883	-0,32831	0,28142
CLGreen	0,20692	-0,00442	0,00043
CLRedEdge	0,18922	0,04090	-0,60209
DVI	0,13687	-0,26594	0,08363
DVIGre	0,10715	-0,30044	0,02101
DVIRed	0,17656	-0,15280	-0,45777
GEMI	0,14490	-0,24102	0,18988
GNDVI	0,20917	-0,00034	0,18216
GOSAVI	0,18881	-0,14758	0,13197
GSAVI	0,15276	-0,23785	0,08784
MCARI	0,17810	-0,11616	0,29600
MCARI2	0,19261	-0,13123	0,13131
MCPOS	0,16195	-0,12235	0,45295
MSAVI	0,20759	0,01582	0,21400
MSAVI2	0,08722	-0,30639	0,09549
MSR	0,20770	0,03325	0,08817
MSRREG	0,19003	0,04078	-0,58083
MTCI	0,15911	0,04256	-0,83672
NDRE	0,19076	0,04070	-0,55719
NDVI	0,20476	0,04594	0,30751
NDWI	-0,20917	0,00034	-0,18216
OSAVI	0,20419	-0,07747	0,20162
OSAVIGRE	0,07309	-0,32668	0,02286
OSAVIREG	0,14837	-0,23366	-0,31338
RDVI	0,18730	-0,15825	0,16574
RDVIREG	0,19049	-0,06707	-0,53305
RVI	0,20536	0,03125	-0,02598
RVIGRE	0,20692	-0,00442	0,00043
SAVI	0,18344	-0,17044	0,14167
SAVIGRE	0,15207	-0,24026	0,05344
TCARI	-0,19030	-0,05856	-0,00978
TCPOS	-0,20086	-0,05160	-0,17250
TNDVI	0,20638	0,03619	0,28682

Tabela 2. Valores de carga das bandas e IV´s por componente principal, destacando aqueles acima do valor absoluto da mediana.

Observa-se na Tabela 2 que dos 37 valores (4 bandas e 33 IV´s), 18 (todos IV´S) estiveram acima da mediana.

Destes, a maior parte usa da relação das bandas do infravermelho (NIR) e vermelho (Red) e que correspondem às principais bandas na produção de clorofila pela planta. A absorção da radiação ocorrida na faixa espectral do vermelho é feita somente pela clorofila. Já o infravermelho, em função da estrutura interna das plantas, promove o espalhamento interno da radiação; em que, quanto mais sadia for a planta, maior será este esse espalhamento.

Com base nos IV´s identificados na Tabela 2 como melhores, procedeu-se a nova regressão PLS. A Tabela 3 apresenta a variância, coeficiente de determinação e de correlação por modelo de componente principal para esta regressão. Observa-se que na comparação da Tabela 1 com Tabela 3 houve aumento na variância para o CP1. Já os demais valores estão muito próximos comparando as Tabelas. Com isso, houve pouca diferença entre os modelos quando se excluiu as bandas / índices não selecionados na Tabela 2, o que pode indicar colinearidade entre essas informações.

CP	Variância	R^2	r
1	0,858870	0,171870	0,41457
2	0,915779	0,240298	0,49020
3	0,931328	0,338061	0,58143

Tabela 3. Variância, coeficiente de determinação e de correlação por modelo de componente principal para IV´s classificados.

Observa-se na Tabela 2 que ao analisar os IV´s destacados no CP1 e 2, os únicos índices presentes simultaneamente nos dois componentes foram o GOSAVI e MCARI2. Em especial os IV´s da família CARI foram idealizados para serem sensíveis às variações de clorofila e resistentes a efeitos da reflectância do solo e de matérias não fotossintéticas (HOBOUDANE et al., 2002). Já o GOSAVI utiliza das bandas do NIR e Green com constante ajustada para minimizar efeitos de solo (adaptado de ROUNDEAUX(1996)).

4. CONCLUSÕES

Há a possibilidade de inferir sobre o nível de clorofila total na cultura de café arábica por imagens RPA com câmera multiespectral, identificando os melhores índices de vegetação por técnicas de regressão linear múltipla. Há indícios que os índices GOSAVI e MCARI2, melhor representam a clorofila total.

5. REFERÊNCIAS

FARIA, R. T. de; CASÃO Jr., R.; WERNER, S.S.; TORRES E.; ZANÃO Jr. Produtividade da Soja em Transectos. In: ZANÃO Jr.; FARIA, R. T.; CARAMORI, P. H (ed**.). Produtividade da Soja no entorno do reservatório de Itaipú.** Londrina: IAPAR, 2015. 217p.

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, p. 416-426, 2002.

HUNT Jr., E. R.; DAUGHTRY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? International Journal of Remote Sensing, v. 39, n. 15–16, p. 5345–5376, 2018.

IDB. Index DataBase. A Database for Remote Sensing Indices. The IDB Project, 2011–2022. Disponível em : < https://www.indexdatabase.de/>. Acessado em outubro de 2022.

Marenco, R. A.; Lopes, N. F. (2009). **Fisiologia vegetal: fotossíntese, respiração, relações hídricas e nutrição mineral**. Brasil: Editora UFV.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of Soil-Adjusted Vegetation Indices.**Remote Sensing of Environment.** v. 55, n. 2, p. 95-107, 1996.

Souza, R. de; Peña-Fleitas, M.T.; Thompson, R.B.; Gallardo, M.; Grasso, R.; Padilla, F.M. The Use of Chlorophyll Meters to Assess Crop N Status and Derivation of Sufficiency Values for Sweet Pepper. **Sensors**, v. 19, no. 13: 2949. https://doi.org/10.3390/s19132949