

Análise da cultura da soja a partir de índices de vegetação (ExG – GLI – TGI – VEG) advindos de imagens RGB obtidas com ARP

RESUMO

O uso de imagens para análise e controle de plantações na agricultura já é feito há algum tempo. Atualmente, com a difusão de ARPs, essa tecnologia se tornou mais acessível, sendo este o foco do presente trabalho: acompanhar o crescimento da soja com esse equipamento. Para isto, as imagens foram processadas nos programas computacionais Agisoft PhotoScan e no Agisoft Metashape, enquanto o cálculo dos índices (ExG, GLI, TGI e VEG) foram feitos através do programa Quantum GIS, bem como a produção de mapas temáticos, que, aliados a fotointerpretação e análises estatísticas, puderam demonstrar, informações relevantes quanto à saúde vegetal, detectando regiões saudáveis, debilitadas e onde haviam falhas no plantio. Esses mapas temáticos, obtidos pela criação de classes a partir de valores retornados pelos índices, foram importantes para facilitar a compreensão do que estava ocorrendo nas diferentes etapas de desenvolvimento e visualização do crescimento da soja. Além disso, foi possível elencar os índices aplicados quanto a sua representação da soja para o caso específico deste estudo.

PALAVRAS-CHAVE: Soja. Índice de Vegetação. Drone. RPA. Agricultura de Precisão.

Matheus Henrique da Silva

matheushenrique@alunos.utfpr.edu.br
orcid.org/0000-0002-0999-7631

Universidade Tecnológica Federal do Paraná (UTFPR), Pato Branco, Paraná, Brasil.

Adão Robson Elias

robsonelias@utfpr.edu.br
orcid.org/0000-0002-3935-8152

Universidade Tecnológica Federal do Paraná (UTFPR), Pato Branco, Paraná, Brasil.

Leticia Laura do Rosário

leticia@alunos.utfpr.edu.br
orcid.org/0000-0001-5081-2814

Universidade Tecnológica Federal do Paraná (UTFPR), Pato Branco, Paraná, Brasil.

INTRODUÇÃO

A agricultura de precisão (AP), integra conceitos e noções de agricultura com a tecnologia atualmente disponível no mercado. Tem por objetivo gerenciar de forma específica cada parte do campo, para atender suas necessidades de maneira heterogênea, considerando que cada porção da lavoura possui necessidades diferentes no que diz respeito aos atributos químicos do solo.

Uma das maiores dificuldades na implementação da AP reside no alto custo das máquinas e equipamentos agrícolas. No entanto, dentre as tecnologias aplicadas na AP, como veículos monitorados com GNSS, imagens de satélites, coleta de amostras de solo, o uso de Veículos Aéreos não Tripulados (VANTs) para o monitoramento agrícola tem crescido ao longo dos anos (HUNT; DAUGHTRY, 2018). A vantagem no uso desse equipamento se dá justamente devido ao seu baixo custo operacional, quando comparado a outros comumente utilizados, além de possibilitar a obtenção de imagens com uma maior resolução espacial do que um satélite ou aeronave tripulada, em épocas melhor definidas pelo usuário, e de oportunizar, assim como em outras plataformas, o uso dos mais variados sensores, sejam eles RGB, ou que abordem outras bandas de grande relevância, como: infravermelho próximo e borda vermelha. (HUNT; DAUGHTRY, 2018; JANNOURA *et al.*, 2015; ZHANG; WALTERS; KOVACS, 2014).

Para possibilitar a análise do estado das plantações, são calculados índices de vegetação a partir das imagens, registradas por sensores apropriados, os quais retornarão dados úteis sobre o estado vegetativo, desenvolvimento e produtividade da cultura. No caso dos VANTs, os modelos mais acessíveis abarcam as bandas comuns do espectro visível (RGB), enquanto os multiespectrais, abarcam outros sensores para captar diferentes comprimentos de onda, com tecnologia mais refinada. Em busca da redução dos investimentos necessários na aplicação de técnicas da AP, vêm sendo aprimorados índices de vegetação que utilizam essas bandas visíveis, a exemplo do Visible Atmospherically Resistant Index (VARI), Normalized Green Red Difference Index (NGRDI) e Excess Red Vegetative Index (ExR), assim como abordado nos trabalhos de Andrade *et al.* (2019), Motohka *et al.* (2010), Cruz (2020) e Freire-Silva *et al.* (2019).

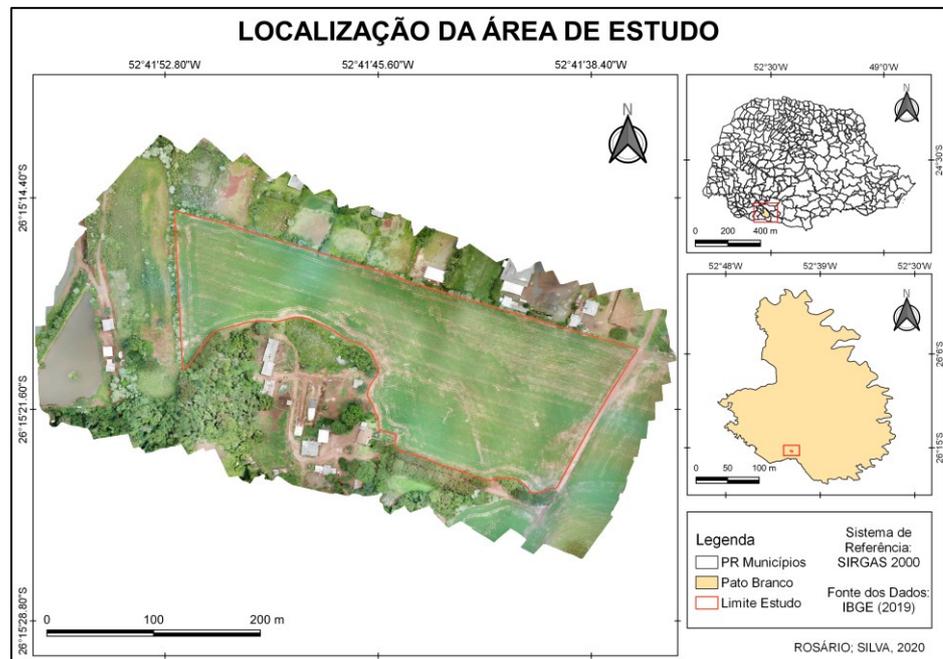
Em vista disso, no presente trabalho serão analisados quatro índices de vegetação que abrangem as bandas do visível, sendo esses: Green Leaf Index (GLI), Triangular Greenness Index (TGI), Vegetative (VEG) e Excess Green Index (ExG), para posteriormente compará-los entre si e conferir sua confiabilidade em relação ao que se é interpretado visualmente pela imagem de composição RGB.

MATERIAIS E MÉTODOS

O local de estudo situa-se na área rural do município de Pato Branco – PR, mais especificamente na área delimitada (figura 1), de coordenadas geográficas centrais (SIRGAS 2000): 52° 41' 44.407" Oeste e 26° 15' 19.637" Sul, onde foi feito o plantio da soja (*Glycine max*), da variedade TMG-7262, cujo ciclo dura em torno de 130 dias na região, sendo: fase vegetativa (emergência até 45 dias), florescimento (45 a 90 dias), fase reprodutiva (90 a 120 dias), enchimento do grão e maturação (a partir de 120 dias). Nesta área, ocorreu a obtenção de imagens em três épocas: no dia 19 de dezembro de 2019 (Voo 1), durante a fase

vegetativa das plantas, 08 de fevereiro de 2020 (Voo 2), na fase reprodutiva e 10 de março de 2020 (voo 3), na maturação, com o intuito de coletar informações em diferentes fases do desenvolvimento da cultura.

Figura 1 - Mapa de Localização



Fonte: Autoria própria (2020).

Para a realização dos voos, além do DJI Mavic Pro (aeronave de classe 3, pela classificação da ANAC), também foi utilizado o Pix4DCapture, no planejamento prévio do voo, que considerou condições climáticas, como vento, de modo a garantir um bom desempenho, bem como a definição de parâmetros, como a altura de voo e as taxas de recobrimento. Os voos foram feitos à 65 metros de altura, com recobrimento longitudinal de 80% e lateral de 70%, resultando em 13 linhas de voo, para minimizar a possibilidade de ocorrerem falhas na cobertura e depois no processamento, garantindo múltiplas vistas dos pontos no terreno e que áreas de agricultura, onde ocorre a repetição de padrões, sejam contempladas de modo satisfatório.

As imagens obtidas nos voos de dezembro e fevereiro (voos 1 e 2) foram processadas no Agisoft Metashape Professional, com o alinhamento das fotos, construção da nuvem densa de pontos, da malha, da textura do tiled model, do DEM e do ortomosaico na qualidade média, enquanto que as de março foram processadas no Agisoft PhotoScan, por meio dos mesmos passos, com exceção da nuvem densa, processada na qualidade baixa. No caso específico deste trabalho, foram encontradas dificuldades quanto a processar todos os voos no Metashape, apesar de ser uma versão mais potente do PhotoScan, mas que por terem parâmetros padrões diferentes, fizeram com que o PhotoScan fosse capaz de processar adequadamente o voo 3, sem falhas de recobrimento como ocorreu com o Metashape. Vale ressaltar que a qualidade do processamento, neste caso específico, não alterou a resolução espacial dos ortomosaicos gerados, sendo possível que sejam comparados e que calibrações radiométricas não foram feitas. Os três ortomosaicos dos levantamentos foram georreferenciados em WGS84.

No QGIS 3.10.12, a partir da ferramenta “calculadora raster”, as bandas de cada ortomosaico foram separadas, assim como os índices de vegetação calculados pelas equações 1, 2, 3 e 4, respectivamente sendo: GLI (Louhaichi *et al.*, 2001), sendo um indicador de clorofila criado para classificar onde há plantas vivas, mortas e solo exposto; TGI (Hunt Jr. *et al.*, 2011, adaptado por McKinnon e Hoff, 2017), criado com o objetivo de estimar os níveis de clorofila; VEG (Marchant e Onyango, 2002), para a identificação da existência de vegetação ou de solo exposto; ExG (Woebbecke *et al.*, 1995), criado para diferenciar a presença de plantas saudáveis de doentes ou mortas, bem como solo exposto.

$$\text{GLI} = \frac{((G-R)+(G-B))}{(G+R+G+B)} \quad (1)$$

$$\text{TGI} = Rg - 0,39 \times Rr - 0,61 \times Rb \quad (2)$$

$$\text{VEG} = \frac{G}{R^a B^{(1-a)}} \quad (3)$$

$$\text{ExG} = 2G - R - B \quad (4)$$

onde G, R e B são, respectivamente, os números digitais das bandas verde, vermelho e azul, R é a reflectância das bandas, enquanto r, g, e b dizem respeito, respectivamente, as bandas do vermelho, verde e azul e a é um valor igual a 0,667.

Além disso, foram confeccionados os mapas temáticos (reprojetados em SIRGAS 2000), para cada índice, a partir da criação de cinco classes para a área de plantação, cujos intervalos foram definidos pela análise visual, conforme a Tabela 1. Optou-se pelo parâmetro visual para a definição de classes pois, justamente, o objetivo era averiguar o quanto cada índice se aproximava da fotointerpretação das imagens RGB. Classes: Solo exposto, onde solo era observado; Vegetação debilitada, mediana, sadia e muito sadia de acordo com a coloração observada nas folhas, sendo as menos verdes marcadas como debilitadas, mediana como uma classe intermediária entre essa e a sadia, sadia as verdes mais homogêneas, muito sadia para os valores acima de sadias. Isso tudo partindo do pressuposto que, quanto maior o valor retornado pelo índice, mais saudável a planta.

Tabela 1 – Classes definidas para cada índice conforme o valor de cada pixel

Índice de Vegetação	Classes				
	Solo exposto	Vegetação debilitada	Vegetação mediana	Vegetação sadia	Vegetação muito sadia
ExG	-63.0 a 30.099999	30.1 a 50.099999	50.1 a 90.099999	90.1 a 130.099999	130.1 a 209
GLI	-1 a 0.07099999	0.071 a 0.12099999	0.121 a 0.16099999	0.161 a 0.40999999	0.41 a 1
TGI	-37 a 25.099999	25.1 a 35.099999	35.1 a 50.099999	50.1 a 70.099999	70.1 a 115
VEG	0 a 1.10999999	1.11 a 1.25999999	1.251 a 1.35099999	1.351 a 1.90999999	1.91 a 48

Fonte: Autoria própria (2020).

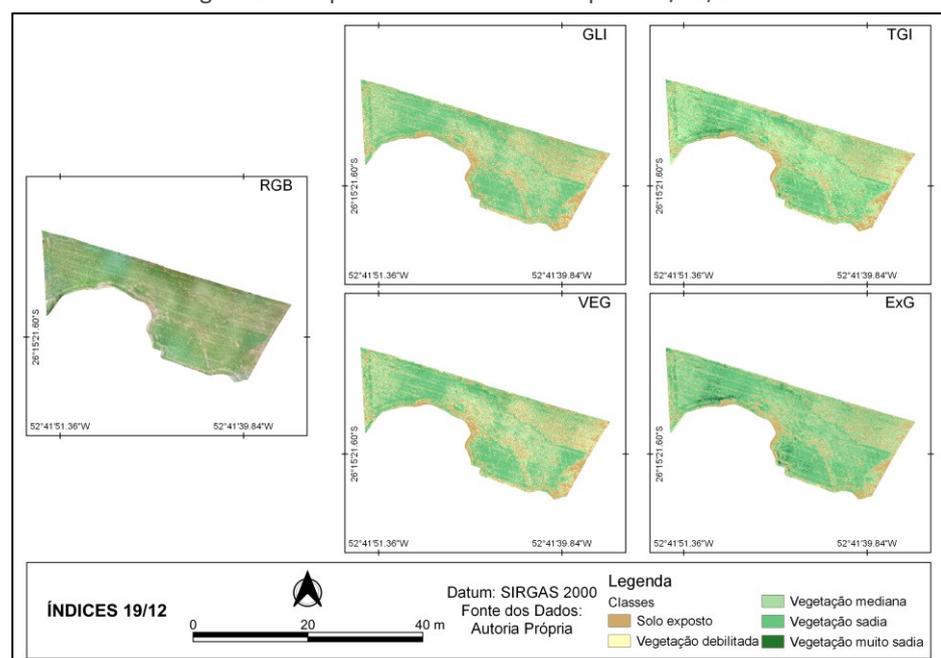
Em seguida a área ocupada por cada classe, em cada índice, foi calculada pela função GRASS “r.report” do programa, que reporta a contagem de pixels para cada classe e fornece a respectiva extensão física. Além disso, a partir das áreas, no Minitab 19, foram realizados cálculos de estatísticas descritivas, como média, mediana, desvio padrão e amplitude, possibilitando a confecção de gráficos boxplot, que demonstram a distribuição de dados em relação a suas tendências centrais, representando visualmente a maneira como determinada medida variou. No caso deste trabalho, trata-se da dispersão das áreas obtidas para cada classe em seus respectivos dias, podendo assim, analisar a similaridade dos resultados obtidos para cada índice de vegetação. Essa estatística, juntamente com a fotointerpretação, possibilitou que os quatro índices fossem avaliados entre si.

RESULTADOS E DISCUSSÕES

Os voos possibilitaram a confecção de três ortomosaicos, com *Ground Sample Distance* (GSD), ou resolução espacial das imagens obtidas, de 2,36cm/pixel. Os dois primeiros voos foram realizados em torno do mesmo horário do dia, por volta das 11:00 conforme o fuso horário de Brasília, e o terceiro por volta das 14:30, visando uma menor cobertura de sombras devido a incidência de raios solares nesses horários.

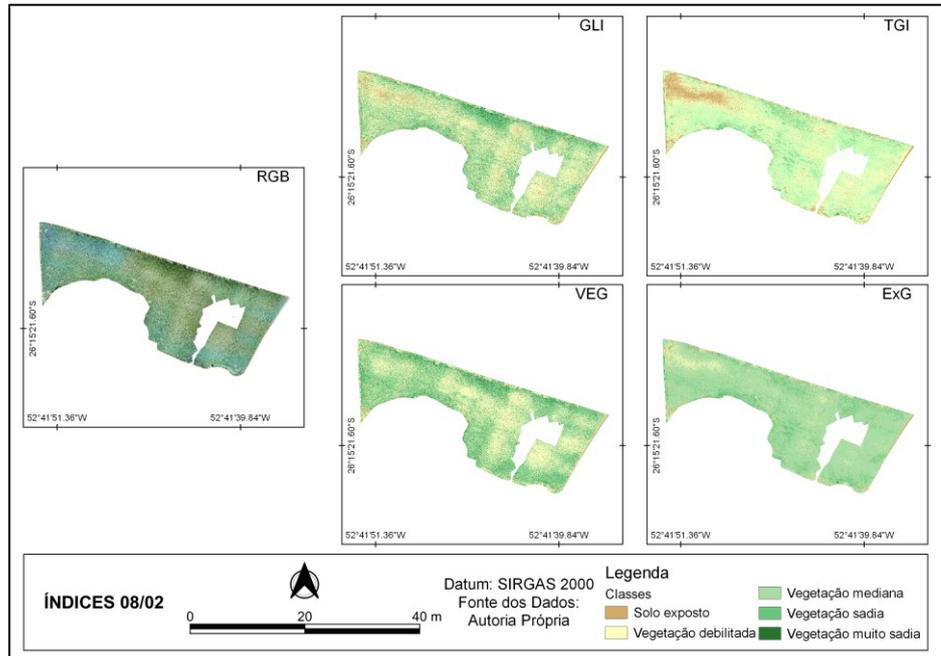
O voo 2 de fevereiro, apresentou falhas de processamento em áreas, sem pixels, que por sua vez afetaram os índices, que não puderam ser corrigidas usando os parâmetros deste trabalho, mesmo processando-a em *softwares* diferentes. Os ortomosaicos, após processamento no QGIS e devidos recortes para a área de interesse, resultaram no total de 15 mapas. Sendo para cada voo um em RGB e quatro para os índices calculados, os quais podem ser visualizados nas figuras 2, 3 e 4 que apresentam os mapas elaborados.

Figura 2 – Mapas dos índices obtidos para 19/12/2019



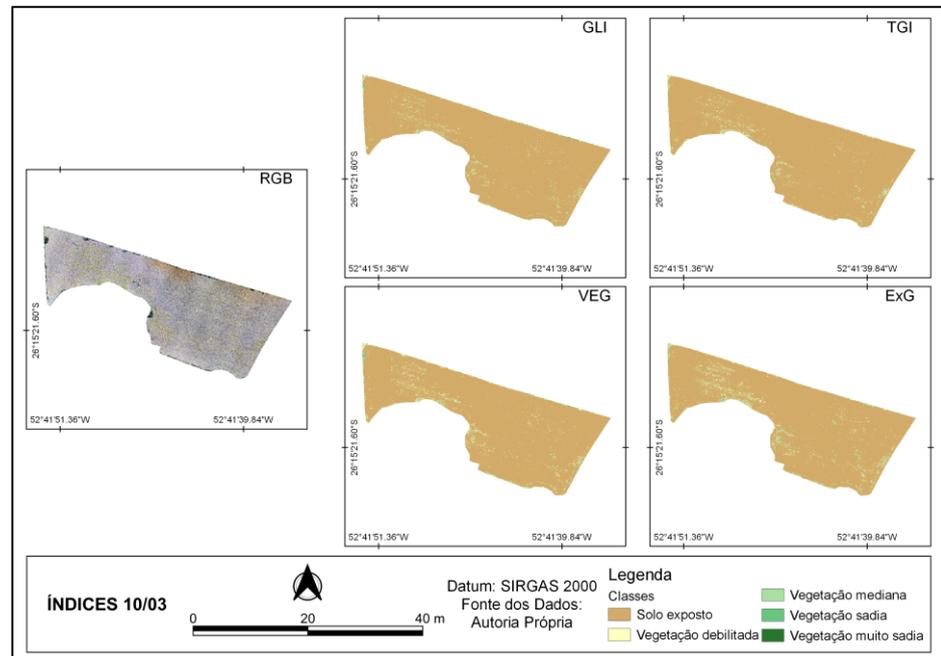
Fonte: Autoria própria (2020).

Figura 3 – Mapas dos índices obtidos para 08/02/2020



Fonte: Autoria própria (2020).

Figura 4 – Mapas dos índices obtidos para 10/03/2020



Fonte: Autoria própria (2020).

A área média obtida para os ortomosaicos, a partir de polígonos vetorizados, foi de 55070,29m². Além disso, foram calculadas as áreas para cada classe e suas respectivas porcentagens da área total, do respectivo dia, para cada índice, que são apresentadas na Tabela 2, 3 e 4.

Tabela 2 – Áreas calculadas para o dia 19/12/2019

Índice de Vegetação	Área (m ²) para cada classe no dia 19/12/2019				
	Solo exposto	Vegetação debilitada	Vegetação mediana	Vegetação sadia	Vegetação muito sadia
ExG	9156,38	4076,57	15918,67	24346,04	1111,37
GLI	12125,53	8337,88	13003,02	21040,17	100,19
TGI	11430,82	4942,61	16007,61	21579,74	648,38
VEG	11822,00	9939,06	12311,14	20128,92	405,14

Fonte: Autoria própria (2020).

Tabela 3 – Áreas calculadas para o dia 08/02/2020

Índice de Vegetação	Área (m ²) para cada classe no dia 08/02/2020				
	Solo exposto	Vegetação debilitada	Vegetação mediana	Vegetação sadia	Vegetação muito sadia
ExG	1468,74	3454,06	39503,44	7396,51	107,40
GLI	3613,88	20667,57	13000,40	13104,91	1535,95
TGI	5798,32	16418,36	26663,73	2967,81	81,94
VEG	1514,22	16937,18	14448,00	15490,12	3221,25

Fonte: Autoria própria (2020).

Tabela 4 – Áreas calculadas para o dia 10/03/2020

Índice de Vegetação	Área (m ²) para cada classe no dia 10/03/2020				
	Solo exposto	Vegetação debilitada	Vegetação mediana	Vegetação sadia	Vegetação muito sadia
ExG	51194,23	1954,70	1146,85	151,88	9,02
GLI	52363,75	1283,01	376,63	380,12	38,63
TGI	52657,15	1028,54	577,65	174,23	19,33
VEG	51976,37	1672,85	336,10	344,10	85,61

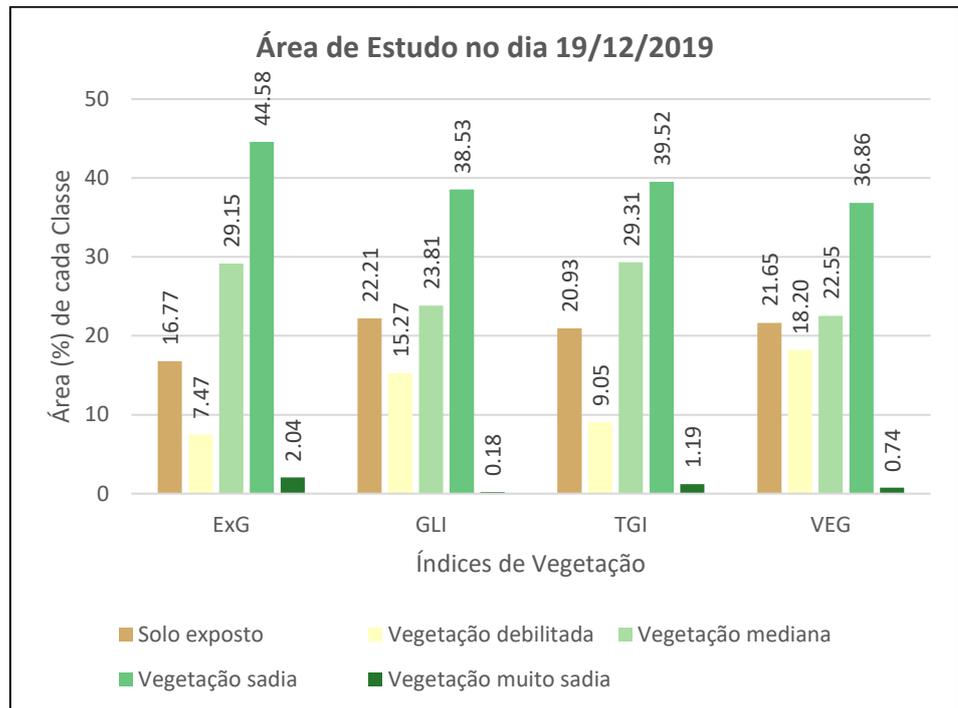
Fonte: Autoria própria (2020).

Ao que tange a composição RGB dos ortomosaicos obtidos, pode-se dizer que os de dezembro e março representaram fielmente a plantação, já que no voo 2 houveram falhas no ortomosaico, tendo sua representação degradada, o que afetou diretamente os índices de vegetação posteriormente.

Em linhas gerais, através da fotointerpretação das imagens RGB pode-se perceber claramente onde há plantas e onde há solo exposto, com existência de regiões mais esbranquiçadas e outras mais escuras. Nota-se também uma variação na tonalidade da cor apresentada pela cultura, conforme ilustrado pelas figuras 2, 3 e 4.

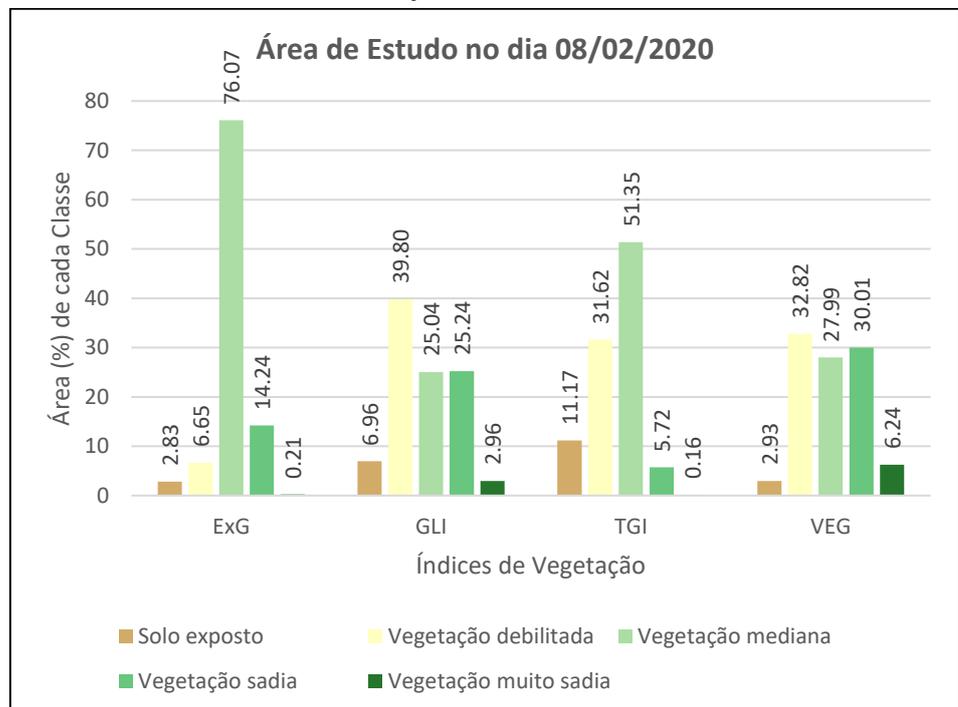
Os índices de vegetação apresentaram resultados semelhantes em algumas datas, principalmente no primeiro e terceiro voo. As diferenças serão melhor elucidadas pelos gráficos 1, 2 e 3.

Gráfico 1 – Situação da área no dia 19/12/2019



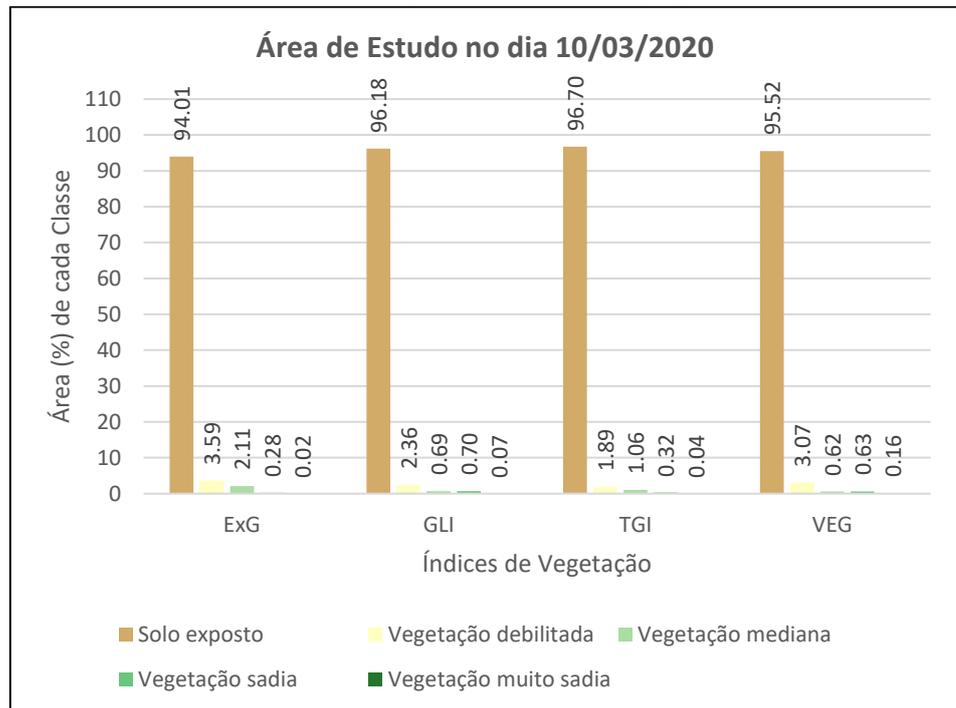
Fonte: Autoria própria (2020).

Gráfico 2 – Situação da área no dia 08/02/2020



Fonte: Autoria própria (2020).

Gráfico 3 – Situação da área no dia 10/03/2020



Fonte: Autoria própria (2020).

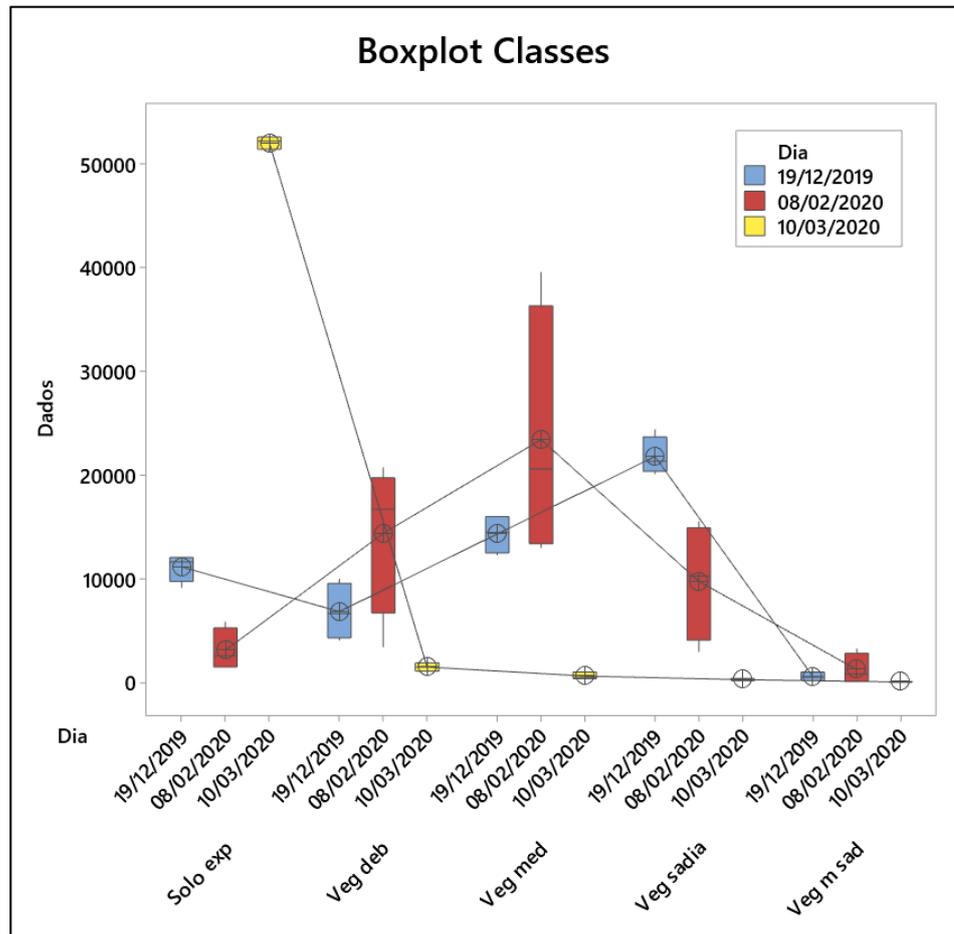
Dado o exposto, pode-se concluir que GLI e VEG foram bastante semelhantes em todas as datas. Além disso, com o intuito de melhor descrever a área para cada dia e analisar a distribuição dos dados, foram confeccionados a figura 5, com as estatísticas descritivas e o gráfico boxplot 4.

Figura 3 – Estatísticas descritivas

Estatísticas							
Variável	Dia	Média	DesvPad	Mínimo	Mediana	Máximo	Amplitude
Solo exposto	19/12/2019	11134	1349	9156	11626	12126	2969
	08/02/2020	3099	2059	1469	2564	5798	4330
	10/03/2020	52048	634	51194	52170	52657	1463
Vegetação debilitada	19/12/2019	6824	2774	4077	6640	9939	5862
	08/02/2020	14369	7519	3454	16678	20668	17214
	10/03/2020	1485	410	1029	1478	1955	926
Vegetação mediana	19/12/2019	14310	1930	12311	14461	16008	3696
	08/02/2020	23404	12359	13000	20556	39503	26503
	10/03/2020	609	374	336	477	1147	811
Vegetação sadia	19/12/2019	21774	1816	20129	21310	24346	4217
	08/02/2020	9740	5649	2968	10251	15490	12522
	10/03/2020	262,6	116,2	151,9	259,2	380,1	228,2
Vegetação muito sadia	19/12/2019	566	427	100	527	1111	1011
	08/02/2020	1237	1487	82	822	3221	3139
	10/03/2020	38,1	33,9	9,0	29,0	85,6	76,6

Fonte: Autoria própria (2020).

Gráfico 4 – Boxplot áreas de cada classe

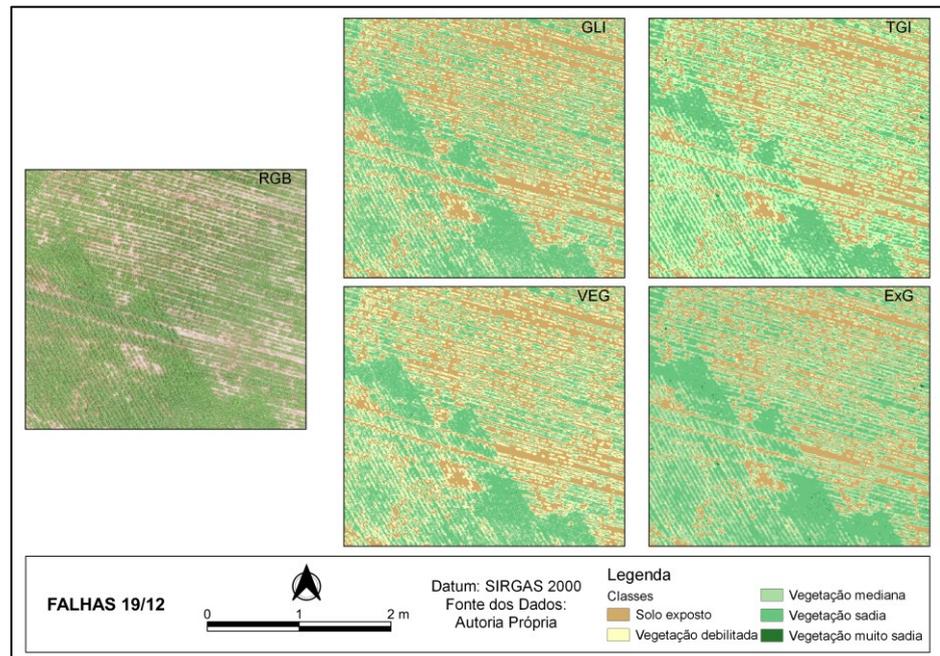


Fonte: Autoria própria (2020).

Conforme ilustrado, a um primeiro momento podemos notar pelo boxplot que o voo de março foi o mais coerente entre os resultados obtidos com os índices, pois houve pouca variação nas medidas observadas, sendo seguido pelo de dezembro e depois pelo de fevereiro. Podemos observar que solo exposto e vegetação muito sadia foram as classes com a maior semelhança entre os índices também. Os índices que mais se aproximaram dos valores médios de classe foram: TGI para solo exposto; TGI para vegetação debilitada no voo 1 e 2, VEG para o voo 3; GLI para vegetação mediana no voo 1, TGI para o voo 2 e 3; TGI para vegetação sadia no voo 1, ExG no voo 2 e VEG para o voo 3; TGI para vegetação muito sadia no voo 1, GLI para o voo 2 e 3. Assim, a partir das médias, podemos dizer que o TGI foi o melhor representante, seguido pelo GLI, contudo, isso não necessariamente significa que foram os que mais se aproximaram da fotointerpretação, fato que será discutido nos próximos parágrafos.

Para o dia 19/12, no período inicial da soja, a partir da fotointerpretação, nota-se uma maior cobertura de vegetação sadia, bem como a identificação de falhas no plantio, que se localizam principalmente na região central e nordeste da área estudada, sendo representadas pela classe solo exposto, conforme mostrado na figura 6. Nesse voo em específico, o GLI melhor representou o que pode ser interpretado através da composição RGB, assim como se vê na figura 2.

Figura 6 – Falhas observadas na área central



Fonte: Autoria própria (2022).

No dia 08/02, o desempenho dos índices não se deu conforme esperado, devido ao ortomosaico, resultando em grandes áreas com vegetação debilitada e solo exposto onde na verdade não havia, como é o caso do TGI e GLI. Ademais, em comparação com o voo anterior, pouca vegetação sadia foi detectada, o que não condiz com a realidade, porque a soja estava em seu máximo vigor. Porém, é interessante notar que a grande maioria das falhas em meio ao plantio sumiram, com redução significativa da quantidade de solo exposto detectada, conforme gráfico 2, mostrando o crescimento das plantas, mas algumas se mantiveram e os índices as detectaram com precisão onde havia, de fato, solo exposto. Nota-se que, na extremidade superior esquerda, a composição RGB se mostrou com uma tonalidade azulada, a qual implicou em classes de vegetação debilitada (VEG, GLI e ExG) ou solo exposto (TGI e GLI). Para esse voo, considera-se o ExG como o melhor representante, com cobertura homogênea de vegetação, fato que pode ser observado na figura 3.

Já no dia 10/03, com a vegetação quase que totalmente seca, com tons de cinza predominantes pela imagem RGB, os índices detectaram a área como solo exposto, salve casos onde as plantas ainda apresentavam uma coloração verde, bem mais amena que nos outros voos, que foi classificada em sua maioria como vegetação debilitada. Nesse sentido, os resultados foram bastante semelhantes, porém, os mais coerentes com a imagem RGB vieram do VEG, como o obtido na figura 4.

CONSIDERAÇÕES FINAIS

Quanto aos índices individualmente, pode atestar-se que:

- VEG – Mostrou-se sensível quanto às alterações na coloração da vegetação, representando grandes áreas de vegetação sadia no 1° e 2° voo, bem como áreas de vegetação debilitada onde havia alta reflectância e solo exposto, em conformidade com a realidade;
- TGI – Foi o índice mais suscetível às alterações na coloração das plantas, como percebido no 1° voo, com o alto percentual de vegetação de saúde mediana, e no 2°, com a identificação de solo exposto onde haviam plantas;
- ExG – Representou bem a cobertura vegetal, tendo as maiores taxas de vegetação sadia e muito sadia no 1° voo, além de quase não apresentar vegetação debilitada no 2° voo, em contraste aos demais. Informou com precisão onde havia solo exposto;
- GLI – Também se mostrou sensível às mudanças de coloração das plantas, demonstrando, no 1° voo, as falhas ao longo do plantio e áreas de vegetação saudável, bem como solo exposto. Pode-se perceber, no 2° voo, que regiões com reflectância maior resultam principalmente em vegetação debilitada.

Dado o exposto, pode-se elencar que os índices, do melhor para o pior, levando em consideração a avaliação da cobertura da área estudada, em comparação com as imagens RGB, como: ExG, GLI, VEG e TGI. Porém, é importante lembrar que todos apresentaram resultados bastante semelhantes, e devem ser aplicados de acordo com a necessidade específica de cada situação.

Todos os índices representaram com êxito alguma característica da vegetação, porém, foram observadas tanto identificações coerentes com as imagens RGB, quanto discrepantes. Outro problema observado foi a falta de consistência dos índices, onde em uma análise um índice se demonstrava eficaz para a detecção de solo exposto, na outra era exatamente o oposto, não sendo possível encontrar uma tendência nos dados. Todos os índices foram, de alguma maneira, afetados pela variabilidade das condições de iluminação.

Também vale ressaltar que a curva espectral (como as plantas refletem radiação eletromagnética) não é tão bem desenhada para a faixa do RGB quando comparada a outros comprimentos de onda, como o infravermelho próximo, fazendo com que os índices RGB tenham limitações quanto a sua utilização para determinar parâmetros.

Diante disso, fica evidente que os índices estudados ainda não possuem consistência suficiente para análises precisas no âmbito da saúde da soja, explicitando-se a necessidade de um estudo mais aprofundado na área de índices de vegetação RGB para essa finalidade, visto que os mesmos possuem bastante potencial científico e comercial. Por final, nota-se que os índices facilitaram a interpretação do que estava ocorrendo na plantação. Sugere-se ainda, para pesquisas futuras, que os resultados obtidos pelos mapas gerados sejam associados com amostragem das plantas em campo, para verificar o verdadeiro estado da vegetação.

Analysis of the soybean culture with vegetation indexes (ExG - GLI - TGI - VEG) from RGB images obtained with RPA

ABSTRACT

The analysis of plantations based on images in agriculture is a technology that has been used for some time. Nowadays, with RPAs, this process is more accessible, being the focus of this paper: to accompany the growth of soybean with this equipment. To do this, the images were processed by the softwares Agifost PhotoScan and Agisoft Metashape, while the calculus of the indexes (ExG, GLI, TGI and VEG) were done by Quantum GIS, as well as the production of thematic maps, that, with the photointerpretation and statistical analysis, were able to show more easily, relevant information about the vegetation health, detecting healthy and debilitated regions and also soil. These thematic maps, obtained by the creation of classes with the values returned by the indexes, were important to facilitate the comprehension of what was happening in the different development stages and the soybean growth. Besides that, it was possible to list the indexes about their representation of the soybean to the specific case of this study.

KEYWORDS: Soybean. Vegetation Index. Drone. RPA. Precision Agriculture.

REFERÊNCIAS

ANDRADE, Ricardo Guimarães *et al.* Uso de veículo aéreo não tripulado (VANT) como plataforma para monitoramento da produção agropecuária: estudo de caso para o milho forrageiro. **Embrapa Gado de Leite**, Juiz de Fora, Documentos, 233, abr. 2019. 20p. Disponível em: <http://dx.doi.org/10.22533/at.ed.00619240721>. Acesso em: 10 mai. 2022.

CRUZ, A. C. **Estimativa da densidade de plantação de cana de açúcar utilizando o espaço de cor CIE LAB em imagens de alta resolução especial providas de VANTs**. Dissertação (Mestrado em Ciências Ambientais) – Universidade Estadual Paulista, Sorocaba (SP), 2020. Disponível em: <http://hdl.handle.net/11449/194254>. Acesso em: 21 jun. 2021.

HUNT, E. R. Jr. *et al.* Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. **Agronomy Journal**, v. 103, n. 4, p.1090-1099, mai. 2011.

HUNT, 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, ago. 2018. Disponível em: <https://doi.org/10.1080/01431161.2017.1410300>. Acesso em: 25 mai. 2020.

JANNOURA, R. *et al.* Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. **Biosystems Engineering**, v. 129, p. 341–351, 2015. Disponível em: <https://doi.org/10.1016/j.biosystemseng.2014.11.007>. Acesso em: 25 mai. 2020.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, n. 1, p. 65–70, mar. 2001.

MERCHANT, J.A.; ONYANGO, C.M. Shadow-invariant classification for scenes illuminated by daylight. **Journal of the Optical Society of America**, v. 17, n. 11, p. 1952–1961, 2002.

MCKINNON, T.; HOFF, P. **Comparing RGB-Based Vegetation Indices With NDVI For Drone Based Agricultural Sensing**. Colorado, 2017.

MOTOHKA, T. *et al.* 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: 10 mai. 2022.

FREIRE-SILVA, J. *et al.* Índices de vegetação do sensoriamento remoto para processamento de imagens na faixa do visível (RGB). **Journal of Hyperspectral Remote Sensing**, v.9, n.4, p. 228-239, 2019. Disponível em: <http://dx.doi.org/10.29150/jhrs.v9.4.p228-239>. Acesso em: 30 mai. 2020.

WOEBBECKE, D. M. *et al.* Shape features for identifying young weeds using image analysis. **Transactions of the ASAE (American Society of Agricultural Engineers)**, v. 38, n. 1, p. 271–281, 1995.

ZHANG, C.; WALTERS, D.; KOVACS, J. M. Applications of low altitude remote sensing in agriculture upon farmers' requests-A case study in northeastern Ontario, Canada. **PLoS ONE**, v. 9, n. 11, p. 17–19, 2014. Disponível em: <https://doi.org/10.1371/journal.pone.0112894>. Acesso em: 25 mai. 2020.

Recebido: 14 dez. 2021

Aprovado: 23 jun. 2022

DOI: 10.3895/rbgeo.v10n2.15042

Como citar: SILVA, M. H; ELIAS, A. R; ROSÁRIO, L. L. Análise da cultura da soja a partir de índices de vegetação (ExG – TGI – GLI - VEG) advindos de imagens RGB obtidas com ARP. **R. bras. Geom.**, Curitiba, v. 10, n. 2, p. 140-154, abr./jun. 2022. Disponível em: <<https://periodicos.utfpr.edu.br/rbgeo>>. Acesso em: XXX.

Correspondência:

Adão Robson Elias

Rua Via do Conhecimento, Km 01, CEP 85503-390, Pato Branco, Paraná, Brasil.

Direito autoral: Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

