

UNIVERSIDADE FEDERAL DE ALFENAS

TAYA CRISTO PARREIRAS

**MONITORAMENTO DO NITROGÊNIO FOLIAR E DA COBERTURA VEGETAL
DE CAFEEIROS EM SISTEMA DE CULTIVO ORGÂNICO COM AERONAVE
REMOTAMENTE PILOTADA**

**Alfenas/MG
2020**

**MONITORAMENTO DO NITROGÊNIO FOLIAR E DA COBERTURA VEGETAL DE CAFEEIROS
EM SISTEMA DE CULTIVO ORGÂNICO COM AERONAVE REMOTAMENTE PILOTADA**

A Banca examinadora abaixo-assinada aprova a Dissertação apresentada como parte dos requisitos para a obtenção do título de Mestre em Ciências Ambientais pela Universidade Federal de Alfenas. Área de concentração: Ciências Ambientais.

Aprovada em: 26 de agosto de 2020

Prof. Dr. Ronaldo Luiz Mincato

Instituição: Universidade Federal de Alfenas

Prof. Dr. Breno Régis Santos

Instituição: Universidade Federal de Alfenas

Prof. Dr. Walbert Junior Reis dos Santos

Instituição: Instituto Federal de Educação do Sul de Minas Gerais



Documento assinado eletronicamente por **Ronaldo Luiz Mincato, Professor do Magistério Superior**, em 26/08/2020, às 16:01, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Breno Régis Santos, Professor do Magistério Superior**, em 26/08/2020, às 16:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Walbert Junior Reis dos Santos, Usuário Externo**, em 26/08/2020, às 16:03, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.unifal-mg.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0363799** e o código CRC **2EE1FE3F**.

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal de Alfenas

P258m Parreiras, Taya Cristo.
Monitoramento do nitrogênio foliar e da cobertura vegetal de
cafeeiros em sistema de cultivo orgânico com aeronave remotamente
pilotada / Taya Cristo Parreiras. -- Alfenas/MG, 2020.
83f. il. –

Orientador: Ronaldo Luiz Mincato.
Dissertação (Mestrado em Ciências Ambientais) - Universidade Federal
de Alfenas, 2020.
Bibliografia.

1. Vegetação – Classificação. 2. Vegetação – Mapeamento. 3. Café. 4.
Nitrogênio. I. Mincato, Ronaldo Luiz. II. Título.

CDD-631.5

AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Agradeço também à toda a sociedade brasileira, uma vez essa oportunidade somente foi possível graças à colaboração de cada cidadão com o avanço da educação no país.

Ao Prof. Dr. Ronaldo Luiz Mincato, por me receber e orientar com dedicação e carinho, e por todo o aprendizado nesta que, sem dúvida, foi uma das minhas mais importantes conquistas.

À toda equipe de técnicos e professores do PPGCA, tanto pelos conhecimentos transmitidos, quanto pelo trabalho burocrático que suportam as nossas atividades.

Aos meus colegas de laboratório: Guilherme, Rodrigo, Luís Felipe, Derielsen, Alexandre e Talyson, por toda colaboração, parceria e amizade que construímos. Nestes dois anos eu pude compreender o que significa trabalhar em equipe, graças a vocês.

Ao Rafael Jacob, não só por ter cedido a área para que meu estudo pudesse ser realizado, mas também pela hospitalidade e atenção que teve com nossa equipe, e pelo compromisso social e ambiental que está impregnado em todas as suas iniciativas.

À Prof. Dra. Olga Luísa Tavano, por toda paciência, acolhimento e orientação durante as análises foliares, fase longa e crucial do trabalho. À Adriana, por todo o trabalho de apoio durante essas análises.

À nossa técnica de laboratório, Marcilene, por toda a paciência, dedicação e boa vontade em tornar o nosso ambiente de trabalho um lugar agradável.

À toda a equipe de apoio da Adcon, que sempre trabalha duro para manter nosso lugar de trabalho confortável, seguro e funcional.

À minha família: Izilda, Otávio, Francisca e Osvaldo, que formaram a base sobre a qual cresci e me desenvolvi.

Por fim, à minha esposa, Sheila, base da minha vida, meu lar.

RESUMO

Imagens de alta resolução obtidas em aerolevantamentos com aeronaves remotamente pilotadas têm sido incorporadas aos estudos agrícolas com o objetivo de auxiliar no planejamento do uso da terra e dos insumos agrícolas, colaborando, assim, com o desenvolvimento de práticas agrícolas mais sustentáveis. Neste contexto, o objetivo deste estudo foi avaliar o potencial de índices de vegetação do visível, de alta resolução, em monitorar o status e estimar o teor do Nitrogênio foliar de cafeeiros em transição para sistema de cultivo orgânico. A pesquisa foi realizada em duas fases: a primeira foi realizada em maio de 2019 e consistiu em um único voo para imageamento, além de leituras com o clorofilômetro SPAD e análises foliares (método Kjeldahl para determinação do teor de Nitrogênio) em uma área de 1 ha não controlada. Nesta fase, foram empregados como métodos de análise e estimativa o coeficiente de correlação de Pearson, a análise de variância, além de modelos de classificação e regressão com o algoritmo *Random Forest*. Na segunda fase, uma área de 0,23 ha foi dividida em 16 parcelas, nas quais foram aplicadas 4 doses de fertilizante orgânico (0, 87,5, 175 e 262 kg N ha⁻¹), e foram realizados voos em outubro de 2019, e janeiro e março de 2020, além de leituras com o clorofilômetro SPAD e análises foliares (método Kjeldahl) em outubro e janeiro. Além disso, a variação do índice de cobertura vegetal ao longo do tempo também foi utilizada como variável de análise. Para a análise estatística, também foram usados o coeficiente de correlação de Pearson e a análise de variância, além de modelos de regressão linear e logística. Na primeira fase do estudo, os modelos de regressão e classificação não conseguiram monitorar a variabilidade do Nitrogênio na área, e as correlações deste com os índices de vegetação e os valores SPAD não foram estatisticamente significativas. Contudo, nesta fase, as imagens foram muito eficientes para a classificação supervisionada. Na segunda fase também não foram identificadas correlações significativas entre os índices de vegetação e o Nitrogênio foliar em nenhum momento da pesquisa. Os modelos de regressão logística, elaborado com os índices individualmente e em conjunto, também não foram capazes de identificar a variação nutricional dos cafeeiros. Por outro lado, as leituras com o SPAD se relacionaram fortemente com o teor de Nitrogênio foliar em janeiro de 2020. O índice de cobertura vegetal se relacionou positivamente com os diferentes tratamentos, embora a análise de variância tenha mostrado que as diferenças entre as médias não tenham sido significativas. Apesar disso, o uso de imagens do visível no monitoramento no Nitrogênio ainda é incipiente, e novas pesquisas são necessárias para maior compreensão dos fatores que possam interferir nos resultados. Além disso, essas

imagens se mostraram úteis no monitoramento da fração da cobertura vegetal, informação muito importante para o gerenciamento das práticas agrícolas, não somente na cafeicultura.

Palavras-chave: Vegetação - Classificação; Vegetação – Mapeamento; Café; Nitrogênio.

ABSTRACT

High-resolution images, obtained in aerial surveys with remotely piloted aircraft, have been incorporated into agricultural studies to assist in the planning of land use and agricultural inputs, and thus collaborate with the development of more sustainable agricultural practices. In this context, the objective of this study was to evaluate the potential of vegetation indices, coming from images of the visible region, in monitoring the status and estimating the leaf Nitrogen content of coffee trees in transition for organic farming system. The research was carried out in two phases: the first phase was carried out in May 2019, and consisted of a single flight for imaging, in addition to readings with the SPAD chlorophyll meter and leaf analysis (Kjeldahl method for determining the Nitrogen content) in an uncontrolled area of 1 ha. In this phase, Pearson's correlation coefficient, analysis of variance, and classification and regression models with the Random Forest algorithm were used as methods of analysis and estimation. In the second phase, an area of 0.23 ha was divided into 16 plots, in which 4 doses of organic fertilizer (0, 87.5, 175 and 262 kg N ha⁻¹) were applied, and flights were carried out in October 2019, and January and March 2020, in addition to readings with the SPAD chlorophyll meter and leaf analysis (Kjeldahl method) in October and January. In addition, the variation in the vegetation cover index over time was also used as a variable of analysis. For statistical analysis, Pearson's correlation coefficient and analysis of variance were also used, along with logistic regression models. In the first phase of the study, the regression and classification models failed to monitor Nitrogen variability in the area, and its correlations with vegetation indices and SPAD values were not statistically significant. However, the images were very efficient for the supervised classification of land use. In the second phase, no significant correlations were found between the vegetation indices and leaf nitrogen at any time during the research. The logistic regression models, elaborated with the indices individually and combined, were also not able to identify the nutritional variation of the coffee trees. On the other hand, the readings with the SPAD were strongly related to the leaf nitrogen content in January 2020. The vegetation cover index was positively related to the different treatments, although the analysis of variance showed that the differences between the means were not significant. Despite this, the use of visible images in monitoring Nitrogen is still incipient, and further research is needed for a better understanding of the factors that may interfere with the results. In addition, these images proved to be efficient

in monitoring the fraction of vegetation cover, very important information for the management of agricultural practices, not only in coffee growing.

Keywords: Vegetation - Classification; Vegetation - Mapping; Coffee; Nitrogen.

SUMÁRIO

1	REVISÃO DE LITERATURA.....	9
1.1	Adubação nitrogenada: produtividade agrícola e impactos ambientais.....	9
1.2	Café: importância econômica para o Brasil e compromisso com a sustentabilidade.....	11
1.3	Imagens aéreas e fundamentos do sensoriamento remoto da vegetação.....	14
1.3.1	Aerofotogrametria e a evolução dos levantamentos aéreos.....	15
1.3.2	Fundamentos básicos de sensoriamento remoto.....	16
1.3.3	Interação da radiação eletromagnética com a vegetação.....	20
1.3.4	Índices de Vegetação e aplicações em estudos agroambientais.....	24
1.4	Aeronaves remotamente pilotadas (RPA): definições, aspectos legais e suas aplicações no monitoramento agrícola.....	27
1.4.1	Uso de RPA em estudos agrícolas e no monitoramento do nitrogênio de lavouras.....	29
	REFERÊNCIAS.....	37
	SEGUNDA PARTE.....	44
	Artigo 1: Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee.....	44
	TERCEIRA PARTE.....	60
	Artigo 2: Monitoramento do nitrogênio foliar de cafeeiros com índices de vegetação e índice de cobertura vegetal de imagens RGB de alta resolução.....	60
2	CONSIDERAÇÕES FINAIS.....	82

1 REVISÃO DE LITERATURA

1.1 ADUBAÇÃO NITROGENADA: PRODUTIVIDADE AGRÍCOLA E IMPACTOS AMBIENTAIS

O avanço científico e a descoberta da síntese química da amônia (NH_3) pelo processo de Harber-Bosch permitiu a rápida redução do Nitrogênio atmosférico (N_2) para suas formas reativas (N_r), aumentando o suprimento de Nitrogênio (N) para produção de alimentos de forma exponencial em todo o mundo (VEIRA, 2017; ZHANG *et al.*, 2015) e dobrando a ciclagem de N no século XX (FOWLER, 2013).

Na cafeicultura, o N é um dos nutrientes mais requeridos, uma vez que compõe a estrutura celular das plantas, e sua falta é a mais limitante para a produção. Assim, a produção de café também se beneficiou do aumento de produtividade pela crescente aplicação de fertilizantes nitrogenados (FENILLI *et al.*, 2008).

Em 2013 foram produzidas mais de 120 milhões de toneladas de amoníaco usado na indústria de fertilizantes, sendo que o Brasil faz parte dos maiores consumidores mundiais, grupo que também é composto por China, Índia e Estados Unidos. Para atender a demanda de alimentos da população mundial em crescimento, sem a produção de fertilizantes, seria necessário um crescimento superior a 200% de terras destinadas à agricultura, o que levaria à elevadas perdas de ambientes naturais (VIEIRA, 2017).

Apesar da extrema importância para o aumento da produtividade agrícola e para a garantia da segurança alimentar, a produção e o uso em larga escala de fertilizantes nitrogenados estão ligados a impactos ambientais que colocam em risco não só ecossistemas, mas a saúde humana e a própria produção de alimentos. A produção de amônia, fonte de diferentes tipos de fertilizantes, consome cerca de 1 a 2% da energia produzida no mundo, e também é responsável pela liberação de CO_2 (VIEIRA, 2017).

No que diz respeito ao consumo, em ambientes agrícolas as plantas são capazes de aproveitar cerca de 40 a 50% do N aplicado, o que resulta não apenas em prejuízos econômicos, mas também em perdas para o ambiente (FENILLI *et al.*, 2008; CHAGAS *et al.*, 2019), sendo que essas perdas estão relacionadas a processos que resultam em impactos ambientais negativos, tais como a volatilização de amônia (NH_3), a lixiviação de nitrato (NO_3^-), e a emissão de óxido nitroso (N_2O) (VIEIRA, 2017; FOWLER, 2013).

A volatilização de amônia é uma das principais causas da perda de eficiência de fertilizantes nitrogenados, especialmente a ureia, fertilizante mais utilizado no Brasil. Este

processo envolve a perda de N por meio da emissão de NH_3 , e é um fenômeno que varia de acordo com as condições climáticas (temperatura e umidade do ar), com as características do solo (pH, umidade, teor de matéria orgânica e capacidade de troca catiônica, e também com o manejo e a presença de inibidores no próprio fertilizante), sendo que as perdas podem variar entre 1 a 50% do N aplicado (VIEIRA, 2017; TASCA *et al.*, 2011).

A amônia pode permanecer na atmosfera local por até 2 semanas, impactando as demais espécies vegetais do entorno, pode reagir com óxidos de enxofre (SO_2 e SO_3) da atmosfera, formar sulfato de amônio $(\text{NH}_4)_2\text{SO}_4$ e atingir o solo pelas chuvas, causando acidificação, o que por sua vez aumenta as perdas por volatilização. Além disso, afeta negativamente o balanço de nutrientes e a diversidade biológica (VIEIRA, 2017).

A lixiviação de nitratos (NO_3^-) para profundidades abaixo das raízes é outra fonte de impactos que resulta da aplicação de fertilizantes nitrogenados, pois causa a contaminação das águas subterrâneas. A intensidade desse processo é influenciada pelo desbalanço entre a quantidade aplicada e a capacidade de absorção e assimilação das plantas, bem como pelo regime de chuvas, podendo ser responsável por perdas de 10 a 30% do N aplicado, embora no Brasil, devido à profundidade do lençol freático, essa intensidade seja maior apenas em períodos chuvosos (VIEIRA, 2017; JADOSKI *et al.*, 2010).

O aumento da concentração de nitrato nas águas subterrâneas, que eventualmente alcançam as águas superficiais, pode contribuir para o aumento da vegetação aquática (eutrofização), que reduz a qualidade da água para consumo e recreação, e causa a morte de peixes pela falta de oxigênio (VIEIRA, 2017).

Quando ingerido por crianças, o nitrato é reduzido no trato intestinal e, ao atingir a corrente sanguínea, gera o desenvolvimento da metahemoglobina, composto que prejudica a capacidade de transporte de oxigênio pelo sangue (VIEIRA, 2017; JADOSKI *et al.* 2010). Além disso, as nitrosaminas, formadas na água por reações do nitrato com compostos aminados, estão relacionadas com a ocorrência câncer de estômago e próstata (VIEIRA, 2017).

A emissão de óxido nitroso (N_2O) pelos solos agrícolas, que ocorre principalmente em função dos processos de nitrificação e desnitrificação, também é uma fonte de impactos na atmosfera, contribuindo no processo de mudanças climáticas, sendo que a produção de alimentos, especialmente de origem animal, é responsável por cerca de 80% das emissões (VIEIRA, 2017).

O N_2O é um gás de efeito-estufa, fonte natural de poluição, que impacta a atmosfera, tanto com seu aquecimento, quanto com a depleção da camada de ozônio estratosférico

(THOMPSON *et al.*, 2019). As emissões de N₂O provêm principalmente de fontes naturais (solos, oceanos, e incêndios florestais), mas são aceleradas por atividades antrópicas, entre elas, o uso de fertilizantes na agricultura (OMM, 2018).

O Boletim de Gases de Efeito Estufa da Organização Mundial de Meteorologia (OMM), publicado em 2018, mostra que o nível de óxido nitroso (N₂O) na atmosfera cresce, em média, 0,09 ppb por ano. O conteúdo global do gás na atmosfera atualmente é de cerca de 329.9 ppb, 25% maior que o nível registrado em 1940 (THOMPSON *et al.*, 2019) e 122% mais alto do que o nível estimado para o período pré-industrial, 270 ppb (OMM, 2018). Embora sua concentração seja inferior ao gás carbônico (CO₂) e ao gás metano (CH₄), o óxido nitroso causa impactos significativos mesmo com menores alterações (VIEIRA, 2017).

A agricultura encontra-se diante de um grande desafio: manter a alta produtividade e garantir a segurança alimentar de uma população mundial em crescimento, e que deve atingir 9,2bi em 2050, e ao mesmo tempo reduzir os impactos ambientais derivados de suas práticas, uma vez que estes ameaçam o equilíbrio dos ecossistemas, a qualidade dos recursos naturais e, portanto, a saúde humana (THOMPSON *et al.*, 2019; VIEIRA *et al.*, 2017; FOWLER *et al.*, 2013).

Dessa forma, serão necessárias mudanças nas práticas agrícolas visando aumentar a eficiência no uso de fertilizantes nitrogenados e também de outros insumos, além de alterações no padrão de consumo do ser humano (THOMPSON *et al.*, 2019), e ambos já estão impactando a produção de diversos produtos, entre eles o café.

1.2 CAFÉ: IMPORTÂNCIA ECONÔMICA PARA O BRASIL E O COMPROMISSO COM A SUSTENTABILIDADE

Originário do leste africano, em uma região onde se encontram Etiópia, Sudão, Sudão do Sul e Quênia, o café teve sua produção difundida em países tropicais e subtropicais, se caracterizando como um dos principais produtos do comércio mundial, de grande importância econômica e cultural (POTTS *et al.*, 2014).

Foi introduzido no Brasil ainda no século XVIII e se tornou uma das principais atividades econômicas do país, que se configura, há séculos, como o maior produtor mundial de café. Em 2018-2019, 36,8% da produção mundial, mais de 3,7 milhões de toneladas, foram produzidas no Brasil (ICO, 2020), em cerca de 2,16 milhões de hectares (CONAB, 2019). Apenas entre 1991 e 2019, a produção brasileira cresceu 130% (ICO, 2020).

Em 2017, o país exportou mais de 1,8 milhão de toneladas de grãos de café, principalmente para Estados Unidos, Alemanha, Itália, Japão e Bélgica, que consumiram, sozinhos, 62% do que foi exportado. No ranking de produtos de exportação do país, o café ocupa a 13ª posição e, em 2018, gerou uma renda, apenas com exportações, de US\$ 4,36 bilhões (BRASIL, 2020).

A produção de café, apesar da relevância econômica, sempre foi altamente suscetível à volatilidade de preços no mercado internacional, gerando períodos de altos ganhos, intercalados com períodos de grandes perdas. Diante desse cenário, em 1962, o Brasil e os demais países produtores, juntamente com os principais países consumidores, assinaram o primeiro Acordo Internacional do Café (AIC), que estabelecia, entre outras coisas, cotas de exportação do produto, visando estabelecer um regime de equidade e estabilidade de preços, elevando os preços a níveis mínimos (MUELLER, 1971).

No fim da década de 1980, devido à falta de consenso entre os países membros acerca das cotas de exportação e do regime de preços, além do baque sofrido pelo Brasil devido à mudança no padrão de consumo do café no mundo, em direção aos grãos de alta qualidade que eram produzidos principalmente na Colômbia, o AIC deixou de regular o mercado de exportações de café em julho de 1989 (GILBERT, 1996).

Após o fim das cláusulas econômicas do AIC, os países produtores entraram em um período de preços baixos e voláteis, situação que atingiu o ápice no século XXI. Além disso, os produtores de café ainda precisam lidar com problemas como o envelhecimento das comunidades produtoras, uma vez que os jovens estão deixando o campo; a baixa renda, a insegurança alimentar, a baixa produtividade, a falta de apoio institucional, a pressão pelos danos ambientais, entre outros (SAMPER; RUIZ, 2017).

Uma vez que a produção do café se concentra em países subdesenvolvidos de regiões de florestas tropicais, a indústria cafeeira se tornou pioneira na adoção de padrões de sustentabilidade e de certificações, o que leva à melhores práticas produtivas, e que pode representar uma alternativa para a obtenção de maiores rendas (POTTS *et al.*, 2014).

Embora em volume o Brasil lidere a comercialização de cafés certificados, em proporção, cerca de 40% do café produzido no país ainda provém de cultivo tradicional, enquanto na Colômbia, por exemplo, 100% da produção segue alguma norma voluntária de sustentabilidade (NVS) (POTTS *et al.*, 2014). A principal certificação do café brasileiro vem

da Associação 4C (POTTS *et al.*, 2014), que exige três dimensões de sustentabilidade: econômica, social e ambiental (4C ASSOCIATION, 2015).

No que diz respeito à dimensão ambiental exigida para a obtenção da certificação 4C, a associação exige que a fertilização seja feita de acordo com resultados de análises de solo e folhas, e também de acordo com a produtividade esperada, além de que ela seja feita em associação com matéria orgânica reutilizada, visando reduzir o uso de fertilizantes nitrogenados sintéticos, diminuindo impactos negativos, além de aumentar a fertilidade (4C ASSOCIATION, 2015).

A produção de cafés em conformidade com normas de sustentabilidade cresce cerca de 26% ao ano, e já representava, em 2012, cerca de 40% da produção mundial, embora apenas parte seja de fato vendida com certificação (cerca de 12% do total comercializado) (POTTS *et al.*, 2014).

Essa nova realidade enfrentada pelos produtores é um reflexo das amplas discussões e acordos firmados nas várias conferências internacionais que ocorreram desde Estocolmo, em 1972, pois o mercado consumidor, principalmente de países desenvolvidos, passou a exigir mudanças, e isso atingiu consideravelmente o mercado do café. A exigência de grãos de qualidade, bem como de práticas de manejo sustentáveis e comércio justo, deram início a uma era de certificações que transformaram a produção de café mundial em mais do que a venda do produto, mas também de experiências (SAMPER; RUIZ, 2017).

A Organização Internacional do Café (OIC), fundada em 1963, foi a instituição responsável pelo controle do mercado cafeeiro durante o período em que vigoraram as cláusulas econômicas do AIC de 1962 e, em 2007, publicou a versão mais recente do acordo, o AIC de 2007. O Brasil se tornou signatário em 2008, mas apenas em 2010 este passou a ter valor legal no país, por meio do Decreto Legislativo nº 806 (BRASIL, 2010).

O acordo de 2007 tem, entre outros, o objetivo encorajar os países membros a adotarem medidas visando a sustentabilidade na produção de café. Entre as preocupações da instituição estão as mudanças climáticas, pois a variabilidade do clima é a principal responsável pela instabilidade da produção mundial. Estratégias de curto e longo prazo envolvem adoção de melhores práticas agrícolas, aumento da fertilidade do solo, além da redução na emissão de GEE (ICO, 2020a).

Apesar de se destacar em quantidade, o Brasil ainda pode evoluir em qualidade, e isso se evidencia no preço médio obtido com as exportações: em 2018, o valor médio por kg de café

vendido pelo país foi cerca de US\$ 2,38, enquanto a Colômbia conseguiu uma média US\$ 3,19 kg⁻¹, e o México, US\$ 3,23 kg⁻¹ (ONU, 2019). Dos US\$ 31,8 bilhões que circularam no mercado de exportações de café no mundo, o Brasil arrecadou cerca de 14% dessa renda (ITC, 2018).

A valorização do café brasileiro passa, entre outras coisas, pela mudança da cultura de produção e de consumo, pelo entendimento da relevância da conservação ambiental. A “Agricultura de Precisão” (AP) é um ramo pelo qual estão sendo utilizadas tecnologias capazes de colaborar com os produtores no planejamento e no manejo das lavouras, considerando a variabilidade espacial dos atributos químicos, físicos e biológicos do ambiente, principalmente dos solos, visando aumentar a produtividade por área, aumentar a eficiência da fertilização, minimizando e reduzindo assim, os impactos ambientais associados à cafeicultura, rumo a uma produção sustentável (FERRAZ *et al.*, 2012).

Diante deste contexto, aeronaves remotamente pilotadas (RPA), aliadas aos sensores de alta precisão, têm sido ferramentas amplamente usadas na AP, pois fornecem a possibilidade de monitoramento das lavouras em tempo real, de forma mais rápida, em alta resolução espacial, e em momentos cruciais dos ciclos fenológicos das culturas (LATIF *et al.*, 2018; HUNT JR; DAUGHTRY, 2017).

As RPA e os sensores nelas acoplados têm sido estudados ao redor do mundo, aplicadas em diversas culturas agrícolas, e têm se mostrado uma ferramenta útil na detecção de pragas e doenças, do estresse hídrico, na estimativa de rendimento, e mais recentemente, têm sido testados no monitoramento do nitrogênio nos campos produtivos (XANTHOULA; MOSHOU; BOCHTIS, 2019; ESCALANTE *et al.*, 2019). Considerando a importância do café para a economia e para a cultura brasileira, o uso dessas tecnologias na cafeicultura está se expandindo (FERRAZ *et al.*, 2012).

O uso de técnicas do sensoriamento remoto e aerofotogrametria está crescendo dentro da agricultura brasileira, e isso pode colaborar para que o Brasil continue a cumprir seus compromissos frente aos acordos internacionais, e se fortaleça na busca por sustentabilidade e por valorização de seus produtos agrícolas no mercado mundial.

1.3 IMAGENS AÉREAS E FUNDAMENTOS DE SORIAMENTO REMOTO DA VEGETAÇÃO

1.3.1 Aerofotogrametria e a evolução dos levantamentos aéreos

A aerofotogrametria é um ramo do conhecimento, derivado da fotogrametria, que envolve um conjunto de técnicas usadas para a obtenção de informações a partir imagens aéreas. Aliada à fotointerpretação, que é a técnica de identificação de feições em fotografias aéreas através da observação das propriedades dos alvos, como cor, textura, forma, etc., é possível realizar não apenas medições, como também a caracterização qualitativa do ambiente fotografado (JENSEN, 2011).

Os sensores imageadores embarcados nas aeronaves são capazes de fornecer aerofotos verticais ($\leq 3^\circ$ de inclinação do eixo óptico da câmera em relação ao terreno), extremamente úteis para a obtenção de informações quantitativas e qualitativas do terreno, e aerofotos oblíquas (com inclinação de até 45°), ideais para a extração de informações qualitativas, identificação de feições e para a geração de modelos tridimensionais (JENSEN, 2011).

Entre os principais produtos da aerofotogrametria se destacam os mapas planimétricos e topográficos, modelos digitais de superfície (MDS) e de elevação (MDE), e as ortofotos, que são fotografias aéreas geometricamente corrigidas, e de alta precisão. Com a aplicação das técnicas de fotogrametria nesses produtos é possível determinar a escala da foto; a altura (z), o comprimento, o perímetro, a área, e a localização planimétrica (x, y) de objetos presentes no terreno (JENSEN, 2011).

Diante disso, as fotografias aéreas são amplamente usadas na geografia, nas diversas áreas da engenharia (geológica, cartográfica, de agrimensura, ambiental, florestal, civil), e têm ganhado cada vez mais espaço em diversos campos da ciência, principalmente devido à rápida evolução das tecnologias envolvidas, tanto na captura de imagens, quanto no transporte dos sensores (JENSEN, 2011; SILVA 2015).

O registro de imagens aéreas surgiu ainda no século XIX, mas se desenvolveu rapidamente no século XX, principalmente devido às necessidades militares durante as grandes guerras. Inicialmente, eram usados balões, pombos correios e planadores, equipados com câmeras de disparos programados. Com o surgimento dos aviões, a aerofotogrametria tornou possível a realização de mapeamento de feições fisiográficas (relevo, corpos hídricos, solos, etc.) em áreas cada vez maiores, pois juntamente com as aeronaves, desenvolviam-se também, sensores cada vez mais modernos (JENSEN, 2011; SILVA, 2015).

Atualmente, aeronaves tripuladas cada vez menores, mais acessíveis e versáteis são usadas ao mesmo tempo em que os veículos aéreos não-tripulados, popularmente conhecidos como “drones”, também se inserem definitivamente na aerofotogrametria, propiciando maiores resoluções temporal (frequência de imageamento por unidade de tempo) e espacial (porção do terreno representada por *pixel*) (MAES; STEPPE, 2019).

As principais diferenças entre o uso de aeronaves tripuladas e não tripuladas envolvem: i) os custos das aeronaves, uma vez que os drones possuem preços relativamente acessíveis e estão em processo de popularização; ii) a escala de trabalho, pois aeronaves tradicionais voam em grandes alturas, portanto podem recobrir áreas muito maiores; iii) a resolução temporal, tendo em vista que aeronaves não tripuladas são de fácil transporte e manuseio, portanto, podem realizar aerolevantamentos com maior frequência (MAES; STEPPE, 2019; MANFREDA *et al.*, 2018).

Além disso, as aeronaves não tripuladas, atualmente, chegam ao mercado com alto desenvolvimento tecnológico e possuem um alto grau automação, facilitando o trabalho dos usuários, pois são programadas para superarem os problemas tradicionais dos aerolevantamentos (JENSEN, 2011; MANFREDA *et al.*, 2018).

Além da fotogrametria e da fotointerpretação, a ciência de obtenção de dados sem o contato direto com o objeto, chamada sensoriamento remoto, constitui um dos campos onde as fotografias aéreas ganham enorme importância pois, com suas técnicas, tornou-se possível conhecer as características biofísicas de ambientes naturais e antropizados. Com o uso de aeronaves e satélites, a investigação acerca da interação da radiação eletromagnética e os objetos terrestres, por meio de sensores imageadores e não-imageadores, se tornou uma ferramenta fundamental dentro da revolução tecnológica do século XX (JENSEN, 2011).


1.3.2 Fundamentos básicos de sensoriamento remoto

O termo sensoriamento remoto se originou na década de 1960, nos Estados Unidos (EUA), durante a Guerra Fria, em que a chamada “corrida espacial” fez da fotointerpretação uma ferramenta de extrema importância, uma vez que, tanto Rússia quanto EUA passaram a lançar, acima da troposfera, satélites equipados com sensores com capacidade de coletar imagens e, conseqüentemente, informações acerca dos recursos naturais de todo o planeta (JENSEN, 2011).

A base do sensoriamento remoto está na interação da radiação eletromagnética (REM) com os alvos terrestres, interação essa, que é captada por sensores altamente tecnológicos, e usada para interpretação com finalidades diversas. A energia emitida pelo sol através de ondas eletromagnéticas é, em parte, absorvida pelos objetos, enquanto o restante é refletido de volta para o espaço, e é justamente a energia refletida pelos diversos elementos presentes no planeta que é captada pelos sensores (JENSEN, 2011).

A radiação eletromagnética (REM) se propaga através de ondas, que resultam da oscilação dos campos elétrico (E) e magnético (M) da luz (Figura 1). Essa oscilação ocorre quando uma partícula eletricamente carregada é acelerada, gerando a perturbação (onda) que se propaga ortogonalmente no vácuo, em diferentes comprimentos (λ), de acordo com a duração da aceleração, e em diferentes frequências (ν), dependendo do número de acelerações por segundo, em um padrão que se repete (JENSEN, 2011).

Figura 1 - Propagação da radiação eletromagnética na geração de ondas pela oscilação do campo elétrico (E) e magnético (M).




Fonte: MENESES *et al.*, 2012, p. 5.

Apesar de contínua, a REM foi dividida em intervalos de comprimentos de onda (chamados de “bandas”), de acordo com sua geração, detecção e seus usos, gerando então uma nomenclatura para determinados padrões de intervalos. Uma banda, canal, ou região do espectro eletromagnético é um intervalo que contém um comprimento inicial e final, que formam uma luz específica, por exemplo, a luz azul ($\sim 0,4 - 0,5 \mu\text{m}$) (JENSEN, 2011). Por meio dessa divisão em intervalos espectrais, é possível conhecer as características de cada comprimento de onda, bem como as suas interações com a atmosfera e os diferentes objetos terrestres (MENESES *et al.*, 2012).

Cada ramo da ciência se utiliza do conhecimento determinados intervalos de comprimentos de onda e suas interações com os objetos de interesse para a realização de pesquisas. Entre as regiões mais importantes para o sensoriamento remoto do ambiente estão: i) o visível, composto pelas bandas referentes às cores primárias vermelho (*red*), verde (*green*) e azul (*blue*), que compõem, aproximadamente, o intervalo entre 0,4 e 0,6 μm ; ii) o infravermelho: próximo (0,7 - 1,3 μm), médio (até 5 μm) e termal (até 1 mm); e iii) as micro-ondas (entre 1 cm e 1 m), usadas em radares. A Figura 2 ilustra a divisão didática do espectro eletromagnético.

Figura 2 – Divisão didática do espectro eletromagnético em bandas, com destaque para a região do visível.



Fonte: JENSEN, 2011, p. 49.

Os comprimentos de onda (λ) mais utilizados no sensoriamento remoto são comumente medidos em micrômetros (μm) ou nanômetros (nm). A frequência de uma onda (ν) é dada pelo seu número de oscilações por um determinado período de tempo, e é sempre inversamente proporcional ao seu comprimento, de modo que quanto maior λ , menor ν . Da mesma forma funciona a quantidade de energia, que também é inversamente proporcional ao λ (JENSEN, 2011).

A REM em seus vários comprimentos de onda, antes de ser capturada por um sensor, interage com as partículas presentes na atmosfera terrestre, em seguida, a porção que atinge a superfície interage com os objetos, depois interagindo novamente com a atmosfera, até finalmente ser registrada e se tornar fonte de informações valiosas (JENSEN, 2011).

Ao atingir a atmosfera terrestre, a REM sofre mudanças nos comprimentos de onda, na intensidade e distribuição, pelo contato com substâncias de diferentes densidades, alterando suas propriedades e causando refração (desvio) e espalhamento da luz. Quanto maior o índice de refração (n) causado, mais desvios sofre a luz, e então mais as imagens obtidas em níveis orbitais, como as de satélites, estão sujeitas a erros (JENSEN, 2011). Esse é um problema é superado pelos aerolevantamentos com aeronaves não tripuladas, uma vez que estes realizam voos em baixas alturas, geralmente inferiores a 120 m (MANFREDA *et al.*, 2018).

Além de ser refratada e espalhada pela atmosfera, a radiação pode ser absorvida pelos objetos e se tornar energia, ou ser refletida por eles. O monitoramento da proporção do *fluxo radiante de energia* (Φ) que entra, sai ou é transmitido por um determinado objeto (Quadro 1) é crucial para o SR, pois é possível selecionar os comprimentos de onda de interesse através de sensores com filtros específicos, estudar as relações destes fluxos com os diferentes elementos da natureza e, portanto, realizar inferências acerca destes elementos e suas propriedades em determinada imagem (JENSEN, 2011).


Quadro 1 - Grandezas radiométricas e suas equações.

Grandeza Radiométrica	Equação
Fluxo radiante incidente (Φ)	$\Phi = \Phi_{refletido} + \Phi_{absorvido} + \Phi_{transmitido}$
Reflectância (ρ)	$\Phi_{refletido} / \Phi$
Transmitância	$\Phi_{transmitido} / \Phi$
Absortância	$\Phi_{absorvido} / \Phi$

Fonte: Adaptado de JENSEN, 2011.

A reflectância (ρ), em especial, possui grande importância para pesquisas em SR, uma vez ela é captada pelos sensores usados em satélites e aeronaves. Como cada substância possui suas próprias características de interação com a REM (FIGURA 3), por meio dela é possível identificar objetos e conhecer suas variações, como é o caso da vegetação, que será abordada no próximo tópico.

Figura 3 - Reflectância de diferentes materiais ao longo do espectro eletromagnético.



Fonte: JENSEN, 2011, p. 57.

Antes mesmo da década de 1960, cientistas já haviam desenvolvido dispositivos capazes de extrair informações além do espectro do visível e do infravermelho próximo, como também do infravermelho termal e das micro-ondas (JENSEN, 2011).


No Brasil, na década de 1970, por exemplo, o governo brasileiro executou o projeto RadamBrasil, inicialmente chamado de Radam (Radares da Amazônia), uma das mais importantes iniciativas de mapeamento dos recursos naturais brasileiros, que foi realizado com o uso de radares aerotransportados que operam no espectro das micro-ondas ($\lambda \sim 3$ cm), e que possibilitou a coleta informações de norte a sul do país (PONZONI; SHIMABUKURO; KUPPLICH, 2012).

1.3.3 Interação da radiação eletromagnética com a vegetação

A interação da radiação eletromagnética com os vegetais pode ser explorada, principalmente, por meio da fotossíntese, complexo processo bioquímico de transformação de energia luminosa em energia química, base da vida no planeta Terra. O termo “fotossíntese” significa literalmente “síntese utilizando a luz”, uma vez que a planta utiliza, para isso, a energia radiante das bandas do azul e do vermelho, do espectro visível (TAIZ *et al.*, 2017).

A folha é o principal órgão onde ocorre o processo fotossintético, mais especificamente nos cloroplastos, presentes na região do mesófilo paliçádico (FIGURA 4). Dentro dos cloroplastos há um sistema de membranas internas denominadas “tilacóides”, que são o lócus da fotossíntese. Nessa região estão as moléculas dos pigmentos fotossintetizantes que são excitados pela energia luminosa. Uma vez excitados, os pigmentos podem, entre outras coisas, fornecer elétrons para a realização das complexas reações químicas da fase luminosa da fotossíntese (TAIZ *et al.*, 2017).

Figura 4 - Corte transversal ilustrando as estruturas anatômicas básicas de uma folha.



Fonte: PONZONI; SHIMABUKURO; KUPLICH, 2012.

Os pigmentos fotossintetizantes, clorofilas, xantofilas e carotenoides, funcionam como um “complexo antena” que captam a energia da luz e a transferem para os “centros de reações”, a partir de onde ocorrerá a fotossíntese. Os canais utilizados pelos pigmentos para obtenção de energia são aqueles referentes às luzes azul (*blue*) e vermelha (*red*), que formam seu espectro de absorção, enquanto o espectro de reflectância se encontra, para a maioria das espécies, na região do verde (TAIZ *et al.*, 2017). Ressalta-se que a vegetação sadia chega a absorver cerca de 80 a 90% da radiação incidente total do espectro visível (JENSEN, 2011).

Assim como em todos os objetos, a forma como a REM irá interagir com a folha e com o dossel de uma planta também depende das suas características físico-químicas. Um feixe de radiação pode ser refletido pela cutícula da folha, pode adentrar e atingir o mesófilo e, dependendo da forma como se organizam as estruturas celulares nesta região, pode alcançar os


pigmentos fotossintetizantes e ser absorvido, assim como pode atravessá-la por completo, sendo então transmitido (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Isso ocorre devido à composição e estrutura externa e interna das folhas, pois elas contêm água, moléculas gasosas, solutos e organelas, ou seja, os padrões de trajetória, refração e de absorção da luz não são homogêneos, variando conforme essas características e também conforme a saúde das plantas (PONZONI; SHIMABUKURO; KUPLICH, 2012).

A interação entre a vegetação e a REM pode ser também avaliada pela reflectância (ρ) em relação às regiões espectrais. Na região visível, como foi visto, a absorção da luz se dá pela ação dos pigmentos fotossintetizantes, que absorvem luz azul e vermelha, contudo, apenas as clorofilas absorvem nesta última, de modo que a absorção na faixa vermelha possui relação linear positiva com o conteúdo de clorofila (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Na região do infravermelho próximo (NIR), entre 0,72 μm e 1,2 μm , aproximadamente, o que determina essa interação é a estrutura e a organização do mesofilo paliçádico, sendo que nessa faixa, a vegetação chega a refletir cerca de 70% da radiação, de modo que, quanto mais lacunosa a estrutura, maior o espalhamento e a reflectância, mas fatores externos podem alterar a relação entre a quantidade de água e ar dentro das folhas, alterando esse comportamento (FIGURA 5).

Figura 5 – Curva de reflectância típica de uma folha verde sadia.

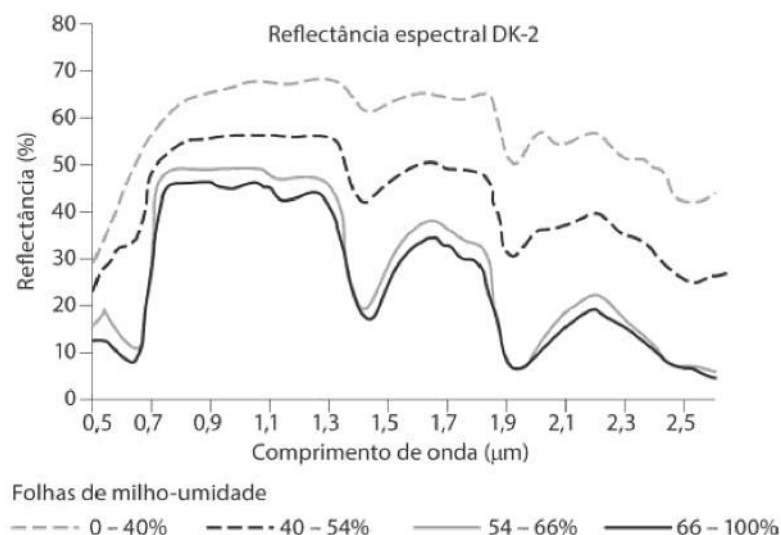


Fonte: PONZONI; SHIMABUKURO; KEPLICH, 2012.

Outra faixa importante para análise do comportamento espectral da vegetação é o infravermelho médio (MIR), cuja definição do intervalo exato varia entre autores e também entre sensores, mas definido por Ponzoni, Shimabukuro e Kuplich (2012) como sendo entre 1,1 - 3,2 μm , e por Jensen (2011), entre 1,3 - 5 μm . Nessa região, como é possível perceber na

Figura 5, a presença de água gera a absorção pronunciada em determinadas faixas desse espectro. Dessa forma, a variação de umidade interfere consideravelmente na reflectância no MIR, conforme é exemplificado no caso de folhas de milho com a Figura 6.

Figura 6 – Curva de reflectância de folhas de milho com diferentes teores de umidade.



Fonte: PONZONI; SHIMABUKURO; KEPLICH, 2012.

Sabe-se que fatores ambientais como o estresse hídrico, a falta de nutrientes, além de patógenos que possam vir a alterar a estrutura e composição das folhas, irão gerar também alterações no padrão de absorção de energia e, conseqüentemente, de reflectância das plantas, e isso poderá ser captado por sensores sensíveis à essas faixas do espectro eletromagnético. A escassez de N, por exemplo, é um dos fatores que afeta diretamente a síntese de pigmentos fotossintéticos e, quanto menor a quantidade de clorofilas, maior a reflectância esperada na região vermelha do visível, uma vez que haverá menor absorção para utilização dessa energia (PONZONI; SHIMABUKURO; KUPPLICH, 2012).

Devido ao profundo estudo do comportamento da vegetação em diferentes regiões do espectro eletromagnético desde a década de 1960, os cientistas têm se esforçado na criação de índices de vegetação (IV) para monitorar características biofísicas das plantas, tais como a fração de cobertura vegetal, teor de clorofila, biomassa, taxa de fotossíntese, entre outros. (PONZONI; SHIMABUKURO; KUPPLICH, 2012; JENSEN, 2011), e a utilidade dos IV que será explorada no próximo tópico.

1.3.4 Índices de Vegetação e aplicações em estudos agroambientais

Os IV são obtidos por meio da álgebra entre as bandas visível e do infravermelho, principalmente, e são baseados nos comportamentos antagônicos da reflectância dessas bandas quando incidem na vegetação (FRANCISCO *et al.*, 2020). De acordo com Jensen (2011), um IV deve ser capaz de ser linearmente sensível aos parâmetros biofísicos das plantas, abrangendo diferentes possíveis estados da vegetação, e deve também ser capaz de normalizar interferências atmosféricas, diferentes ângulos solares e possibilitar o confronto de imagens multitemporais.

Os satélites artificiais lançados com finalidades de observar a superfície do planeta são equipados com modernos sensores multiespectrais (mais de 3 bandas com a presença do NIR) e hiperespectrais (múltiplas bandas contínuas e estreitas), ou seja, são capazes de captar imagens ao longo de uma ampla faixa do espectro eletromagnético, em múltiplas bandas, permitindo que dezenas de IV sejam produzidos a partir de suas imagens (JENSEN, 2011). No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) disponibiliza gratuitamente imagens multitemporais e multiespectrais de alguns dos principais satélites, como os diversos Landsat, o sino-brasileiro CBERS, entre outros (INPE, 2020).


A resolução espectral é, sem dúvida, uma das principais vantagens das imagens de satélite em relação à outras plataformas. O Landsat-8, que possui o sensor OLI (*Operational Terra Imager*), por exemplo, oferece imagens georreferenciadas em 11 diferentes bandas incluindo as do visível (RGB), além de NIR e MIR, infravermelho termal, entre outras, permitindo uma ampla gama de opções para estudos e aplicações de vários IV (INPE, 2020).

Por outro lado, as resoluções espacial e temporal, e a alta susceptibilidade às interferências atmosféricas são os maiores fatores limitantes desse tipo de plataforma (MATESE *et al.*, 2015). Os satélites artificiais que orbitam a Terra possuem períodos determinados de revisita ao mesmo ponto do planeta, ligados ao período de tempo que levam para circunda-lo, ou seja, não existem imagens disponíveis para todos os dias nos mesmos satélites. Além disso, apesar de alguns sensores orbitais disponibilizarem resoluções espaciais menores que 10 m *pixel*⁻¹, ainda não oferecem a precisão necessária no monitoramento de áreas menores (MANFREDA *et al.*, 2018).

O uso de sensores acoplados em aeronaves remotamente pilotadas (RPA) tem sido útil na superação dessas questões, uma vez que elas realizam missões em baixas altitudes (aproximadamente 120 m acima do solo), resultando em imagens de altíssima resolução

espacial (FIGURA 7), na casa dos centímetros, além de serem fáceis de transportar e manusear, permitindo também uma alta resolução temporal, caso as condições do tempo sejam favoráveis (MANFREDA *et al.*, 2018).

Figura 7 – Diferença de resolução espacial entre uma imagem de RPA e uma imagem de satélite.



Fonte: Autora.

Legenda: (A) Imagem RGB obtida com uma RPA a 100m de altura, com resolução máxima de $1,36 \text{ cm pixel}^{-1}$.

(B) Imagem RGB da mesma área, obtida com o satélite Landsat 8, sensor Thematic Mapper TM, com resolução máxima de 15 m pixel^{-1} .

A Figura 8 mostra um exemplo de RPA, do mesmo modelo utilizado neste estudo, com um sensor multiespectral acoplado.

Figura 8 - RPA DJI Phantom 4 com sensor multiespectral extra embarcado.



Fonte: <https://www.fotografiaecompanhia.com/>

Um IV de ampla aplicação em estudos de vegetação ao redor do planeta é o Índice de Vegetação por Diferença Normalizada (NDVI), desenvolvido em 1974, e que é baseado na relação entre a banda vermelha (R) e o infravermelho próximo (NIR). Como foi visto, a se relaciona com o espectro de absorção de luz pelas plantas, enquanto a NIR, de reflectância, já que não é absorvida pelos pigmentos, mas espalhada internamente (JENSEN, 2011).

A principal vantagem do NDVI é a capacidade de monitorar alterações de caráter sazonal, além de possuir boa correlação com o Índice de Área Foliar (IAF). Contudo, essa correlação costuma atingir um platô, fazendo com que a adição de biomassa não aumente o seu valor, tornando-o pouco efetivo para monitoramento de florestas, por exemplo (JENSEN, 2011).

Usando apenas bandas do visível, alguns índices de vegetação podem ser usados para diferentes finalidades. O Índice Resistente à Atmosfera no Visível (VARI) é um IV desenvolvido para resistir às interferências atmosféricas e estimar, com alta precisão, a fração de vegetação em porcentagem (JENSEN *et al.*, 2011). Outro IV que também é útil para monitorar a fração de cobertura vegetal é o Índice da Diferença Normalizada de Verde e Vermelho (NGRDI), e ambas as equações estão presentes na Tabela 3, na seção de Material e Métodos.

O *Excess Green* (ExG), ou “excesso de verde”, também usado neste estudo, foi um IV desenvolvido por Woebbecke *et al.* (1995) para o monitoramento de ervas daninhas e controle de pulverização, uma vez que este índice produz um contraste entre as tonalidades, favorecendo a diferenciação de áreas descobertas e com diferentes coberturas.

Nesta pesquisa, este IV foi também testado no monitoramento do nitrogênio, uma vez que o contraste entre as cores também é esperado para plantas com deficiência nutritiva (por exemplo, a ocorrência de amarelamento das folhas, que altera o padrão de resposta espectral).

São vários os fatores a serem considerados nas análises no sensoriamento, tanto em ambientes naturais, quanto para culturas agrícolas, uma vez que cada planta possui um ciclo fenológico específico e, uma mesma espécie plantada em datas diferentes, estarão em estágios diferentes, além de que fatores ambientais como condições climáticas, variações dos solos, disponibilidade de água e nutrientes, e até mesmo a presença de sombra afetam diretamente na fisiologia e na anatomia das plantas, gerando então, mudanças no comportamento da resposta espectral (JENSEN, 2011).

Apesar disso, os IV e as outras técnicas disponíveis para sensoriamento remoto com RPA e outras plataformas têm sido amplamente utilizadas em diversos estudos ambientais e agrícolas, com diversas espécies. Como exemplos, podem ser citados o monitoramento da sintomatologia de doenças na produção de uvas realizado por Di Gennaro *et al.* (2016); a estimativa do índice de cobertura vegetal com IV em RGB executado por Beniaich *et al.* (2019); o monitoramento do rendimento da colza através da estimativa do IAF, feito por Peng *et al.* (2019); estimativa de parâmetros biofísicos de cafeeiros, desenvolvida por Santos *et al.* (2020); a estimativa de parâmetros como a concentração de nitrogênio, biomassa e a altura das plantas em cultivo de arroz, executado por Stavrakoudis *et al.* (2019), entre muitos outros estudos que colaboram com o desenvolvimento de técnicas que ajudam a tornar a produção de alimentos mais eficiente e menos ambientalmente impactante.

Este estudo tem como interesse específico o uso de RPA e índices de vegetação no monitoramento do nitrogênio em diferentes culturas e, por isso, a próxima seção, além de abordar um pouco mais sobre essa nova plataforma do sensoriamento remoto, trata de como este tema tem sido explorado em estudos ao redor do planeta, e que perspectivas e resultados eles têm trazido.

1.4 AERONAVES REMOTAMENTE PILOTADAS (RPA): DEFINIÇÕES, ASPECTOS LEGAIS E SUAS APLICAÇÕES NO MONITORAMENTO AGRÍCOLA

Aeronave Remotamente Pilotada (RPA) é uma subcategoria de aeronaves não tripuladas cuja pilotagem se dá por uma estação remota, e cuja finalidade não é recreativa, além de possuir a capacidade de interação com o Controle de Tráfego Aéreo em tempo real (BRASIL, 2019).

Apesar de ser considerado obsoleto pelo Departamento de Controle do Espaço Aéreo (DECEA), o termo Veículos Aéreos Não Tripulados (VANT) é relativamente usual na literatura, e é equivalente ao termo RPA. Tais aeronaves são capazes de realizar operações livres ou automatizadas, sendo estas últimas, realizadas sem a efetiva ação do piloto durante o voo, ainda que, de acordo com a legislação, o mesmo deva manter condições de interferir a qualquer momento (BRASIL, 2019).

A Agência Nacional de Aviação Civil (ANAC) divide as RPA em três categorias, de acordo com o peso máximo de decolagem (PMD), sendo: i) classe 1 (PMD > 150 kg); classe 2 (PMD > 25 kg ≤ 150 kg); classe 3 (PMD < 25 kg) (ANAC, 2015). As aeronaves da classe 3 são as mais utilizadas em levantamentos aéreos devido à praticidade de operação e transporte, além

de não ser necessária licença ou habilitação para pilotagem, que é emitida pela Agência Nacional de Aviação Civil.

As operações automatizadas são muito importantes, uma vez que o piloto pode delimitar um *grid* recobrando a área de interesse, as linhas de execução e a altura de voo, a velocidade da aeronave e a relação de sobreposição entre as imagens. Tal processo gera um conjunto de imagens com informações precisas de localização e altitude, permitindo a produção de ortomosaicos georreferenciados, modelos digitais de superfície e elevação, além de mapas espectrais, entre outros produtos que, aliados aos Sistemas de Informação Geográficas (SIG), possuem alto potencial para estudos em diferentes ambientes (MANFREDA *et al.*, 2018).

Durante o percurso de uma operação automatizada, a câmera, acoplada à aeronave, realiza disparos para a captura das imagens. O tempo entre os disparos varia de acordo com as sobreposições lateral (*sidelap*) e frontal (*overlap*) entre as imagens. Quanto maior a sobreposição entre as fotos, maior o número de imagens que precisam ser capturadas, porém maior a precisão de detalhes. Os pontos de captura são armazenados e as coordenadas ficam conservadas nos metadados das imagens, possibilitando a produção do ortomosaico georreferenciado.

As RPA são ideais para fotogrametria em áreas menores (até 100 ha) pois fornecem, no geral, imagens de alta resolução, e representam um bom custo-benefício, além de possuírem boa resolução temporal, desde que observadas as condições do tempo (MANFREDA *et al.*, 2018; SEIFERT *et al.*, 2019). Contudo, possuem limitações quanto ao tempo de autonomia, especialmente as multirotoras (como é o caso neste estudo), cuja bateria sustenta uma missão de cerca de 20-25 minutos.

Para a realização dos aerolevantamentos, é necessário um Sistema de Aeronave Remotamente Pilotada (SRPA), que é composto por uma aeronave que contenha um GPS e uma unidade de navegação inercial (IMU) e um sensor para imageamento. Além da aeronave, um SRPA também deve conter uma estação de controle em solo (*Ground Control Station – GCS*), e um *joystick*. Com a GCS e o *joystick*, o piloto consegue planejar e controlar a missão por um *Tablet* ou *smartphone*, sem a necessidade de acesso à internet no momento do voo (FIGURA 9) (EMBRAPA, 2014).

Figura 9 – RPA modelo Phantom 4 com estação de controle em solo (GCS) e *joystick*.



Fonte: <http://dronestore.com.br/>

Tendo em vista o potencial das RPA e dos sensores nelas acoplados, aliados às técnicas de sensoriamento remoto e fotogrametria, tem crescido nos últimos anos o número estudos em ambientes naturais e agrícolas, com diferentes finalidades (MAES; STEPPE, 2019).

O tópico a seguir trata de como as RPA estão sendo usadas na pesquisa e no desenvolvimento de métodos para colaborar com as práticas agrícolas, em especial, em que estado encontram-se as pesquisas envolvendo o monitoramento e estimativa do nitrogênio em diferentes culturas, principal objetivo deste estudo.

1.4.1 Uso de RPA em estudos agrícolas e no monitoramento do nitrogênio de lavouras

Tendo em vista o aprimoramento da eficiência da gestão agrícola, a melhoria da alocação de recursos em insumos, além do desafio que a produção de alimentos tem de reduzir os impactos ambientais, está em plena expansão o uso de sensores aerotransportados para auxílio nas práticas agrícolas, e as imagens aéreas derivadas desse tipo de aerolevanteamento estão sendo analisadas com técnicas estatísticas, algoritmos específicos e equipamentos cada vez mais modernos (XANTHOULA; MOSHOU; BOCHTIS, 2019; LATIF *et al.*, 2018).

Aliado ao desenvolvimento de diversas técnicas de análise de dados para detecção de doenças, pragas, estresse hídrico e previsão de variáveis biofísicas das culturas, como teor de clorofila e nitrogênio, altura e biomassa fresca ou seca, o SR baseado em imagens de alta resolução obtidas com RPA, tem o potencial de preencher as lacunas entre o SR tradicional,

com satélites e aeronaves tripuladas, e as observações de campo (XANTHOULA; MOSHOU; BOCHTIS, 2019; MANFREDA *et al.*, 2018).

A determinação de doses ótimas de fertilizantes, por exemplo, não é uma tarefa simples, pois envolve a coleta e análise dados que, muitas vezes, podem limitar agricultores, devido tanto a custos quanto ao tempo (ESCALANTE *et al.*, 2019). Dessa forma, o desenvolvimento de tecnologias que sejam capazes fornecer informações rápidas e úteis no planejamento e na tomada de decisões neste aspecto é fundamental para que a agricultura ganhe em efetividade e seja menos impactante (ESCALANTE *et al.*, 2019; XANTHOULA; MOSHOU; BOCHTIS, 2019; MANFREDA *et al.*, 2018).

Neste contexto, Escalante *et al.* (2019) buscaram estimar o conteúdo de nitrogênio para seis variedades da cultura da cevada usando imagens em RGB capturadas em uma missão durante a maturidade das plantas. Os autores fizeram uso de redes neurais convolucionais profundas (DCNN), compostas de algoritmos de classificação úteis para geração de modelos preditivos, tais como *AdaBoost* e *Artificial Neural Network* (ANN), no reconhecimento de diferentes tratamentos com nitrogênio.

Esses modelos são capazes de obter elementos descritores das imagens com alto potencial discriminativo, captando padrões espaciais, textura e aparência. Neste estudo, os autores obtiveram bons resultados na discriminação das variedades sem aplicação de nitrogênio, mas os modelos não foram suficientes para explicar as variações entre as demais doses de aplicação. Na predição da produtividade, todavia, o desempenho dos modelos foi superior a 80%, com baixos erro médio quadrático (RMSE), indicando um campo promissor para a metodologia (ESCALANTE *et al.*, 2019).

Usando técnicas de conversão de imagens RGB em valores de matiz, brilho e saturação (HSV), Caturegli *et al.* (2019) construíram o IV *Dark Green Colour Index* (DGCI) e atingiram correlações significativas ($R > 0,8$) deste índice com o teor de N de duas espécies de gramíneas da família *Poaceae*, a *Cynodon dactylon* e a *Festuca arundinacea*, adubadas com 11 diferentes níveis de N, na Itália. Além disso, os autores também observaram correlações positivas entre o DGCI e o NDVI para as duas espécies ($R > 0,85$), o que pode indicar uma alternativa de baixo custo quando a banda NIR não estiver disponível, embora com maior exigência de processamento.

Garza *et al.* (2020), construíram o *Triangular Vegetation Index* (TGI), um IV que mede a intensidade do verde nas plantas, usando apenas imagens RGB, com o objetivo de monitorar a saúde de árvores de citrus, no estado do Texas, nos EUA. Entre os parâmetros observados,

estava o teor de N foliar, contudo, não houve correlação significativa entre este e o TGI. Os autores apontam que os resultados de estudos com imagens RGB são muito variados, portanto requerem mais estudos para verificar que fatores podem ser mais significativos.

Osco *et al.* (2019) usaram uma RPA com um sensor multiespectral embarcado, contendo os canais *Red*, *Green*, *Red-Edge* e NIR, com o objetivo de estimar o conteúdo de nitrogênio presente no dossel (*Canopy Nitrogen Content*) de mais de 33 mil árvores de citrus, no interior do estado de São Paulo, no Brasil. Com uma área de estudo superior a 71 ha, os autores criaram 27 parcelas, das quais foram amostradas mais de 4000 folhas para determinação do teor de nitrogênio, o que foi feito por meio do método Kjeldahl.

Usando um SIG e técnicas de fotointerpretação, foram identificadas todas as árvores do estudo e foram também calculados os índices de área foliar. Os modelos preditivos foram criados usando o algoritmo de regressão por meio de um conjunto de árvores de decisão, *Random Forest* (RF), em que foram considerados 33 IV (entre eles: NDVI, GNDVI, NDRE, OSAVI, CCI, entre outros), produzidos a partir das diversas combinações entre as bandas do sensor, e o CNC (teor médio de nitrogênio foliar multiplicado pela área foliar) (OSCO *et al.*, 2019).

Realizando uma análise de regressão simples entre os IV e o CNC, os maiores coeficientes de determinação obtido foram com o *Triangular Vegetation Index* (Tri VI), 0,63, e com *Modified Soil Adjusted Vegetation Index* (MSAVI), 0,62. Todavia, usando o RF, os autores atingiram um $R^2=0,90$, com erros inferiores aos obtidos com as regressões individuais (OSCO *et al.*, 2019).

Um recurso importante do RF é o retorno da contribuição individual de cada IV para o modelo, o que possibilita a redução do número de IV a serem testados, economizando tempo de processamento e análise. Dos 33 índices, os 10 mais importantes contribuíram para explicar mais de 55% do modelo. Entre os mais importantes estavam: *Simple Ratio 750-550*, Tri VI, *Chlorophyll Index Red-Edge* e outros índices sensíveis à clorofila, especialmente os que requerem a banda *Red-Edge* (OSCO *et al.*, 2019).

Van der Meij *et al.* (2017) usaram modelos tridimensionais de superfície de colheita (*Crop Surface Model* - CSM), gerados a partir de imagens em RGB, e imagens hiperespectrais (94 bandas contínuas entre 450-915 nm), oriundos de imageamento com RPA, para estimar as seguintes características de plantas de aveia: altura, biomassa fresca, teor de clorofila foliar, e teor de nitrogênio. Das imagens hiperespectrais foram gerados 10 IV, testados em diferentes

combinações espectrais, entre eles, 11 arranjos distintos do NDVI, em diferentes comprimentos de onda.

Os autores realizaram apenas uma missão para imageamento e, para a análise de dados, empregaram o método da Regressão Parcial de Mínimos Quadrados (*Partial Least Square Regression* - PLS), que consiste em uma técnica usada para modelar relações entre dados espectrais e propriedades físico-químicas.

Confrontados com os dados de levantamento de campo, os resultados dos modelos foram promissores para a estimativa do conteúdo de clorofila foliar ($R^2 = 0,80$) e para a modelagem 3D da altura das plantas ($R^2 = 0,79$). Contudo, para a estimativa do teor de nitrogênio, os autores atingiram um $R^2 = 0,68$, e para a biomassa fresca, $R^2 = 0,56$ (VAN DER MEIJ *et al.*, 2017).

Levando em conta apenas as regressões entre os índices de vegetação de forma individual, os IV *Merris Terrestrial Chlorophyll Index* (MTCI) e o *Red-Edge Position* (REP) obtiveram os maiores coeficientes de determinação em relação ao conteúdo de N (0,58 e 0,57, respectivamente). Tanto MTCI quanto REP são IV compostos pela banda *Red-Edge*, região de transição do vermelho para o infravermelho próximo, e ambos estão diretamente ligados com o teor de clorofila, que por sua vez, também está relacionada com o N na planta (VAN DER MEIJ *et al.*, 2017).

Vega *et al.* (2015) avaliaram, na Espanha, a capacidade monitoramento do nitrogênio com imagens multiespectrais multitemporais oriundas de voos com uma RPA, durante todo o ciclo de crescimento de uma variedade de girassol, com 8 doses diferentes de aplicação de fertilizantes, cada uma com quatro volumes diferentes de irrigação, simulando assim, o estresse hídrico.

Os autores usaram calcularam o *Normalized Difference Vegetation Index* (NDVI) da área e realizaram a reamostragem dos *pixels* para avaliar também os efeitos da resolução, testando as correlações para 1, 30 e 100 cm, e também os efeitos da classificação dos elementos das imagens (VEGA *et al.*, 2015).

Para o teor de N e para todas as resoluções, as correlações aumentaram conforme o ciclo de crescimento avançava, atingindo um platô na maturidade, e decresceram novamente próximo da colheita. Contudo, os índices com 1 cm de resolução obtiveram as melhores correlações, tanto para imagens que foram classificadas (entre 0,13, no início do ciclo, e 0,83, no fim), quanto para as não classificadas (0,15 no início, e 0,86 na maturidade), atestando assim a importância da alta resolução (VEGA *et al.*, 2015).

A classificação supervisionada pelo método *Maximum Likelihood Classification* (MLC), realizada por Vega *et al.* (2015), não aumentou as correlações entre os dados espectrais e as variáveis de estudo (teor de N, rendimento dos grãos e biomassa da parte aérea). Os autores relataram também que, no estudo, o NDVI não foi alterado pelo horário de captura da imagem (ao meio-dia ou durante a tarde).

Ballester *et al.* (2017) realizaram, na Austrália, um experimento de 30 parcelas com cultivo de algodão contendo replicações de 8 tratamentos diferentes de nitrogênio de fontes diferentes, orgânicas e inorgânicas: esterco de aves, fosfato de diamônio (DAP), amônia anidra (NH₃-N) e ureia. O objetivo dos autores era monitorar o nitrogênio com uma RPA equipada com um sensor multiespectral de 5 bandas: RGB, NIR e *Red-Edge*.

Os índices de vegetação gerados a partir da combinação das bandas foram: NDVI, *Normalized Difference Red Edge Index* (NDRE), *Simplified Canopy Chlorophyll Content Index* (SCCCI), *Visible Atmospherically Resistant Index* (VARI), *Optimized Soil Adjusted Vegetation Index* (OSAVI). Além da porcentagem de N na planta, os autores avaliaram também a captação de N, o rendimento dos fiapos e a biomassa seca (BALLESTER *et al.*, 2017).

Assim como reportado por Vega *et al.* (2015), Ballester *et al.* (2017) também obtiveram correlações que aumentaram no tempo, conforme a cultura atingia a maturidade. Para o teor de nitrogênio da planta, durante a maturidade, os coeficientes de determinação foram: NDVI (0,77), NDRE (0,84), SCCCI (0,80) e OSAVI (0,76), todos estatisticamente significativos. Apesar dos bons resultados com o uso das bandas NIR e *Red-Edge*, o VARI, que é um IV baseado em bandas do espectro RGB, obteve um $R^2 = 0,29$ na maturidade, e $R^2 = 0,40$ na primeira abertura do botão floral.

Os índices sensíveis ao teor de clorofila (NDRE, SCCCI e OSAVI) foram também bem correlacionados com o rendimento, principalmente entre a maturidade e a colheita. Para esta variável, o VARI, ao contrário do que ocorreu com o N, atingiu uma correlação positiva crescente ao longo do ciclo, atingindo $R^2=0,70$ na maturidade, o que mostra que o imageamento de baixo custo, em RGB, pode ser interessante para monitorar o rendimento quando sensores de maior resolução espectral não estão disponíveis (BALLESTER *et al.*, 2017).

Hunt Jr. *et al.* (2018) simularam a deficiência de nitrogênio na cultura de batata, nos Estados Unidos, aplicando quatro doses de fertilizante de ureia revestida de liberação lenta. Os autores utilizaram uma RPA com sensores que captam imagens em *red*, *green* e NIR, sendo possível, assim, usar o NDVI e o *Green Normalized Difference Vegetation Index* (GNDVI) para tentar monitorar os tratamentos. Todavia, os IV só foram capazes de diferenciar os tratamentos

mais baixos, em relação ao adequado, quando já não era mais possível promover alterações no manejo do nitrogênio.

Apesar das boas correlações durante a maturidade, a utilidade das RPA e dos sensores reside na possibilidade de monitoramento do N antes desse período, para que seja possível auxiliar no planejamento da fertilização (HUNT JR. *et al.*, 2018). Uma alternativa seria, segundo os autores, usar a análise da fração da cobertura foliar como estratégia, tendo em vista que quando a planta apresenta menor cobertura foliar em relação às demais, pode apresentar deficiência de N.

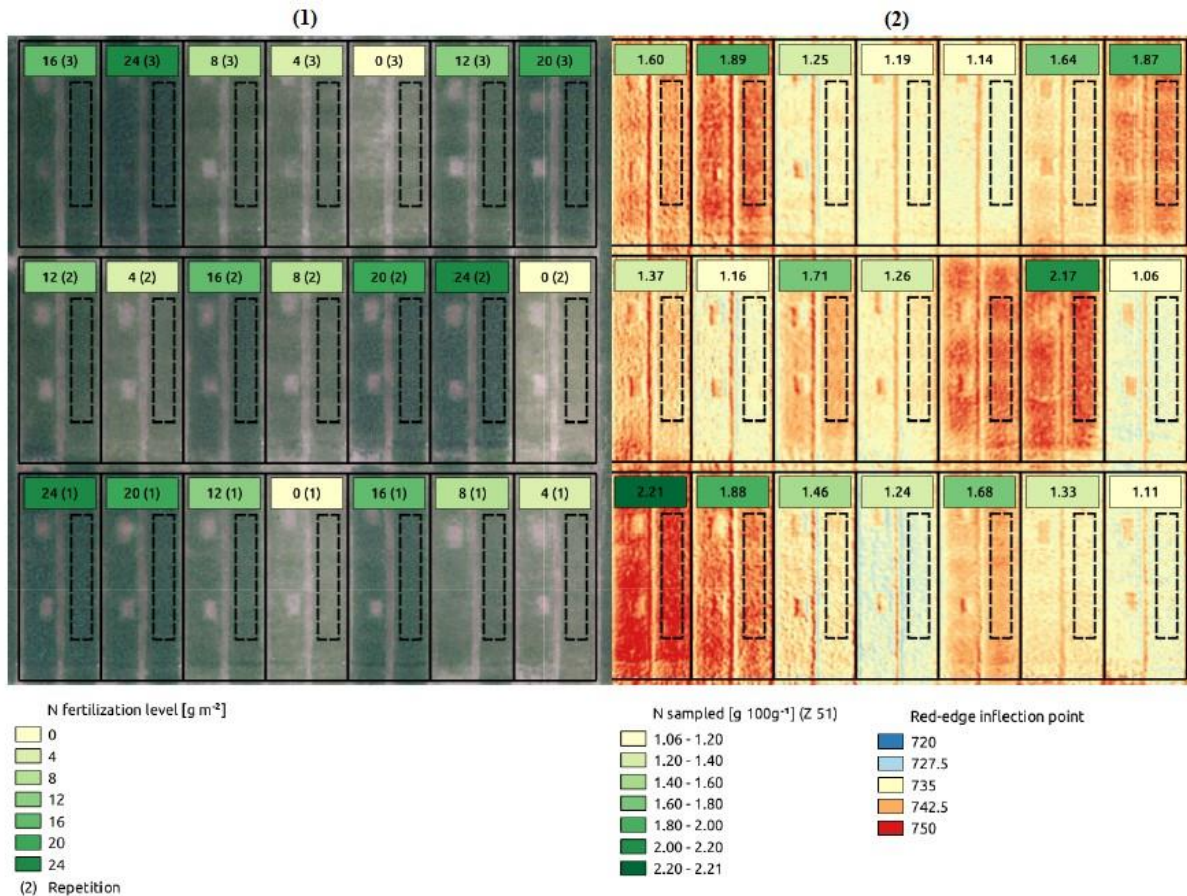
Para Hunt Jr. *et al.* (2018), a alta resolução das imagens pode ser mais útil para a detecção de daninhas, danos causados por insetos e doenças, enquanto o monitoramento do nitrogênio pode ser mais eficiente se realizado com sensores ativos em nível de solo, tais como *Green Seeker* ou *FieldSpec*.

Com o objetivo de monitorar o nitrogênio em lavouras de trigo, espécie que requer aplicações de N durante o crescimento das plantas, Geipel *et al.* (2016) desenvolveram uma câmera multiespectral programável de quatro bandas estreitas na região da *Red-Edge*, que foi acoplada em uma RPA multirrotora, e que foi então usada para monitorar, no sul da Alemanha, 21 parcelas contendo 7 níveis de fertilização nitrogenada para uma variedade de trigo de inverno, com imagens multitemporais.

Os autores usaram o NDVI e o *Red-Edge Inflection Point* (REIP) para monitorar as parcelas, em 4 fases do crescimento, e obtiveram resultados estatisticamente significativos e com baixos RMSE na estimativa do teor de N, e a eficácia do REIP pode ser visualizada na Figura 10 (GEIPEL *et al.*, 2016).

Em relação aos coeficientes de regressão entre REIP e os tratamentos, assim como outros autores observaram, após a maturidade, a correlação diminui próximo à colheita: $R^2 = 0,83$ (1ª missão, no início do perfilhamento); $R^2 = 0,89$ (2ª missão, início do alongamento); $R^2 = 0,81$ (3ª missão, na fase de emissão); $R^2 = 0,58$ (4ª missão, no enchimento). O NDVI, apesar de correlações inferiores (0,75; 0,73; 0,63; 0,53), seguiu o mesmo padrão do REIP, decrescendo em direção à colheita, o que ocorre devido ao decréscimo do conteúdo de clorofila no início da senescência (GEIPEL *et al.*, 2016).

Figura 10 – Monitoramento do nitrogênio foliar em lavoura de trigo com o índice de vegetação *Red-Edge Inflection Point* (REIP).



Fonte: Geipel *et al.*, 2016.

Nota: Área de estudo de Geipel *et al.* (2016) em RGB, e níveis de fertilização em três repetições (1); resultado da análise do nitrogênio e mosaico do *Red-Edge Inflection Point* (REIP) ainda na fase de alongamento do trigo (2). Zonas de tratamentos sem aplicação de fertilizante apresentam-se mais claras, tanto no RGB, quanto no REIP. Conforme aumentam os níveis de N, as cores ficam mais escuras, sendo fácil discernir entre os teores de nitrogênio, tanto aplicados, quanto resultantes.

Schirmann *et al.* (2016) também testaram o potencial de uma RPA multirrotora e um sensor RGB de baixo custo no monitoramento do N na cultura do trigo de inverno, usando não somente as informações espectrais, como também a proporção da cobertura vegetal (CVR) e a altura das plantas, ambas estimadas em campo e com as imagens.

Os autores utilizaram IV baseados no espectro RGB e as informações da CVR e da altura das plantas, e confrontaram com medições de campo referente à altura real das plantas, ao teor de nitrogênio (Nt), ao índice de área foliar (IAF) e à biomassa, usando a análise de correlação de Pearson. Em relação ao Nt, dentre as 3 missões realizadas, o IV *Red-Green Ratio* (RG) foi o que atingiu a melhor correlação significativa ($R = 0,68$), na segunda missão, na fase de florescimento (SCHIRMANN *et al.*, 2016).

O *Excess Green* (ExG), testado pelos autores, teve resultado similar à CVR, uma vez que não se correlacionou com o Nt em nenhuma das missões, alcançando, inclusive, correlação negativa ($R = -0,48$) na segunda missão. Como mencionado, Hunt Jr. *et al.* (2018) propuseram que analisar a fração da cobertura vegetal pode ser uma estratégia para monitorar o N, uma vez que a deficiência do elemento gera déficits no desenvolvimento. Todavia, no estudo de Schirrmann *et al.* (2016), com trigo, a cobertura vegetal não se relacionou com o N, indicando que essa estratégia ainda requer maiores estudos.

Resultados promissores trazidos pelos autores são as boas correlações da CVR com o IAF ($R = 0,96$, na terceira missão), e do ExG com a altura real da planta (PHT), que foi sempre superior a 0,7 nas três missões, atingindo 0,83 também na terceira fase (maturidade) (SCHIRRMANN *et al.*, 2016).

Fica evidente, então, que a capacidade de previsão do N com uso de índices de vegetação depende de fatores como o tipo de cultura, estágio de crescimento, localização, além das resoluções espectral, espacial e temporal dos sensores. Em especial, o monitoramento do N parece ser mais eficiente na fase vegetativa em diferentes culturas, e a presença da banda *Red-Edge* se mostra ser um diferencial para esta tarefa (XANTHOULA; MOSHOU; BOCHTIS, 2019).

São muitos estudos e uma grande diversidade de metodologias empregadas na tarefa de monitorar o nitrogênio em culturas agrícolas, e outros autores como Cen *et al.* (2019), Latif *et al.* (2018), Li *et al.* (2018), Mozgeris *et al.* (2018), entre outros, exploraram o tema e têm para colaborado com o desenvolvimento de métodos mais eficientes, e também de menor custo e maior facilidade de aplicação, explorando inclusive imagens RGB, embora IV produzidos com a banda *Red-Edge* tenham exibido resultados promissores.

Dessa forma, este estudo se propõe a colaborar com o desenvolvimento de técnicas e métodos, em especial de baixo custo, envolvendo aerolevantamentos em RGB, visando a popularização das ferramentas de monitoramento e de planejamento das ações agrícolas, além da redução dos impactos ambientais.

REFERÊNCIAS

- 4C ASSOCIATION. **Código de Conduta 4C**. 2015. Disponível em: https://www.globalcoffeeplatform.org/assets/files/4CDoc_001a_Code_of_Conduct_v.2.0_PT.pdf. Acesso em: 25 fev. 2020.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- Agência Nacional de Aviação Civil (Brasil). Regulamento Brasileiro da Aviação Civil Especial – **RBAC-E n. 94**. 2015. Disponível em: <https://www.anac.gov.br/participacao-social/consultas-publicas/audiencias/2015/aud13/anexoi.pdf>. Acesso em: 20 set. 2019.
- ARROYO, J.; GUIJARRO, M.; PAJARES, G. An instance-based learning approach for thresholding in crop images under different outdoor conditions. **Computers and Electronics in Agriculture**, v. 127, p. 669- 679, 2016.
- BALLESTER, C. *et al.* Assessment of In-Season Cotton Nitrogen Status and Lint Yield Prediction from Unmanned Aerial System Imagery. **Remote Sensing**, v. 9, n. 1149, p. 1-18, 2017.
- BENIAICHI, A. *et al.* Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. **Semina: Ciências Agrárias**, v. 40, n. 1, p. 49-66, 2019.
- BRASIL. Congresso Nacional. Câmara dos Deputados. **Legislação informatizada: Decreto Legislativo nº 806, de 2010 - Acordo**. Brasília, 2010. Disponível em: <https://www2.camara.leg.br/legin/fed/decleg/2010/decretolegislativo-806-20-dezembro-2010-609784-acordo-131092-pl.html>. Acesso em 25 fev. 2020.
- BRASIL. Departamento de Controle do Espaço Aéreo. **ICA 100-40: Aeronaves não Tripuladas e o Acesso ao Espaço Aéreo Brasileiro**. Brasília, 2019. Disponível em: <https://publicacoes.BRASIL.gov.br/?i=publicacao&id=4944>. Acesso em 24 set. 2019.
- _____. Ministério da Economia. **Comex Vis: principais produtos exportados**. Brasília, 2020. Disponível em: <http://www.mdic.gov.br/comercio-exterior/estatisticas-de-comercio-exterior/comex-vis/frame-ppe?ppe=1080>. Acesso em 24 fev. 2020.
- BORDOLOI, N. *et al.* Impact of nitrogen fertilization and tillage practices on nitrous oxide emission from a summer rice ecosystem. **Archives of Agronomy and Soil Science**, v. 65, n. 11, 2019.
- CAMARGO, A. P; CAMARGO, M. B. P. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia**, v. 60, n. 1, p. 65-68, 2001.
- CATUREGLI, L. *et al.* Normalized Difference Vegetation Index versus Dark Green Colour Index to estimate nitrogen status on bermudagrass hybrid and tall fescue. **International Journal of Remote Sensing**, v. 41, p. 1-16, 2019.

CECHIM JÚNIOR, C; JOHANN, J. A; ANTUNES, J. F. G. Mapping of sugarcane crop area in the Paraná State using Landsat/TM/OLI and IRS/LISS-3 images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 6, p. 427 - 432, 2017.

CEN, H. *et al.* Dynamic monitoring of biomass of rice under different nitrogen treatments using a lightweight UAV with dual image-frame snapshot cameras. **Plant Methods**, v. 15, n. 32, 2019.

CHAGAS, W. F. T. *et al.* Nitrogen fertilizer technologies for coffee plants. **Coffee Science**, v. 14, n. 1, p. 55-66, 2019.

CHEN, Z. *et al.* In-Season Diagnosis of Winter Wheat Nitrogen Status in Smallholder Farmer Fields Across a Village Using Unmanned Aerial Vehicle-Based Remote Sensing. **Agronomy**, v. 9, n. 619, p. 1-23, 2019.

Companhia Nacional de Abastecimento (Brasil). **Acompanhamento da safra brasileira: café**. Brasília, 2019. Disponível em: <https://www.conab.gov.br/info-agro/safras/cafe>. Acesso em 24 fev. 2020.

DI GENNARO, S. F. *et al.* Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex. **Phytopathologia Mediterranea**, v. 55, n. 2, p. 262 - 275, 2016.

DOMINGHETTI, A. W. *et al.* Nitrogen loss by volatilization of nitrogen fertilizers applied to coffee orchard. **Ciência e Agrotecnologia**, v. 40, n. 2, 2016.

Empresa de Assistência Técnica e Extensão Rural do Estado de Minas Gerais. **Manual do café: implantação de cafezais**. 2016. Disponível em: http://www.sapc.embrapa.br/arquivos/consorcio/publicacoes_tecnicas/livro_implantacao_cafe_zais.pdf. Acesso em 24 fev. 2020.

EMBRAPA Hortaliças. **Agricultura de precisão: resultados de um novo olhar**. Brasília, 2014. 600 p.

ESCALANTE, H. J. *et al.* Barley yield and fertilization analysis from UAV imagery: a deep learning approach. **International Journal of Remote Sensing**, London, v. 40, n. 7, p. 2493-2516, 2019.

ESRI, Environmental Systems Research Institute - Inc. **ARCGIS Professional GIS for the desktop version 10.5**. Redlands, Califórnia, Software, 2017. Disponível em: <https://desktop.arcgis.com/en/quick-start-guides/10.5/arcgis-desktop-quick-start-guide.htm>. Acesso em: 10 Jan. 2020.

FAVARIN, J. L. *et al.* Equações para a estimativa do índice de área foliar do cafeeiro. **Pesquisa Agropecuária Brasileira**, v. 37, n. 6, p. 769-773, 2002.

FERRAZ, G. A. S. *et al.* Agricultura de precisão no estudo de atributos químicos do solo e da produtividade de lavoura cafeeira. **Coffee Science**, v. 7, n. 1, p. 56-67, 2012.

FENILLI, T. A. B. *et al.* Fertilizer ^{15}N balance in a coffee cropping system: a case of study in Brazil. **Revista Brasileira de Ciência do Solo**, v. 32, p. 1459-1469, 2008.

FOWLER, D. *et al.* The global nitrogen cycle in the twenty-first century. **Philosophical Transactions of the Royal Society**, v. 368, e-20130164, 2013.

FRANÇA, A. C.; CARVALHO, F. P. Correlations between SPAD readings, chlorophyll and leaf nitrogen in coffee cultivars during fruiting stage. **Revista Agrarian**, v. 9, n. 34, p. 319-325, 2016.

FRANCISCO, C. N. Análise do impacto da correção atmosférica no cálculo do Índice de Vegetação por Diferença Normalizada a partir de Imagem Landsat 8/OLI. **Revista Brasileira de Geografia Física**, v. 13, n. 1, p. 76-76, 2020.

GARZA, B. N. Quantifying citrus tree health using true color UAV images. **Remote Sensing**, v. 12, n. 170, 2020.

GEIPEL, J. *et al.* A Programmable Aerial Multispectral Camera System for In-Season Crop Biomass and Nitrogen Content Estimation. **Remote Sensing**, v. 6, n. 4, p. 1-19, 2016.

GILBERT, C. L. International Commodity Agreements: an obituary notice. **World development**, v. 24, n. 1, p. 1-19, 1996.

GITELSON, A. A.; KAUFMAN, Y.J.; STARK, R. *et al.* Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v.80, p.76-87, 2002.

GUIMARÃES, P. T. G. *et al.* Cafeeiro. In: RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVARES, V. H. (Ed.). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação**. Viçosa, MG: UFV, 1999. p.289-302.

HUNT Jr., E. R. *et al.* Monitoring nitrogen status of potatoes using small unmanned aerial vehicles. **Precision Agriculture**, v. 19, p. 314-333, 2018.

HUNT Jr.; 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.

International Coffee Organization. **Historical data on the global coffee trade**. 2020. Disponível em: http://www.ico.org/new_historical.asp?section=Statistics. Acesso em: 24 Fev. 2020.

_____. **Developing a sustainable coffee economy**. 2020a. Disponível em: http://www.ico.org/sustaindev_e.asp. Acesso em: 24 Fev. 2020.

Instituto Nacional de Meteorologia (Brasil). **Estações Convencionais**. 2020. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesConvencionais>. Acesso em 27 jan. 2020.

Instituto Nacional de Pesquisas Espaciais (Brasil). **Catálogo de Imagens**. 2020. Disponível em: <http://www.dgi.inpe.br/CDSR/>. Acesso em 20 fev. 2020.

Centro de Comércio Internacional. **Trade Map: trade statistics for international business development**. 2018. Disponível em: <https://www.trademap.org/>. Acesso em 24 Fev. 2020.

JADOSKI, S. O. *et al.* Características da lixiviação de nitrato em áreas de agricultura intensiva. **Pesquisa Aplicada e Agrotecnologia**, v. 3, n. 1, p. 193-200, 2010.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2. ed. São José dos Campos: Parêntese, 2011.

LATIF, M. A. *et al.* Mapping wheat response to variations in N, P, Zn and irrigation using unmanned aerial vehicle. **International Journal of Remote Sensing**, v. 39, n. 21, p. 7172-7188, 2018.

LEPSCH, I. F. **19 Lições de pedologia**. São Paulo: Oficina de Textos, 2011. 456 p.

LI, S. *et al.* Potential of UAV-based active sensing for monitoring rice leaf status. **Frontiers in Plant Science**, v. 9, p. e-1834, 2018.

LIAW, A; WIENER, M. Classification and regression by random forest. **R News**, v. 2, n. 3, p. 18-22, 2002.

LOUHAICHI, M. *et al.* Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, n. 1, p. 65-70, 2001.

MAES, W. H.; STEPPE, K. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. **Trends in Plant Science**, v. 24, n. 2, p. 152-164, 2019.

MALTA, M. R. *et al.* Produtividade de lavouras cafeeiras (*Coffea Arabica L.*) em conversão para o sistema orgânico de produção. **Coffee Science**, v. 2, n. 2, p. 183 – 191, 2007.

MANFREDA, S. *et al.* On the use of Unmanned aerial systems for environmental monitoring. **Remote Sensing**, v. 10, e-641, 2018.

MATESE, A. *et al.* Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. **Remote Sensing**, v. 7, p. 2971 – 2990, 2015.

MENESES, P. R. *et al.* **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UnB, 2012. 266p.

MINOLTA. Chlorophyll meter SPAD-502: Instruction manual. **Minolta Co.**, Osaka, 1989. 24 p.

MOZGERIS, G. *et al.* Imaging from manned ultra-light and unmanned aerial vehicles for estimating properties of spring wheat. **Precision Agriculture**, v. 19, p. 876-894.

MUELLER, C. C. O impacto do Acôrdio Internacional do Café sôbre o preço do café. **Revista Brasileira de Economia**, v. 25, n. 3, p. 131-148, 1971.

- MULVANEY, R. L. *et al.* The myth of nitrogen fertilization for soil carbon sequestration. **Journal of Environmental Quality**, v. 36, 2007.
- NÄSI, R. Estimating biomass and nitrogen amount of barley and grass using UAV and aircraft based spectral and photogrammetric 3D Features. **Remote Sensing**, v. 10, e-1082, 2018.
- OMM - Organização Mundial de Meteorologia. **Greenhouse gas bulletin: the state of greenhouse gases in the atmosphere based on global observations through 2017**. 2018. Disponível em: <http://portalods.com.br/publicacoes/greenhouse-gas-bulletin-gases-de-efeito-estufa-boletim/>. Acesso em 24 Fev. 2020.
- ONU – Organização das Nações Unidas. Divisão de Estatísticas. **UN Data: Trade of goods, US\$, HS 1992, 09 Coffee, tea, mate and spices**. 2019. Disponível em: http://data.un.org/Data.aspx?d=ComTrade&f=_11Code%3A10. Acesso em 24 Fev. 2020.
- OSCO, L. P. *et al.* Predicting canopy nitrogen content in citrus-trees using random forest algorithm associated to spectral vegetation indices from UAV-imagery. **Remote Sensing**, v. 11, e-2925, 2019.
- OTTO, R. *et al.* Effects of previous soil management on sugarcane response to nitrogen fertilization. **Scientia Agricola**, v. 76, n. 1, p. 72-81, 2019.
- PENG, Y. *et al.* Remote prediction of yield based on LAI estimation in oilseed rape under different planting methods and nitrogen fertilizer applications. **Agricultural and Forest Meteorology**, v. 271, p. 116 – 125, 2019.
- PONZONI, F. J; SHIMABUKURO, Y. E; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. 176 p.
- PÔRTO, M. L. *et al.* Índice SPAD para o diagnóstico do estado de nitrogênio na cultura da abobrinha. **Horticultura Brasileira**, v. 29, n. 3, p. 311 - 315, 2011.
- POTTS, J. *et al.* Coffee market. In: ILNYCKY, R.; HOLMES, D.; RICKERT, E. (Ed.). **The state of sustainability initiatives review 2014: standards and the green economy**. Winnipeg: International Institute for Sustainable Development, 2014. p. 155-183.
- R Core Team. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Viena, 2019.
- RIBEIRO JR, P. J; DIGGLE, P. J. **geoR: Analysis of geostatistical data**. R package version 1.7-5.2.1. 2018.
- REIS, A. R. *et al.* Photosynthesis, chlorophylls, and SPAD readings in coffee leaves in relation to nitrogen supply. **Communications in Soil Science and Plant Analysis**, v. 40, n. 9, p. 1512-1518, 2009.
- SAMPER, L. F; QUIÑONEZ-RUIZ, X. F. Towards a balanced sustainability vision for the coffee industry. **Resources**, v. 6, e-17, p. 1-28, 2017.

SANTOS, C. G. *et al.* Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture**, 2020.

SEIFERT, E. *et al.* Influence of drone altitude, image overlap, and optical sensor resolution on multi-view reconstruction of forest images. **Remote Sensing**, v. 11, e-1252, 2019.

SILVA, D. C. Evolução da fotogrametria no Brasil. **Revista Brasileira de Geomática**, v. 3, n. 2, p. 81-96, 2015.

STAVRAKOUDIS, D. *et al.* Estimating rice agronomic traits using drone-collected multispectral imagery. **Remote Sensing**, v. 11, e-545, 2019.

SOUZA, J. A. *et al.* Nitrogen dynamics in a Latossol cultivated with coffee. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 6, p. 390 – 395, 2018.

TAIZ, L. *et al.* **Fisiologia e Desenvolvimento Vegetal**. 6. ed. Porto Alegre: Artmed, 2017. 858p.

TASCA, F. A. *et al.* Volatilização de amônia no solo após a aplicação de ureia convencional ou com inibidor de urease. **Revista Brasileira de Ciência do Solo**, v. 35, p. 493-518, 2011.

THOMPSON, R. L. *et al.* Acceleration of global N₂O emissions seen from two decades of atmospheric inversion. **Nature Climate Change**, v. 9, p. 993-998, 2019.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, p. 127–150, 1979.

Universidade Federal de Viçosa. Departamento de Solos. **Mapa de solos do estado de Minas Gerais**. 2010. Disponível em: http://www.dps.ufv.br/?page_id=742. Acesso em: 15 set. 2019.

VAN DER MEIJ, Remote sensing of plant trait responses to field-based plant-soil feedback using UAV-based optical sensors. **Biogeosciences**, v. 14, p. 733-749, 2017.

VEGA, F. A. *et al.* Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. **Biosystems Engineering**, v. 132, p. 19-27, 2015.

VIEIRA, R. F. **Ciclo do Nitrogênio em sistemas agrícolas**. Brasília: Embrapa, 2017. 163 p.

WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259-269, 1995.

XANTHOULA, E. P; MOSHOU, D; BOCHTIS, D. Intelligent data and fusion systems in agriculture. Cambridge: Academic Press, 2019. 325 p.

YANG, B. *et al.* Evaluation of aboveground nitrogen content of winter wheat using digital imagery of unmanned aerial vehicles. **Sensors**, v. 19, n. 4416, p. 1-18.

YUAN, M. *et al.* Unmanned aerial vehicle-based assessment of cover crop biomass and nitrogen uptake variability. **Journal of Soil and Water Conservation**, v. 74, n. 4, p. 350-359, 2019.

ZHANG, X. *et al.* Managing nitrogen for sustainable development. **Nature**, v. 528, p. 51-59, 2015.

ZHENG, *et al.* Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. **Biosystems Engineering**, v. 189, p. 24 - 35, 2020

SEGUNDA PARTE

Artigo publicado em julho de 2020 na Revista *Coffee Science*, v. 15:
<https://doi.org/10.25186/v15i.1736>

Artigo 1: Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee

Taya Cristo Parreiras¹, Guilherme Henrique Expedito Lense¹, Rodrigo Santos Moreira¹,
Derielsen Brandão Santana², Ronaldo Luiz Mincato¹

¹Universidade Federal de Alfenas/UNIFAL, Alfenas, MG, Brasil

²Instituto Brasileiro de Geografia e Estatística/IBGE, Alfenas, MG, Brasil

Contact authors: tayacristo1@gmail.com, guilhermeelense@gmail.com,
rodrigomagro@yahoo.com.br, derielsen@hotmail.com, ronaldo.mincato@unifal-mg.edu.br *Received*
in March 23, 2020 and approved in May 26, 2020

ABSTRACT

Nitrogen is an essential element for coffee production. However, when fertilization do not consider the spatial variability of the agricultural parameters, it can generate economic losses, and environmental impacts. Thus, the monitoring of nitrogen is essential to the fertilizing management, and remote sensing based on unmanned aerial vehicles imagery has been evaluated for this task. This work aimed to analyze the potential of vegetation indices of the visible range, obtained with such vehicles, to monitor the nitrogen content of coffee plants in southern Minas Gerais, Brazil. Therefore, we performed leaf analysis using the Kjeldahl method, and we processed the images to produce the vegetation indices using Geographic Information Systems and photogrammetry software. Moreover, the images were classified using the Color Index of Vegetation and the Maximum Likelihood Classifier. As estimator tool, we created Random Forest models of classification and regression. We also evaluated the Pearson correlation coefficient between the nitrogen and the vegetation indices, and we performed the analysis of variance and the Tukey-Kramer test to assess whether there is a significant difference between the averages of these indices in relation to nitrogen levels. However, the models were not able to predict the nitrogen. The regression model obtained a $R^2 = 0.01$. The classification model achieved an overall accuracy of 0.33 (33%), but it did not distinguish between the different levels of nitrogen. The correlation tests revealed that the vegetation indices are not correlated with the nitrogen, since the best index was the Green Leaf Index ($R = 0.21$). However, the image classification achieved a Kappa coefficient of 0.92, indicating that the tested index is efficient. Therefore, visible indices were not able to monitor the nitrogen in this case, but they should continue to be explored, since they could represent a less expensive alternative.

Keys words: Vegetation indices; RGB; machine learning; *Coffea arabica*.

INTRODUCTION

Coffee production can be impacted by several factors such as plagues, climate variations, planting system and density, terrain slope, soil quality, as well as the physiological characteristics of the plants (Ferraz *et al.*, 2012). Therefore, management planning and the monitoring of the crops are key-factors to guarantee good productivity and to reduce socioeconomics and environmental impacts (Näsi *et al.*, 2018).

Nitrogen is an essential element to crops, once it is part of the structure, the metabolism, and the osmoregulation of the plants, playing an essential role in photosynthesis (Taiz *et al.*, 2017), therefore, is limiting factor to coffee production. On the other hand, when the N availability highly overcomes the plant's necessity, it can cause soil and atmosphere pollution, which can also lead to eutrophication of water bodies (Ballester *et al.*, 2017).

Thus, precision agriculture (PA) has been gained space on the field, approaching science and technology to agricultural practices, helping to reduce costs, improve productivity by area, and minimize environmental impacts through the planning of actions as fertilization, irrigation, and disease control (Vega *et al.*, 2015), and remote sensing is an important technology of the PA (Hunt Junior *et al.*, 2018).

Therefore, researchers have been analyzing the potential vegetation indices (VI) obtained with visible sensors mounted to unmanned aerial vehicles (UAV), along with digital image processing techniques, to monitor the spatial variability of the nitrogen content in different kinds of crops like barley (Escalante *et al.*, 2019), grasses (Caturegli *et al.*, 2019; Näsi *et al.*, 2018), potatoes (Hunt Junior *et al.*, 2018), wheat (Schirrmann *et al.*, 2016), and maize (Zhang *et al.*, 2020).

The UAV can help to overcome issues related to the leaf analysis, which may be expensive and time-consuming, since the mounted sensors have high resolution and the crops can be monitored during the entire season (Maes; Steppe, 2019). The VI are equations relating the spectral behavior of the surface vegetation, based on the plant responses in the different ranges of the electromagnetic spectrum, which is different according to the plant health (Caturegli *et al.*, 2019; Ponzoni; Shimabukuro; Kuplich, 2012).

The VI relating the red, blue, and green reflectance have also been tested to detect the severity of infections, weed occurrence, to monitor growth vigor, and presented good perspectives to monitor nutrient status and yield prediction. Moreover, they represent a less expensive alternative when other bands, like Red-Edge and Near Infrared, are not available (Beniaich *et al.*, 2019; Maes; Steppe, 2019).

To the data analysis, machine learning algorithms like Random Forest (RF), used in this study, and neural networks like Deep Learning Convolutional Neural Network (DCNN) are gaining space and presenting promising results (Escalante *et al.*, 2019; Osco *et al.*, 2019; Näsi *et al.*, 2018).

Although this approach is becoming more present, at the best of our knowledge, there are no published studies involving N content monitoring using UAV in coffee crops, which is an essential economic activity in Brazil, especially at southern Minas Gerais. Furthermore,

researchers have been mainly applying multispectral VI, which require more expensive sensors, and makes the RGB-based imaging, a less expensive alternative.

Comparing the individual relationship of the spectral indices with the ground measured N, and evaluating them with Random Forest classification and regression models, our work aimed to assess the potential of RGB-based VI in monitoring N in a coffee-growing area, in Divisa Nova Municipality, Minas Gerais, Brazil's southeast.

MATERIAL AND METHODS

Study area and leaf sampling

The research was carried out in a 1 ha plot of coffee crops, located in Divisa Nova, southern Minas Gerais state, Brazil (21°20'S and 46°10'W, Datum SIRGAS 2000) (Figure 1). The Santo Andre farm has about 80 ha and produces coffee (Red Catuaí variety - *Coffea arabica*) in transition to organic type of production, with plants 0.65 m x 3.5 m apart.

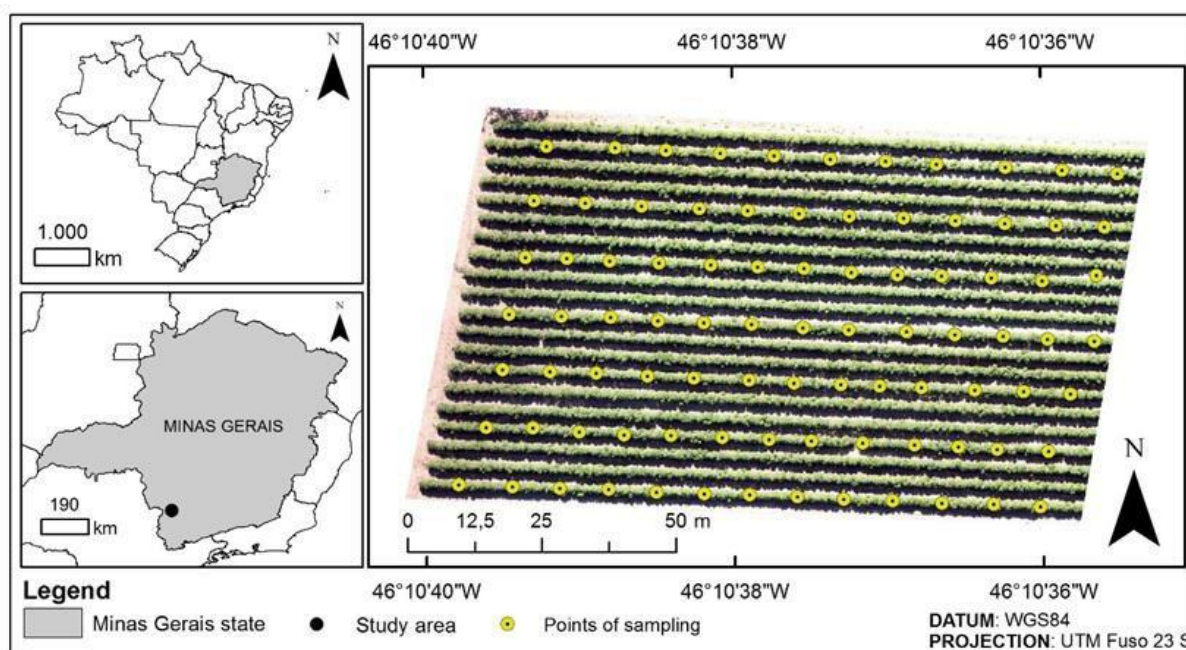


Figure 1: Study area, at the Santo André Farm, southern Minas Gerais, Brazil, and location of the points of sampling for leaf analysis and SPAD readings.

According to Köppen classification, the climate is characterized by dry winters and tempered summers (Cwb) (Alvares, 2013), with an average annual temperature between 20 and 22 °C, and a total annual rainfall in 2018 between 1800 and 2000 mm (Instituto Nacional de Meteorologia – INMET, 2020). The altitude of the area ranges from 820 to 900 m, with an average elevation of 860 m. The soil of the area is classified as Oxisol.

In the first stage of the study, we distributed 88 points of sampling, as shown in Figure 1, where 8 leaves were collected, 4 from each side of the plants. The healthy-looking leaves were removed from the plagiotropic branches, in the middle third of the coffee trees. This sampling

was carried out on May 29th, 2019, between 7:30 am and 10:30 am. Moreover, to determine the N content, we conducted triplicates of the Kjeldahl method for leaf N quantification.

Along with the N amount expressed in kg kg^{-1} , obtained with the analysis, a parallel database was created to turn these measures into classes, where we classified them in three levels of nitrogen: deficient (if $N < 0.0288 \text{ kg kg}^{-1}$), appropriate ($N 0.0288 - 0.0322 \text{ kg kg}^{-1}$), and excessive ($N > 0.0322 \text{ kg kg}^{-1}$), as proposed by Guimarães *et al.* (1999). This new database was used to perform the Random Forest (RF) classification model, which will be discussed below.

On the same leaves that were analyzed, we used the chlorophyll meter SPAD 502, performing 2 readings per leaf, and registering the average for each point, that is, 16 readings per point. The SPAD values are given by the difference between the transmittance of red and infrared light that penetrated the leaf (Garza *et al.*, 2020), and the objective of obtaining these values was to verify their relationship with the measured amounts of N.

Image acquisition, processing, and vegetation indices generation

The UAV used in this study was a multirotor Phantom 4 Advanced (DJI, Shenzhen, China) that has a visible (RGB) sensor 1" CMOS of 20 megapixels. The flights were planned using the Pix4D Capture software (Pix4D Inc., San Francisco, USA), where the area coverage grid was created, and the flight parameters (altitude, overlap, NADIR field of view, etc.) were determined. The uncalibrated images were taken on the same day as the leaf sampling (May 29th, 2019), at noon, with a clear sky and no clouds. The parameters of the flight are shown in Table 1.

Table 1: Date and parameters of the flight.

Flight date	Altitude	Overlap/Sidelap	Average GSD* cm px^{-1}	Flight Time
May 29th, 2019	50 m	80/80 (%)	1.27	0.12 h

*GSD: Ground Sample Distance by pixel.

Firstly, the acquired images were processed in the Pix4D Mapper 4.4.12 software (Pix4D Inc., San Francisco, USA), where the 171 photos were combined to produce the georeferenced orthomosaic and the digital surface model (DSM) of the entire study area. Using the DSM, we generate 100 points well distributed over the area to extract values of elevation, ignoring the values regarding the plants. Then, using these values, we interpolated them with the IDW tool (Environmental Systems Research Institute - Inc. – ESRI, 2017) to create de Digital Elevation Model (DEM) of the area.

Then, the bands of the orthomosaic were separated using the Raster Calculator tool of the QGIS 3.8.3 (QGIS Development Team, 2020), which generated three spectral maps: Red, Green, and Blue. The separated bands were normalized, also using the Raster Calculator, to determine the chromatic levels, as proposed by Arroyo, Guijarro and Pajares (2016) with Equation 1.

$$\frac{\text{Red}}{\text{Red+Green+Blue}}, \frac{\text{Green}}{\text{Red+Green+Blue}} \text{ and } \frac{\text{Blue}}{\text{Red+Green+Blue}} \quad (1)$$

Image classification

To remove as much background interference as possible, isolating the spectral response of coffee trees, we performed a supervised classification using the Color Index of Vegetation (CIVE) (Kataoka *et al.*, 2003), given by Equation 2. This index is indicated to generate a contrast between plants and soil, and has a good performance to estimate the fraction of vegetation cover (Beniaichi *et al.*, 2019).

$$\text{CIVE} = 0.441 * \text{Red} - 0.881 * \text{Green} + 0.385 * \text{Blue} + 18.78745 \quad (2)$$

Therefore, using the Image Classification tool, from the Spatial Analyst extension of the ArcMap 10.5 (ESRI, 2017), we collected 75 training samples from the soil and the coffee plants to perform the classification. The algorithm chosen for the process was the Maximum Likelihood Classifier (MLC), which uses the training samples to delimit homogeneous regions, pixel by pixel, to calculate the mean and the covariance matrix, estimating the probability of determined pixel belongs to a given class (Cechim Júnior; Johann; Antunes, 2017).

Moreover, to verify the accuracy of this classification, 100 random points were generated in the study area to verify the agreement index between the real and the classified image, given by the Kappa coefficient (k) through Equation 3 (Cohen, 1960), measured using the “kappa2” and “kappam.fleiss” functions, from the “irr” package of the R software (Gamer *et al.*, 2019; R Core Team, 2019).

$$k = P_0 - P_e / (1 - P_e) \quad (3)$$

In which: P_0 = proportion of agreement between classified and real; P_e = proportion of units in which concordance is expected by the chance.

Vegetation indices generation

The classification of the previous step, which resulted in a binary raster image, was converted into a polygon file, from which only those polygons referring to the coffee lines were selected. Thus, the vegetation indices could be calculated and generated only within the areas of interest, that is, those occupied by the coffee trees.

The vegetation indices (VI) selected for the study were the following: Excess Green (ExG), Green Leaf Index (GLI), Visible Atmospheric Resistance Index (VARI), Normalized Green-Red Difference Index (NGRDI) and Color Index of Vegetation (CIVE). The VI were generated executing their corresponding equations (Table 2), also using the Raster Calculator tool, with the normalized bands.

Table 2: Vegetation Indices (VI), equations and references.

VI	Equation	Reference
GLI	$\frac{2 * \text{Green} - \text{Red} - \text{Blue}}{2 * \text{Green} + \text{Red} + \text{Blue}}$	Louhaichi <i>et al.</i> (2001)
ExG	$2 * \text{Green} - \text{Red} - \text{Blue}$	Woebbecke <i>et al.</i> (1995)

NGRDI	$\frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red}}$	Tucker (1979)
VARI	$\frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red} - \text{Blue}}$	Gitelson <i>et al.</i> (2002)
CIVE	$0.441 * \text{Red} - 0.881 * \text{Green} + 0.385 * \text{Blue} + 18.78745$	Kataoka <i>et al.</i> (2003)

Where: GLI (Green Leaf Index), ExG (Excess Green), NGRDI (Normalized Difference Green Red Index), VARI (Visible Atmospherically Resistant Index), and Color Index of Vegetation (CIVE).

To complete the datasets used to run the Random Forest (RF) models, at the same georeferenced points of sampling, we generated circular buffers with radius = 0.7 m. Then, using the Zonal Statistics as Table tool (ESRI, 2017), the average values of each VI were extracted in the areas corresponding to these buffers. Therefore, the regression model dataset contained the amount of N (kg kg⁻¹) plus the VI values, while the classification model dataset, was composed by the levels of N (deficient, appropriate, and excessive) plus the VI data.

Variance and mean analysis, and Random Forest models

Initially, we generated a correlation matrix to evaluate the relationship between the VI and the measured N (kg kg⁻¹) through the Pearson Correlation Coefficient (PCC). We also performed the analysis of variance (ANOVA) using R, and then, using the package DTK (Lau, 2015), in R environment, we executed the Tukey-Kramer test ($p < 0.05$), since the samples were unbalanced, relating the VI data to the three levels of N.

The Random Forest (RF) is a machine learning algorithm, used to make predictions through regression or classification, and that can handle a high number of variables without overfitting. Its implementation is relatively simple and fast, being currently, one of the most accurate available techniques for this task (Biau, 2012).

The RF works with the analysis of decision trees, creating a “forest” of trees that are combined by the bagging method, with the premise that this random combination will generate better models with more accurate predictions (Osco *et al.*, 2019; Biau, 2012).

In this work, this algorithm was used to generate a model of regression, to estimate the N content, and another of classification, to estimate the N levels, using the values of VI as explanatory variables. Both models were executed using the randomForest package in the software R (Liaw; Wiener, 2002; R Core Team, 2019).

The datasets of the models were separated into training subsets, with 80% of the data, and test subsets, with 20% of the data. Also, it was determined the creation of 500 trees, with 2 variables at each node. This last parameter was defined using the tuneRF function, of the same package.

To evaluate the regression model, we use the coefficient of determination (R^2) and the root mean of square error (MSE) between the predicted and the measured data in the test subset. To evaluate the classification model, we used the Kappa coefficient (k), and the overall accuracy, which is a measure that discounts the Out of bag (OOB) error rate, and estimates the classification error rate in the test subset as the trees are added to the forest. However, for both models, as the trees are added, the reduction of the errors is limited, avoiding overfitting.

Moreover, the Random Forest also assesses the relevance of variables by generating a score of importance, given by the increase of the Mean Squared Error (%IncMSE) for the regression model, and by the Mean Decrease Accuracy for the classification model. Both scores reflect the OOB error rate assessment, evaluating the impact of the exchange of each variable for the increase of the errors in the predictions, that is, determining how important is each variable to the precision of the forecasts.

RESULTS AND DISCUSSION

Leaf analysis and Digital Elevation Model

The basic statistics of the N and SPAD values measured are shown in Table 3. The results indicate that, in general, the N content is appropriated, according to the level proposed by Guimarães *et al.* (1999).

Table 3. Basic statistics of the leaf analysis of the nitrogen content and the SPAD values.

Parameter	Minimum	Maximum	Average	Standard Deviation
N	0.024 kg kg ⁻¹	0.0357 kg kg ⁻¹	0.0302 g kg ⁻¹	0.0024 kg kg ⁻¹
SPAD values	50.3	70.3	59.95	3.53

However, considering these levels, only 53% of the leaf samples were appropriate (0.0288 to 0.0322 kg kg⁻¹), while 23.5% of the analyzes showed deficiency (N < 0.0288 kg kg⁻¹), and another 23.5%, exhibited an excess (N > 0.0322 kg kg⁻¹). Using the DEM (Figure 2), it was possible to understand how the nitrogen varies in the studied area.




Figure 2: Digital Elevation Model (DEM) of the study area.

We performed a Pearson correlation test with the N amounts (kg kg⁻¹) and the respective values of altitude, with all sampled points, to evaluate if there is a variation of the N levels according to the altitude. The result presented R of -0.48 (significant at $p < 0.01$), and therefore, although it is not a perfect negative correlation, it shows a significant tendency of accumulation

of the nutrient in the lower parts of the area, which can be explained by the transportation of nutrients mainly due to the action of rainfall and the surface runoff. The variation of the N content in relation to the terrain elevation is shown in the Table 4.

Table 4: Variation of the N content as the terrain elevation changes.

Elevation (meters)	Average N content (kg kg^{-1}) \pm Standard Deviation
838 – 840 m	0.0329 ± 0.00016
840.1 - 841 m	0.0313 ± 0.00022
841.1 - 842 m	0.0297 ± 0.00019
842.2 - 843 m	0.0319 ± 0.00018
843.1 - 844 m	0.0285 ± 0.00021
844.1 - 845 m	0.0288 ± 0.00018
845.1 - 846 m	0.0294 ± 0.00018

The correlation analysis between N content and SPAD values, otherwise, indicated low relationship, $R = 0.16$ between these parameters, which was not expected, since the SPAD readings usually are well related with plant nutrition (Reis *et al.*, 2009; Pôrto *et al.*, 2011).

Image classification

The supervised classification of the image that was made with the CIVE to separate the coffee lines from the background (soil, shade, and invasive plants), presented an almost perfect accuracy, since the Kappa coefficient of the classification was 0.92, with significance statistic of $p < 0.01$. The final classified image is shown in Figure 3.




Figure 3: Classified image indicating the coffee rows.

Vegetation Indices

The correlation analysis showed that the VI are not related to the N content, since the best correlation obtained was with the Green Leaf Index (GLI), $R = 0.21$ ($p < 0.05$). However, most VI are highly related to each other. The Color Index of Vegetation (CIVE) is a VI that highlight the red band (absorption band on plants), that is why it presented inversely proportional correlation with the N and the other VI, especially with the GLI (Table 5).

Table 5: Correlation matrix between the measured N x VI, and between VI x VI.

	N (kg kg ⁻¹)	GLI	NGRDI	VARI	ExG	CIVE
N (kg kg ⁻¹)	1					
GLI	0.21*	1				
NGDRI	0.18	0.79*	1			
VARI	0.15	0.69*	0.98*	1		
ExG	0.17	0.64*	0.97*	0.98*	1	
CIVE	-0.20	-0.98*	-0.69*	-0.57*	-0.51*	1

Where: N (nitrogen); GLI (Green Leaf Index); NGRDI (Normalized Green Red Difference Index); VARI (Visible Atmospherically Resistant Index); ExG (Excess Green); CIVE (Color Index of Vegetation).

**statistical significance at $p < 0.05$.

Considering the levels of N (deficient, appropriate and excessive), the analysis of variance (ANOVA) showed that, between the VI, only the CIVE presented significant variation, and the SPAD values also did not varied significantly within the N levels (Table 6).

Table 6: Analysis of variance between the vegetation indices and the SPAD values in relation to the nitrogen levels.

Variable	F value	Probability (>F)
CIVE	3.404	0.03
ExG	0.169	0.84
GLI	1.968	0.15
VARI	0.113	0.89
NGRDI	0.304	0.74
SPAD	0.202	0.82

Where: GLI (Green Leaf Index); NGRDI (Normalized Green Red Difference Index); VARI (Visible Atmospherically Resistant Index); ExG (Excess Green); CIVE (Color Index of Vegetation).

The analysis of means, made with the Tukey-Kramer test for unbalanced samples revealed that this difference exhibited in the CIVE occurred between the excessive - appropriate classes (Table 7).

Table 7: Average values of the vegetation indices and the SPAD values according to the levels of nitrogen analyzed with the Tukey-Kamer test ($p < 0.05$).

Variable	Average	Variable	Average
CIVE		GLI	
Appropriate	18.770 a	Excessive	0.186 a
Deficient	18.768 ab	Deficient	0.176 a
Excessive	18.757 b	Appropriate	0.175 a
EXG		NGRDI	
Excessive	0.726 a	Excessive	0.0965 a
Appropriate	0.723 a	Appropriate	0.0927 a
Deficient	0.721 a	Deficient	0.0910 a
VARI		SPAD	
Excessive	0.1422 a	Excessive	68.18 a
Appropriate	0.1409 a	Appropriate	59.69 a
Deficient	0.1371 a	Deficient	59.50 a

Where: GLI (Green Leaf Index); NGRDI (Normalized Green Red Difference Index); VARI (Visible Atmospherically Resistant Index); ExG (Excess Green); CIVE (Color Index of Vegetation).

Random Forest models

Both the regression model, built with the N data in kg kg⁻¹, and the classification model, made with the N data classified in levels, did not obtain significant results in the predictions. The results of the models are shown in Table 8.

Table 8: Performance of the Random Forest models.

Model	Overall accuracy	Kappa Coefficient	R ²	MSE (kg kg ⁻¹)
Regression	-	-	-0.06	0.00636
Classification	0.33	-0.02	-	-

Where: R² (coefficient of determination); MSR (mean squared error).

In the classification model, the appropriate class reached an overall accuracy of 73%. However, the unbalancing of the samples can help to explain this outcome. There were 44 samples of this class, while there were only 19 for the excessive, and 21 for the deficient. The confusion matrix of the training sample shows that the model estimated 67% of the samples as “appropriated”, which although representative of this level on the field, did not mean sensibility to distinguish among the different N levels. This outcome can also be explained by the inexistence of significant differences within the vegetation indices, as shown previously with the Tukey-Kramer test.

Regarding the importance of each variable, the CIVE was the most important for the regression model, while for the classification model, the VARI was the most relevant, followed by the CIVE (Table 9).

Table 9: Contribution of each vegetation index for the Random Forest models of regression and classification, where higher values represents higher relevance.

Vegetation Index	Regression Model	Classification Model
	Increase of mean squared error	Mean Decrease Accuracy
Color Index of Vegetation (CIVE)	8.73 %	2.48
Green Leaf Index (GLI)	6.54 %	-4.44
Normalized Green-Red Difference Index (NGRDI)	1.50 %	-1.34
Excess Green (ExG)	1.33 %	-2.29
Visible Atmospherically Resistant Index (VARI)	1.21 %	3.19

The main objective of finding a model able to explain and predict N-variability is to assist farmers in the identification of zones with deficiency or excess, with fastness e precision, thus preventing economic losses and environmental negative impacts caused by unnecessary fertilization. However, our approach of using the Random Forest models could not monitor and predicted the N content or level, since the vegetation indices used in this study did not present significant variation that it would allow them to distinguish between the different nutrition status over the field.

Zhang *et al.* (2020), Hunt Junior *et al.* (2018) and Schirrmann *et al.* (2016) also found weak results monitoring the N variability with RGB imagery in maize, potatoes, and winter wheat, respectively. Garza *et al.* (2020), did not find significant correlation with the visible VI Triangular Greenness Index (TGI) and the amount of N in citrus trees. However, Zhang *et al.* (2020) reported that the Excess Green (ExG) may have the potential for this task, and Schirrmann *et al.* (2016) found positive relationships with other biophysical parameters of the crop, like fresh and dry biomass, and Leaf Area Index.

Regarding the leaf area, Hunt Junior *et al.* (2018) suggest that the vegetation cover index (CVR) can be an alternative in the monitoring of the N content with RGB images, due to the high spatial resolution, and due to the relationship between N content and plant development. Garza *et al.* (2020) also affirm that the leaf area can be affected by the nutritional status of the plants, so monitoring it can lead to the detection of stresses like diseases and lack of nutrients, and Näsi *et al.* (2018) found high correlations between the amounts of N and biomass in barley crops, indicating the potential of the approach.

Beniaich *et al.* (2019) estimated the cover vegetation index of millet and jack beans using RGB images and found good results with the CIVE and the ExG. In our study, the CIVE presented an excellent performance in the leaf cover classification. Moreover, Cunha, Sirqueira Neto and Hurtado (2019) obtained good results estimating the volume of coffee crops using true color images from UAV. Therefore, the monitor of the growth, within different rates of N fertilizing with this VI could be an alternative to be explore.

In previous studies, researchers have been establishing plots with different treatments to create a contrast over the study area. Our study, on the other hand, was executed in an area without the control of the fertilizing, which was done homogeneously by the farm administration. Moreover, in the monitoring of N-variability of different crops, the correlations

are usually higher in the vegetative phase (Schirrmann *et al.*, 2016; Vega *et al.*, 2015; Zhang *et al.*, 2020), which was not the case of this survey, done after the harvest.

The authors that used RGB-imagery report variable results, and the methodology seems to play an important role in these outcomes. Escalante *et al.* (2019) achieved very good results using different deep convolutional neural networks to monitor three different rates of N with barley, and their model were especially accurate to identify zones of deficiency, with a performance higher than 95%. Näsi *et al.* (2018), also monitoring the N variability with barley, managed to improve their results combining RGB spectral data with 3D features.

Therefore, exploring the wide range of machine learning algorithms is a way of deeply examine the potential of the RGB-imagery to this task, as well as incorporate 3D models in the analysis, which can be done with the same photogrammetry software, although it requires a much powerful computer.

Caturegli *et al.* (2019) bring an interesting approach that involves the conversion of the RGB images into values of Hue, Saturation, and Brightness (HSB) to generate the Dark Green Colour Index (DGCI), which led them to promising results, with high correlations of this index with the N content and even with the NIR-based VI Normalized Difference Vegetation Index (NDVI).

Therefore, although the use of RGB-imagery can lead to very poor results, it all depends on continuously exploring different approaches of data acquiring, processing, and analysis. Base on the results reported by some authors, the visible range should not be discarded from the task of monitoring the nutritional status of crops.

Regardless of the fact that we did not establish different fertilizing treatments, the leaf analysis revealed the occurrence of sites with inadequate N content, with a noticeable spatial distribution, like higher amounts in lower areas. This reasserts the importance of the N-monitoring so producers can create management zones, perform the applications at variable rates, using a faster, relatively less expensive, and more appropriate strategy to reach the goals.

Despite the results, RGB imagery is a less expensive alternative that should continue to be tested, once it could come to represent a changing point to the planning of the fertilization. If this approach reaches success, it can also beneficiate small farmers, helping to reduce the costs of the production, to improve productivity, and to minimize the environmental impacts related to the fertilizers.

CONCLUSIONS

The Random Forest models were not able to explain and predict the nitrogen variability, since the regression model achieved an R^2 of -0.06, while the classification model presented an overall accuracy of 33%, with a Kappa coefficient of -0.02.

The analysis of variance pointed to a significant variance only in the Color Index of Vegetation, and the Tukey-Kramer test showed that this difference occurred between the appropriate and the excessive levels. Therefore, this index could be implemented in further studies.

The analysis of correlation shown that the Excess Green had almost perfect positive correlation with the Normalized Green-Red Difference Index, $R = 0.97$ ($p < 0.05$), and with the Visible Atmospherically Resistant Index, where $R = 0.98$ ($p < 0.05$). Moreover, the Color Index of Vegetation, that highlights the red band, showed an almost perfect negative correlation with the Green Leaf Index, that in turn, highlights the green band, where $R = 0.98$ ($p < 0.05$).

The Green Leaf Index was the only vegetation index that presented a significant correlation with the N content, although low, where $R = 0.21$ ($p < 0.05$).

The method of image classification done using the Color Index of Vegetation and the Maximum Likelihood Classifier algorithm presented very good performance, achieving a Kappa coefficient of 0.92, an almost perfect accordance between real and classified image. There is a tendency of occurrence of higher nitrogen amount in lower areas of the field, since the Pearson Correlation Coefficient was significant as $R = -0.48$ ($p < 0.01$).

ACKNOWLEDGMENTS

This study was financed in part by the Coordination for the Improvement of Higher Education Personnel - Brazil (CAPES) – Finance Code 001. The authors thank the Minas Gerais State Research Support Foundation (FAPEMIG) and the National Council for Scientific and Technological Development (CNPq) for the grants awarded. The authors also thank the Legado Cafés that conceded the study area, and the Experimental Nutrition Laboratory of the Nutrition School of the Federal University of Alfnas for conceding space, orientation and equipment for leaf analysis.

REFERENCES

- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, 22(6):711-728, 2013.
- ARROYO, J.; GUIJARRO, M.; PAJARES, G. An instance-based learning approach for thresholding in crop images under different outdoor conditions. **Computers and Electronics in Agriculture**, 127:669-679, 2016.
- BALLESTER, C. *et al.* Assessment of In-Season Cotton Nitrogen Status and Lint Yield Prediction from Unmanned Aerial System Imagery. **Remote Sensing**, 9(11):1149, 2017.
- BENIAICHI, A. *et al.* Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. **Semina: Ciências Agrárias**, 40(1):49-66, 2019.
- BIAU, G. Analysis of a Random Forests model. **Journal of Machine Learning Research**, 13:1063-1095, 2012.
- CATUREGLI, L. *et al.* Normalized Difference Vegetation Index versus Dark Green Colour Index to estimate nitrogen status on bermudagrass hybrid and tall fescue. **International Journal of Remote Sensing**, p. 1-16, 2019.

CECHIM JÚNIOR, C.; JOHANN, J. A.; ANTUNES, J. F. G. Mapping of sugarcane crop area in the Paraná State using Landsat/TM/OLI and IRS/LISS-3 images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 21(6):427-432, 2017.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, 20(1):37-46, 1960.

CUNHA, J. P. A. R.; SIRQUEIRA NETO, M. A.; HURTADO, S. M. C. Estimating vegetation volume of coffee crops using images from unmanned aerial vehicles. **Engenharia Agrícola**, 39:41-47, 2019.

ESCALANTE, H. J. *et al.* Barley yield and fertilization analysis from UAV imagery: A deep learning approach. **International Journal of Remote Sensing**, 40(7):2493-2516, 2019.

ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE - INC. ESRI. **ARCGIS Professional GIS for the desktop version 10.5**. Redlands, California, 2017. Available in: <<https://desktop.arcgis.com/en/quick-start-guides/10.5/arcgis-desktop-quick-start-guide.htm/>>. Access in: January 10, 2019.

FERRAZ, G. A. S. *et al.* Agricultura de precisão no estudo de atributos químicos do solo e da produtividade de lavoura cafeeira. **Coffee Science**, 7(1):56-67, 2012.

GAMER, M. *et al.* **irr**: various Coefficients of Interrater Reliability and Agreement. R package version 0.84.1. 2019 Available in: <<https://cran.r-project.org/web/packages/irr/irr.pdf>>. Access in: April 30, 2020.

GARZA, B. N. *et al.* Quantifying Citrus Tree Health Using True Color UAV Images. **Remote Sensing**, 12(1):170, 2020.

HUNT JUNIOR, E. R. *et al.* Monitoring nitrogen status of potatoes using small unmanned aerial vehicles. **Precision Agriculture**, 19:314-333, 2018.

GITELSON, A. A. *et al.* Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, 80:76-87, 2002.

GUIMARÃES, P. T. G. *et al.* Cafeeiro. In: RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVARES, V. H. **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação**. Viçosa: UFV, 1999. p.289-302.

INSTITUTO NACIONAL DE METEOROLOGIA – INMET. **Estações Convencionais**. 2020. Available in: <<http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesConvencionais>>. Access in: January 27, 2020.

KATAOKA, T. *et al.* Crop growth estimation system using machine vision. **Proceedings 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics**, 2(1):1079-1083, 2003.

LAU, M. K. **DTK**: Dunnett-Tukey-Kramer Pairwise Multiple Comparison Test Adjusted for Unequal Variances and Unequal Sample Sizes. R package version 3.5. 2015. Available in: <<https://CRAN.R-project.org/package=DTK>>. Access in: April 30, 2020.

LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, 2(3):18-22, 2002.

LOUHAICHI, M. *et al.* Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. **Geocarto International**, 16(1):65-70, 2001.

MAES, W. H.; STEPPE, K. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. **Trends in Plant Science**, 24(2):152-164, 2019.

NÄSI, R. *et al.* Estimating Biomass and Nitrogen Amount of Barley and Grass Using UAV and Aircraft Based Spectral and Photogrammetric 3D Features. **Remote Sensing**, 10(7):1082, 2018.

OSCO, L. P. *et al.* Predicting Canopy Nitrogen Content in Citrus-Trees Using Random Forest Algorithm Associated to Spectral Vegetation Indices from UAV-Imagery. **Remote Sensing**, 11(24):2925, 2019.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. 176p.

PÔRTO, M. L. *et al.* Índice SPAD para o diagnóstico do estado de nitrogênio na cultura da abobrinha. **Horticultura Brasileira**, 29(3):311-315, 2011.

QGIS Development Team, 2020. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project. Available in: http://www.qgis.org/wiki/Developers_Manual>. Access in March 30, 2020.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, 2019.

REIS, A. R. *et al.* Photosynthesis, Chlorophylls, and SPAD Readings in Coffee Leaves in Relation to Nitrogen Supply. **Communications in Soil Science and Plant Analysis**, 40:1512-1528, 2009.

SCHIRRMANN, M. *et al.* Monitoring Agronomic Parameters of Winter Wheat Crops with Low-Cost UAV Imagery. **Remote Sensing**, 8(9):706, 2016.

TAIZ, L. *et al.* **Fisiologia e Desenvolvimento Vegetal**. 6. ed. Porto Alegre: Artmed, 2017. 858p.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, 8:127-150, 1979.

VEGA, F. A. *et al.* Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. **Biosystems Engineering**, 132:19-27, 2015.

WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, 38(1):259-269, 1995.

ZHANG, M. *et al.* Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. **Biosystems Engineering**, 189:24-35, 2020.

TERCEIRA PARTE

Artigo elaborado conforme as normas da revista *Precision Agriculture*.

Artigo 2: Monitoramento do nitrogênio foliar de cafeeiros com índices de vegetação e índice de cobertura vegetal de imagens RGB de alta resolução

Taya Cristo Parreiras¹ • Rodrigo Santos Moreira¹ • Guilherme Henrique Exedito Lense¹ • Luis Felipe Pigatto Miranda Silva¹ • Marx Leandro Naves Silva² • Ronaldo Luiz Mincato¹

Resumo

O Nitrogênio é um elemento essencial para o bom desenvolvimento das plantas, mas o uso indiscriminado na agricultura tem gerado impactos ambientais que ameaçam também a saúde humana. Por meio do uso de técnicas do sensoriamento remoto e da fotogrametria, tem sido testada a capacidade de sensores da faixa do visível, multiespectrais e hiperespectrais, embarcados em veículos aéreos não-tripulados, de monitorar o Nitrogênio em diferentes culturas, com o objetivo de colaborar na tomada de decisões relacionadas ao uso de fertilizantes. Portanto, este estudo teve por objetivo verificar o potencial de imagens do espectro visível, obtidas com uma aeronave não tripulada, em monitorar o Nitrogênio foliar em uma lavoura de café. Para isso, foram estabelecidos 4 tratamentos (0, 87,5, 150 e 262 kg N ha⁻¹), e foram realizadas análises foliares laboratoriais, leituras com o clorofilômetro SPAD, e aerolevantamentos entre outubro de 2019 e março 2020. Foram usados índices de vegetação e o índice de cobertura vegetal como variáveis de análise. O teste de correlação de Pearson, modelos de regressão linear e de regressão logística, além da análise de variância, foram executados. Contudo, as variáveis derivadas das imagens não foram eficientes no monitoramento do Nitrogênio, antes ou após a adubação, obtendo correlações não significativas, e modelos de regressão de baixa acurácia. As leituras SPAD, por outro lado, foram eficientes para monitorar o Nitrogênio em janeiro ($R^2 = 0,97$). Apesar disso, as imagens RGB são uma alternativa de baixo custo e os estudos apontam resultados variados, portanto novas pesquisas são necessárias.

Palavras-chave: UAV; RGB; café; SPAD; índices de vegetação; nitrogênio.

Introdução

Devido ao avanço científico que permitiu a redução de Nitrogênio atmosférico (N₂) em sua forma reativa, pelo processo de Harber-Bosch, o suprimento de Nitrogênio (N) na agricultura cresceu exponencialmente a partir da segunda metade do século XX, permitindo o aumento da produtividade, o que gerou desenvolvimento econômico e ajudou a poupar florestas que poderiam ter se tornado terras agrícolas. Atualmente, mais da metade da população mundial se beneficia diretamente de alimentos produzidos com o uso de fertilizantes nitrogenados sintéticos (Zhang *et al.*, 2015).

A má gestão da aplicação dos fertilizantes é, todavia, um dos principais problemas na agricultura, tendo em vista que colabora para a redução da eficiência do uso de nitrogênio (NUE). De maneira geral, as plantas aproveitam cerca de 40-50% do N aplicado, ficando o restante sujeito a perdas pelo escoamento superficial, volatilização, desnitrificação e lixiviação (Vieira, 2017; Chagas *et al.*, 2019).

Os impactos da fertilização nitrogenada, tanto de fertilizantes sintéticos, quanto orgânicos, envolvem a volatilização de amônia (NH₃), a emissão de óxido nitroso (N₂O) para a

atmosfera, e a lixiviação de nitratos (NO_3^-) para os corpos hídricos, ameaçando não somente o equilíbrio ambiental e a qualidade dos recursos naturais, como também a saúde humana (Vieira, 2017; Thompson *et al.*, 2019).

Neste contexto, a agricultura tem o desafio aumentar a produção agrícola para garantir a segurança alimentar e nutricional de uma população mundial em constante crescimento, e ao mesmo tempo responder à necessidade de práticas agrícolas mais sustentáveis e menos lesivas ao ambiente (Thompson *et al.*, 2019; Vieira, 2017).

A agricultura de precisão (PA) e suas ferramentas emergem como resposta à essas demandas, e o sensoriamento remoto (SR), que é uma dessas ferramentas, ajuda na implementação de uma das principais produtos da PA, que é a tecnologia de taxas variáveis, que envolve a aplicação de insumos de acordo com a variabilidade espacial das necessidades (Mozgeris *et al.*, 2018).

O SR envolve, tradicionalmente, o uso de imagens aéreas oriundas de satélite, de veículos aéreos tripulados e, mais recentemente, de sensores acoplados a veículos aéreos não-tripulados (VANT) que, devido às baixas altura de voo, fornecem imagens de alta resolução (escala de cm), flexibilidade para maior frequência de imageamento, baixo custo e também fácil operação (Maes; Steppe, 2018; Radoglou-Grammatikis *et al.*, 2020).

Na agricultura, os VANT têm sido testados em diversas práticas, tais como planejamento de plantio, irrigação e aplicação de insumos, intervenções no terreno, detecção de doenças e pragas, monitoramento do crescimento e desenvolvimento, estimativas de biomassa e erosão, e um dos principais desafios é o monitoramento do nitrogênio (Maes; Steppe, 2018; Radoglou-Grammatikis *et al.*, 2020).

Este, por sua vez, tem sido testado para diversas culturas, tais como trigo (Mozgeris *et al.*, 2018), cevada (Escalante *et al.*, 2019), citrus (Osco *et al.*, 2019), milho (Corti *et al.*, 2018), girassol (Vega *et al.*, 2015), batatas (Hunt Jr. *et al.*, 2018), entre outras, com sensores do espectro visível (Garza *et al.*, 2020), multiespectrais (Geipel *et al.*, 2016), hiperespectrais (Wen *et al.*, 2018), por meio do uso de índices de vegetação (VI) (Schirrmann *et al.*, 2016), modelos tridimensionais do dossel (Näsi *et al.*, 2018), e com técnicas de análise diversas, como por exemplo o uso diversos algoritmos de aprendizado de máquina (Zheng *et al.*, 2018; Escalante *et al.*, 2019; Osco *et al.* 2019).

Neste contexto, este estudo tem por objetivo verificar o potencial de imagens do espectro visível (RGB) de alta resolução, obtidas com UAV, no monitoramento do nitrogênio (N) foliar de cafeeiros em sistema de cultivo orgânico, em comparação com o tradicional método de leituras do clorofilômetro SPAD (Soil Plant Analysis Development).

Para isso, foram usados 4 diferentes tratamentos de fertilização (0, 87,5, 175 e 262 kg N ha⁻¹), em 4 repetições (16 parcelas), e foram testadas duas abordagens: a relação dos índices vegetação (VI) e do índice de cobertura foliar (VCI) com os 4 tratamentos, com o teor de N foliar (g kg⁻¹), e também com o *status* nutricional (nível de N baixo ou normal). Como métodos de análise foram usados modelos de regressão linear e logística, coeficiente de correlação de Pearson, além da análise de variância (ANOVA) e teste de Kruskal-Wallis, com seus respectivos *post-hoc*, teste Tukey e teste Dunn.

Material e Métodos

Descrição da área de estudo

A área de estudo está localizada na Fazenda Santo André, Município de Divisa Nova, região sul do Estado de Minas Gerais (Figura 1). Trata-se de parte de um talhão com cultivo orgânico de café arábica, da variedade Catuaí Vermelho, com área total de 0,23 ha. Os cafeeiros

dessa área foram plantados em 2006, em espaçamento de 3,5 m x 0,65 m e, atualmente, se encontram em transição para cultivo orgânico.

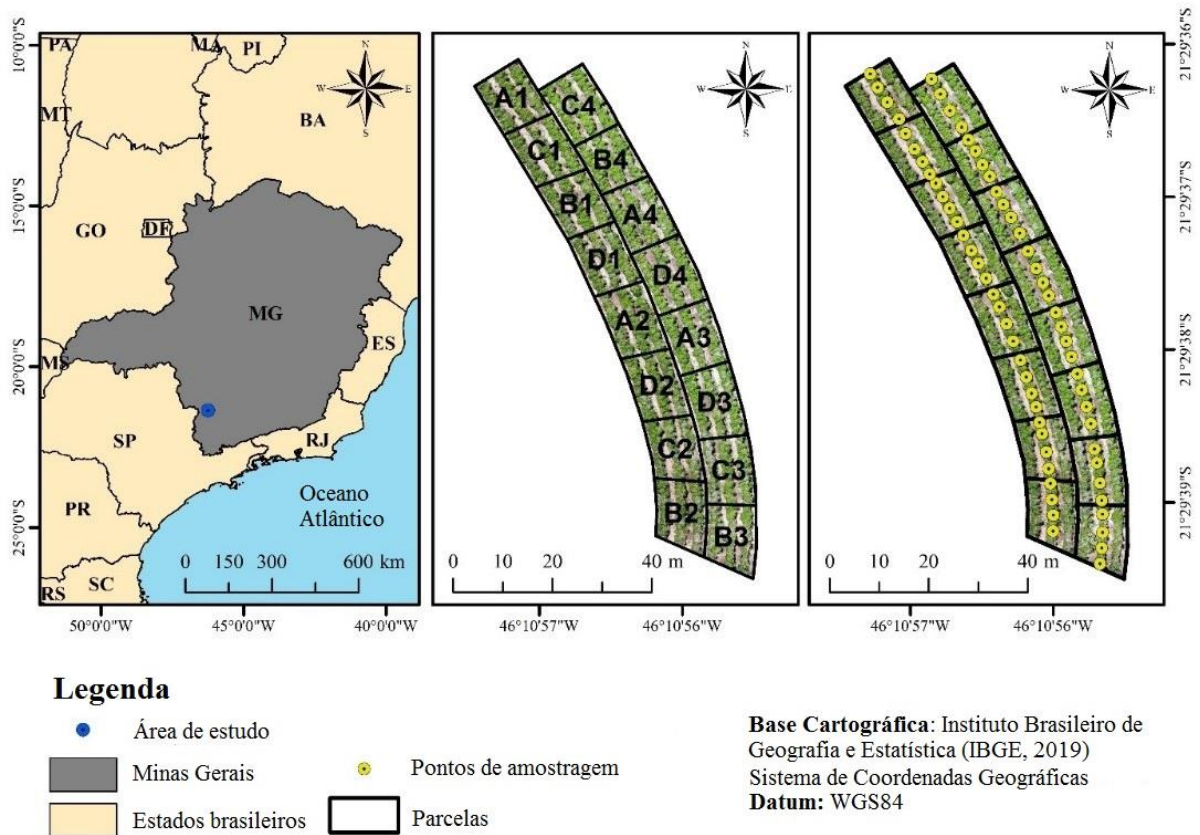


Fig. 1 Localização da área de estudo em relação ao território brasileiro, parcelas de estudo e pontos de amostragem.

O clima da área é do tipo *Cwb*, de acordo com a classificação de Köppen, caracterizado por invernos secos, e verões úmidos e temperados (Alvares, 2013), sendo que a temperatura média anual da região é 20° C, e o volume médio de precipitação anual é de 1520 mm, com um período chuvoso concentrado entre outubro e março (INMET, 2020). A altitude na fazenda varia entre 820 e 900 m, e o solo dominante é o Latossolo Vermelho distrófico (LVd) (Santos *et al.*, 2010).

Delineamento experimental e adubação

O delineamento experimental selecionado foi de blocos casualizados, com 4 tratamentos divididos em 4 blocos de repetições, totalizando 16 parcelas experimentais que são mostradas na Figura 1. Cada parcela possui 60 plantas de café, sendo 20 em cada linha de plantio. Foram aplicadas, em novembro de 2019, 4 doses (0, 87,5, 175 e 262 kg N ha⁻¹) de um composto orgânico formado por esterco bovino, palha de café e pó de rocha. Antes da adubação, foi realizado o processo de calagem. A dose de 175 kg N ha⁻¹ foi estabelecida como dose ideal, conforme Guimarães *et al.* (1999), considerando a produtividade esperada (entre 20 e 30 sacas ha⁻¹), e as demais foram calculadas como taxas de 0, 50 e 150% da dose recomendada (Tabela 1).

Tabela 1 Tratamentos e doses de aplicação do adubo por planta.

Tratamento	Dose (%)	Aplicação (kg/ha ⁻¹)	Dose por planta (kg)
A	0	0	0
B	50	87,5	1,15
C	100	175	2,3
D	150	262	3,6

Inicialmente, para determinar a quantidade de composto a ser aplicada por cafeeiro, foi realizada uma análise de determinação do teor N do composto, na base seca, com uma triplicata do método Kjeldahl (AOAC, 1995). As amostras do composto foram retiradas de diferentes pontos da leira usada na adubação. Em seguida, considerou-se o espaçamento de 3,5 x 0,65 m, para calcular a densidade, ou seja, número de plantas por hectare, o que foi feito a partir da Equação 1.

$$\text{Densidade} = 10.000 \text{ m}^2 \div (3,5 \times 0,65) \quad (1)$$

Determinação do teor de nitrogênio foliar e dos valores SPAD

Para determinar o teor do N foliar, em outubro de 2019 (pré-adubação) e em janeiro de 2020 (55 dias pós-adubação), pela manhã, foram coletadas 8 folhas bem desenvolvidas por cafeeiro, 4 do lado leste, e 4 do oeste, de 5 em 5 plantas das linhas centrais, totalizando 32 folhas e 4 plantas amostrados por parcela. Os pontos de coleta também são mostrados na Figura 1. As folhas foram coletadas do terceiro ou quarto par de nós dos ramos plagiotrópicos, do terço médio das plantas, e estavam com aspecto sadio, sem sinal de infestação por pragas ou doenças.

Após a coleta, as folhas foram armazenadas em sacos de papel, lavadas com água e detergente líquido neutro, secas em estufa de circulação de ar forçada a 65° C até atingir massa constante. Em seguida, foram moídas em moinho rotor, e por fim, as amostras passaram pelo processo de determinação de N (g kg⁻¹) pelo método Kjeldahl, no qual a proteína bruta foi calculada como N x 6,25 a partir de 3 fases: digestão, destilação e titulação (AOAC, 1995).

Nos mesmos dias de coleta e nas mesmas folhas amostradas, foi usado o clorofilômetro SPAD 502 (Konica Minolta, Osaka, Japão), de uso comum na agricultura (França; Carvalho, 2016; Reis *et al.*, 2009), que mede a absorção de luz nas regiões *Red* e *Near-Infrared* do espectro eletromagnético, indicando o teor de clorofila. Foram realizadas leituras na parte central do limbo das 32 folhas de cada parcela, imediatamente após a remoção, sendo registrado o valor médio por planta, e em seguida, o valor médio por parcela.

Aquisição e processamento das imagens aéreas

A aeronave utilizada no estudo foi a quadricóptero modelo DJI Phantom 4 *Advanced*, que possui um sensor 1"CMOS de 20 Megapixels, e que capta imagens RGB. A aeronave opera com dois sistemas de navegação: um Global Positioning System (GPS) e um Global Navigation

Satellite System (GLONASS), resultando em imagens georreferenciadas, de alta resolução espacial, com *Ground Sample Distance* (GSD) médio inferior a 0,02 m por pixel, dependendo da altura de voo.

Foram realizadas 3 missões: 17 de outubro de 2019, 21 de janeiro e 06 de março de 2020, sendo possível assim, monitorar os cafeeiros desde a florada, até a fase de granação dos frutos. Todos os voos foram realizados entre às 10:00 a.m. e 12:00 p.m., com o objetivo de evitar, ao máximo, presença de sombras. A Figura 2 mostra um esquema da realização dos voos e da adubação, além da temperatura média e precipitação acumulada de cada mês, em relação às fases fenológicas de cafeeiros arábicas no segundo ano fenológico, de acordo com Camargo e Camargo (2001).




Fig. 2 Cronograma missões e da adubação, precipitação acumulada e temperatura média de setembro a março, em relação às fases fenológicas segundo Camargo e Camargo (2001).

Todos os voos foram planejados com o aplicativo gratuito Pix4D *Capture* (Prilly, Suíça), no qual foram definidos parâmetros como a altura de voo (50 m), sobreposições lateral e frontal (80/80%), velocidade da aeronave (baixa), além das linhas de passagem da aeronave. As resoluções (GSD) obtidas com os voos foram: 0,012 m $pixel^{-1}$ (outubro), 0,015 m $pixel^{-1}$ (janeiro) e 0,013 m $pixel^{-1}$ (março).

Após cada missão, as imagens geradas nos aerolevanteamentos foram inspecionadas, a fim de encontrar e eliminar possíveis erros ou ruídos que pudessem comprometer o processamento. Em seguida, foram inseridas no software Pix4D versão Discovery 4.3.33 (Prilly, Suíça) para a geração dos ortomosaicos e dos modelos digitais de superfície (DSM), que contém a elevação dos objetos em campo. Uma vez gerados, os ortomosaicos referentes a janeiro e março foram georreferenciados com base no de outubro por meio de elementos fixos e coincidentes na área.

Usando a ferramenta *Raster Calculator*, do software QGIS 3.8.3 (QGIS Development Team, Open Source Geospatial Foundation), os ortomosaicos foram processados para a geração dos mapas espectrais individuais em *Red*, *Green* e *Blue*. Após a separação, usando a mesma ferramenta, foi realizada a normalização das bandas para obtenção dos níveis cromáticos, a partir Equação 2 (Arroyo; Guijarro; Pajares, 2016).

$$\frac{\text{Red}}{\text{Red+Green+Blue}}, \frac{\text{Green}}{\text{Red+Green+Blue}} \text{ and } \frac{\text{Blue}}{\text{Red+Green+Blue}} \quad (2)$$

Uma vez normalizadas, as bandas *Red*, *Green* e *Blue* foram usadas para gerar os índices de vegetação (IV), processo que foi feito usando a ferramenta *Raster Calculator* do software ArcGIS 10.5 (ESRI, Redlands, California, EUA), na qual foram inseridas as equações correspondentes a cada índice (Tabela 2).

Tabela 2 Índices de Vegetação usados no estudo, siglas, equações e fontes.

Índice de Vegetação	Sigla	Equação	Fonte
<i>Green Leaf Index</i>	GLI	$\frac{2 * G - R - B}{2 * G + R + B}$	Louhaichi <i>et al.</i> (2001)
<i>Excess Green</i>	EXG	$2 * G - R - B$	Wöbbecke <i>et al.</i> (1995)
<i>Normalized Green Red Difference</i>	NGRDI	$\frac{G - R}{G + R}$	Tucker (1979)
<i>Visible Atmospherically Resistant Index</i>	VARI	$\frac{G - R}{G + R - B}$	Gitelson <i>et al.</i> (2002)
<i>Color Index of Vegetation</i>	CIVE	$0.441R - 0.881G + 0.385B + 18.78745$	Kataoka <i>et al.</i> (2003)
<i>Soil-Adjusted Vegetation Index</i>	SAVI	$\frac{1.5 * (G - R)}{(G + R + 0.5)}$	Huete (1988)

Com o objetivo de direcionar a análise e a extração dos valores dos IV para as áreas de interesse, que são as linhas de plantio ocupadas pelos cafeeiros, os mosaicos georreferenciados RGB de cada missão foram usados como base para gerar, manualmente, polígonos no entorno das plantas, evitando a vegetação espontânea e o solo exposto. Em seguida, estes polígonos foram usados como “máscaras” para o recorte dos IV.

Uma vez recortados, foi realizado um processo de classificação supervisionada dos mosaicos RGB, com o objetivo de remover *pixels* referentes às sombras e galhos secos presentes na parte superior de alguns cafeeiros nas três missões. Para tanto, foram coletadas 50 amostras referentes à cada classe de interesse: sombras, galhos secos e folhas, sendo esta última, a classe alvo.

A classificação foi realizada com o algoritmo *Maximum Likelihood Classification* (MLC), que determina, pela análise *pixel a pixel*, a probabilidade de um pixel *i* pertencer a uma classe *x*, e realizando as classificações de acordo com a maior probabilidade (Ahmand; Qegan, 2012).

O mapa resultante do processo de classificação, em formato matricial, foi transformado em polígonos, formato vetorial, e as áreas referentes apenas às folhas de café foram selecionadas e usadas para recorte dos IV. Em seguida, foi calculado o valor médio de cada índice, em cada parcela, para as três missões. Todos os processos descritos nesta subseção foram executados usando ferramentas do ArcGIS 10.5 (ESRI, Redlands, California, EUA).

Índice de Cobertura Vegetal

A cobertura vegetal está diretamente ligada à proteção do solo contra o impacto das gotas da chuva, que causam a erosão, além de indicar o potencial de rendimento das culturas, uma vez que a área foliar é um importante indicador do potencial fotossintético das plantas. Assim, o monitoramento da cobertura vegetal pode ser útil no acompanhamento do crescimento

e desenvolvimento das lavouras (Torrez-Sánchez *et al.*, 2014; Unigarro-Muñoz *et al.*, 2015; Beniaich *et al.*, 2019).

Para tanto, os polígonos criados para delimitar a área ocupada pelos cafeeiros nas três missões foram usados também para calcular o Índice de Cobertura Vegetal (ICV) do café em cada parcela do estudo. A área ocupada pelas plantas foi calculada em m², e, em seguida, foi usada a Equação 3 para calcular o ICV.

$$\text{ICV} = \frac{\text{Área de café (m}^2\text{)}}{\text{Área da parcela (m}^2\text{)}} \quad (3)$$

Análise de dados

Inicialmente foi realizada a análise exploratória dos dados (valores mínimos, máximos, médios e desvio-padrão) referentes aos teores de N foliar (g kg⁻¹), valores SPAD e índice de cobertura vegetal (ICV) de outubro e janeiro. Em seguida, todas as variáveis do estudo foram submetidas ao teste de normalidade de Shapiro-Wilk.

O efeito das diferentes doses de adubação no teor de N foliar, nos valores SPAD e no ICV foi avaliado por modelos de regressão linear. Para verificar como os VI se relacionam com o teor de N foliar em outubro e janeiro, foram construídas matrizes de correlação, a partir do teste de correlação de Pearson. Além disso, em janeiro, os VI foram submetidos a modelos de regressão logística para detecção do teor de N foliar, como baixo (< 28,8 g N kg⁻¹) ou normal (> 28,8 g N kg⁻¹), de acordo com Guimarães *et al.* (1999).

Para avaliar a performance dos modelos de regressão logística, foram consideradas as seguintes métricas: coeficiente de concordância de Kappa (k), acurácia (Equação 4), sensibilidade (Equação 5) e especificidade (Equação 6).

$$\text{Acurácia} = \frac{\text{Vp} + \text{Vn}}{\text{Total (p+n)}} \quad (4)$$

$$\text{Sensibilidade} = \frac{\text{Vp}}{\text{Total p}} \quad (5)$$

$$\text{Especificidade} = \frac{\text{Vn}}{\text{Total n}} \quad (6)$$

Em que: Vp (verdadeiro positivo); Vn (verdadeiro negativo); p (positivo); n (negativo).

Os teores de N foliar (g kg⁻¹) obtidos com as análises de janeiro, bem como os VI de janeiro e março, que apresentaram distribuição normal, foram submetidos à análise de variância (ANOVA) das médias em relação aos tratamentos (A, B, C e D), e ao Teste Tukey. Os VI que não apresentaram distribuição normal no teste de Shapiro-Wilk, foram analisados pelo teste não-paramétrico de Kruskal-Wallis, e teste *post-hoc* de Dunn com método Bonferroni de ajuste do valor de *p*.

O coeficiente de correlação de Pearson (R) e o coeficiente de determinação do modelo de regressão linear (R²) também foram calculados para verificar como se relacionam o ICV e o teor de N foliar em outubro, e o percentual de crescimento da cobertura vegetal, entre outubro e janeiro, em relação aos 4 tratamentos e ao teor de N foliar de janeiro.

As análises estatísticas e a construção dos gráficos foram desenvolvidas nos softwares R (R Core Team, Viena, Áustria) e Microsoft Excel 2016 (Microsoft, Redmond, EUA).

Resultados

Nitrogênio Foliar e valores SPAD

As análises exploratórias das variáveis N (g kg^{-1}), dos valores SPAD e do ICV referentes a outubro e janeiro, para cada tratamento (A, B, C e D), estão descritas nas Tabela 2 e 3.

Tabela 2 Estatísticas descritivas das variáveis Nitrogênio (g kg^{-1}), valores SPAD e Índice de Cobertura Vegetal (ICV) referentes a outubro.

Tratamento	Estatística	N (g kg^{-1})	Valores SPAD	ICV
A	Mínimo	25,6	49,7	0,57
	Máximo	27,1	54,3	0,64
	Média	26,4	52,5	0,62
	Desvio Padrão	0,74	2,00	0,03
B	Mínimo	26,2	53,3	0,59
	Máximo	29,0	57,8	0,64
	Média	27,3	65,3	0,62
	Desvio Padrão	1,20	5,49	0,02
C	Mínimo	25,7	64,2	0,47
	Máximo	29,2	54,9	0,61
	Média	27,1	58,8	0,57
	Desvio Padrão	1,49	3,89	0,07
D	Mínimo	23,6	53,0	0,57
	Máximo	26,9	57,4	0,63
	Média	25,2	55,4	0,60
	Desvio Padrão	1,74	2,08	0,03

Tabela 3 Estatísticas descritivas das variáveis Nitrogênio (g kg^{-1}), valores SPAD e Índice de Cobertura Vegetal (ICV) referentes a janeiro.

Tratamento	Estatística	N (g kg^{-1})	Valores SPAD	ICV
A	Mínimo	23,3	51,8	0,67
	Máximo	31,1	53,3	0,75
	Média	26,0	52,3	0,70
	Desvio Padrão	3,65	0,66	0,05
B	Mínimo	24,8	50,30	0,66
	Máximo	25,0	55,80	0,77

	Média	27,2	53,40	0,71
	Desvio Padrão	3,21	2,57	0,05
	Mínimo	26,8	52,3	0,61
	Máximo	31,5	58,6	0,72
C	Média	28,6	55,7	0,67
	Desvio Padrão	2,23	2,64	0,05
	Mínimo	26,6	52	0,68
	Máximo	32,3	57,8	0,70
D	Média	28,3	55	0,69
	Desvio Padrão	2,67	2,61	0,01

Em janeiro, as médias do N foliar (g kg^{-1}) foram mais baixas para os tratamentos de menor fertilização, A e B ($26,2$ e $27,2 \text{ g kg}^{-1}$), e mais altas para C e D ($28,6$ e $28,3 \text{ g kg}^{-1}$), sendo que C obteve média superior a D. Isso indica que a adubação extra do tratamento D, que representa 150 % do recomendado, não resultou em maiores teores de N foliar.

Apesar da segunda amostragem foliar ter sido realizada 55 dias após a adubação, apenas 5 parcelas apresentaram teores de N considerados normais ($> 28,8 \text{ g kg}^{-1}$) (Figura 3). Além disso, o bloco 4, com as repetições A4, B4, C4 e D4, apresentou $\text{N} > 31 \text{ g kg}^{-1}$ nas 4 parcelas.

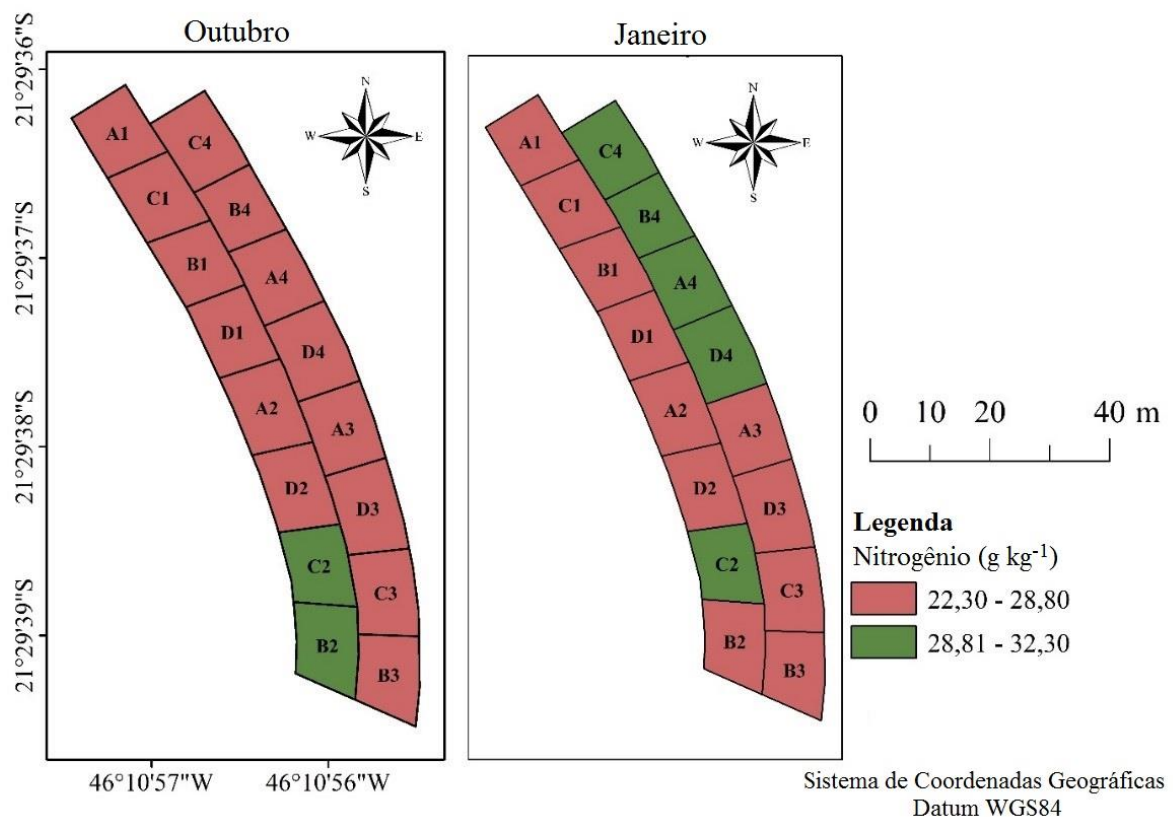


Fig. 2 Distribuição do status de N foliar (g kg^{-1}) entre as parcelas de estudo em outubro e janeiro, em que $\text{N} < 28,80$ (baixo), e $\text{N} > 28,80 \text{ g kg}^{-1}$ (normal)

O estado de deficiência nas parcelas, que era esperado para os tratamentos A e B, também permaneceu para 3 parcelas do grupo C, e 2 do grupo D, o que pode ter afetado o resultado a análise de variância (ANOVA), uma vez que o teste não apontou diferença significativa entre as médias em nenhum par de tratamentos ($p\text{-value} = 0,614$). Portanto, não foi necessário realizar o Teste Tukey para determinar entre quais tratamentos haveria essa diferença.

Uma das hipóteses para explicar a deficiência neste período é a natureza do fertilizante que, sendo um composto orgânico, depende da sua decomposição para a liberação dos nutrientes, e esta é influenciada por fatores climáticos e edáficos, pela composição do adubo, pela relação carbono-nitrogênio (C:N) e também pela microbiota do solo, o que pode retardar a liberação dos nutrientes presentes no composto (Gama-Rodrigues *et al.*, 2007; Santos *et al.*, 2008). Apesar disso, as diferenças nos tratamentos afetaram, de maneira geral, os teores médios de N nas folhas em janeiro, como é mostrado na Figura 4.




Fig. 4 Teor médio de N foliar (g kg^{-1}) em relação às doses de N na adubação (0, 87,5, 175 e 262 kg N ha^{-1}).

No que diz respeito aos valores SPAD, em outubro, as leituras do clorofilômetro não se relacionaram com o teor de N foliar. O teste de correlação de Pearson, considerando os valores individuais de cada uma das 16 parcelas, mostrou a inexistência de correlação significativa ($R = 0,07$). O modelo linear construído com os valores médios de SPAD e N (g kg^{-1}) nos quatro blocos de repetição, nos quais seriam aplicados os tratamentos em novembro, obteve um R^2 de 0,27, ou seja, os valores SPAD e o N foliar não se relacionaram em outubro.

Em janeiro de 2020, por outro lado, os valores SPAD se relacionaram fortemente, tanto com as diferentes doses de fertilizante aplicadas ($R^2 = 0,75$), quanto com o teor de N foliar médio de cada tratamento ($R^2 = 0,97$) nos 4 blocos, como é mostrado na Figura 4.

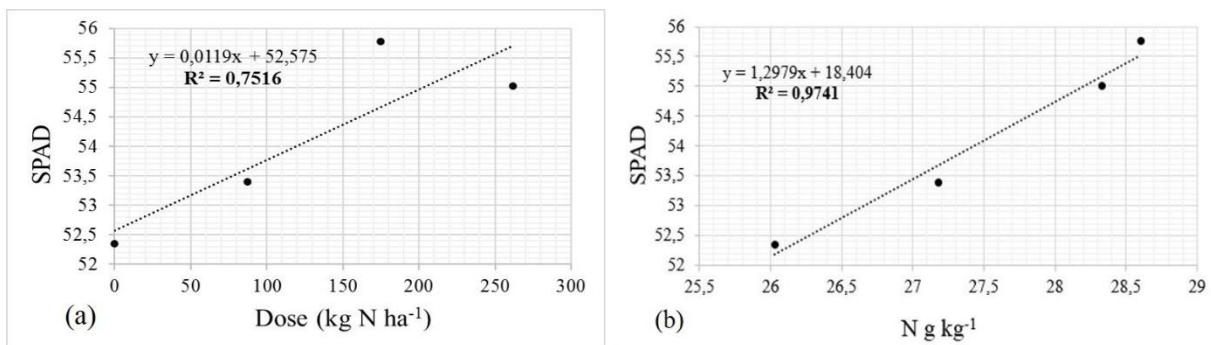


Fig. 4 a Valores SPAD em função dos tratamentos (0, 87,5, 175 e 262 kg N ha⁻¹); **b** Valores SPAD em função do teor médio de N foliar (g kg⁻¹).

Esses resultados reforçam o potencial dessa ferramenta no monitoramento do N na agricultura, sendo importante, entretanto, atentar aos períodos de amostragem, relacionados às diferentes fases das culturas. Reis *et al.* (2009), por exemplo, em estudo realizado com cafeeiros da variedade Catuaí vermelho, obtiveram coeficientes de determinação (R^2) entre 0,70 e 0,97, dos meses de novembro a março, tanto em ano de alta, como em ano de baixa produtividade, e em diferentes formas de aplicação de fertilizante que totalizavam 15 tratamentos.

Por outro lado, Garza *et al.* (2020) não encontraram correlação significativa entre as leituras SPAD e o teor de N foliar na cultura de citros, amostradas em abril (primavera nos EUA, onde a pesquisa foi conduzida), e questionaram a capacidade do clorofilômetro ser um bom indicador quando há infestação por doenças. Schirrmann *et al.* (2016), em estudo com o trigo de inverno, obtiveram as maiores correlações entre o teor de clorofila e o teor de N próximo do período de florada, e menores correlações com o avanço da senescência da cultura, uma vez que o N é mobilizado pelas plantas para o desenvolvimento dos grãos.

Índices de Vegetação

Os valores IV, como era esperado, aumentaram ao longo do tempo, tendo em vista o avanço do crescimento vegetativo da cultura entre outubro e janeiro, com exceção do CIVE, cujo comportamento é oposto, já que é um índice que realça a banda vermelha, portanto, tende a diminuir conforme aumenta o vigor vegetativo.

Todavia, apesar desse aumento, em janeiro, a ANOVA dos IV que apresentaram distribuição normal (NGRDI, SAVI e VARI) não apontou variação significativa entre as médias dos tratamentos (p -value de 0,49, 0,77 e 0,40, respectivamente).

No que diz respeito aos índices EXG, GLI e NGRDI, que não apresentaram distribuição normal, foi realizado o teste Kruskal-Wallis, que verifica se a mediana da variável independente difere significativamente entre os grupos. Os três índices obtiveram, neste teste, $p < 0,05$, sendo 0,036 (EXG e CIVE), e 0,046 (GLI). Portanto, foi realizado então o teste *post-hoc* de Dunn, para análise entre pares. O Teste de Dunn, entretanto, também não indicou diferenças significativas entre os tratamentos em nenhum dos três IV, sendo todos os $p > 0,05$. O comportamento dos IV em relação aos tratamentos, em janeiro, é mostrado na Figura 5.

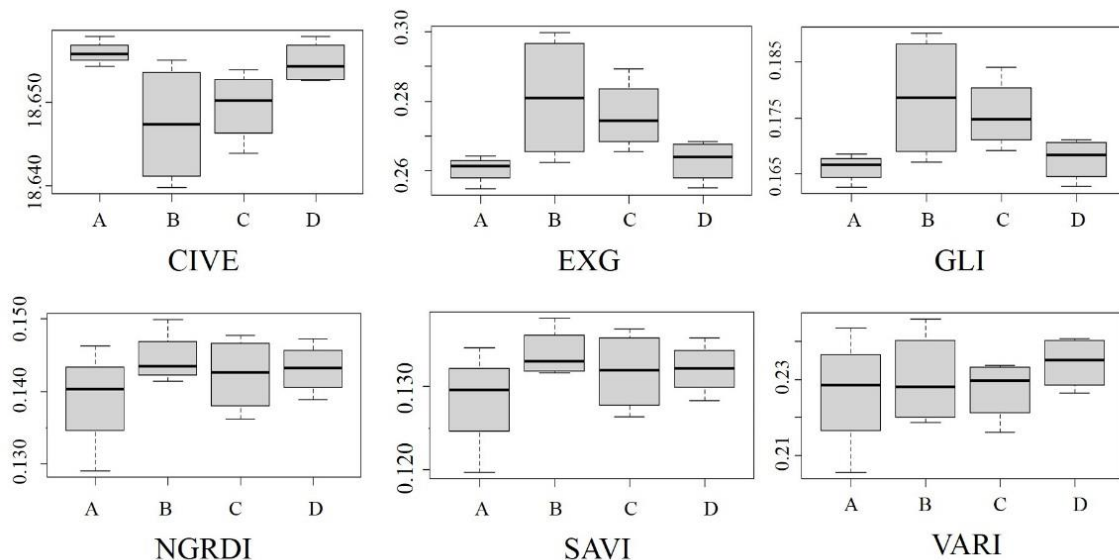


Fig. 5 Boxplots com a variação dos índices de vegetação entre as parcelas de estudo em janeiro. Em que: CIVE (*Color Index of Vegetation*) EXG (*Excess Green*), GLI (*Green Leaf Index*), NGRDI (*Normalized Green Red Difference Index*), SAVI (*Soil-Adjusted Vegetation Index*), e VARI (*Visible Atmosphericly Resistant Index*).

Em março de 2020, a ANOVA apontou a existência de diferença significativa entre as médias apenas nos índices EXG e GLI (p -value de 0,015 e 0,016, respectivamente). O teste Tukey, por sua vez, mostrou que essa variação estava, em ambos índices, apenas entre os tratamentos A e B, com p -value de 0,009 no EXG, e 0,01 no GLI. Essa diferença, que pode ser visualizada nos *boxplots* da Figura 6, não tem potencial para o monitoramento do N, uma vez que ambos os tratamentos correspondem a áreas de deficiência, e o objetivo seria a identificação do contraste entre o estado nutricional das plantas.




Fig. 6 Boxplots com a variação dos índices de vegetação entre as parcelas de estudo em março. Em que: CIVE (*Color Index of Vegetation*), EXG (*Excess Green*), GLI (*Green Leaf Index*), NGRDI (*Normalized Green Red Difference Index*), SAVI (*Soil-Adjusted Vegetation Index*), e VARI (*Visible Atmosphericly Resistant Index*).

Os testes de correlação de Pearson, realizados com os valores individuais de cada parcela para os meses de outubro e janeiro, mostraram que alguns IV possuem correlação negativa com o N foliar em outubro, e positiva em janeiro. Mas de forma geral, as correlações são baixas ou não significativas, como mostra a Tabela 4. Como não foi realizada amostragem foliar em março, não foi construída uma matriz para esta missão.

Tabela 4 Matrizes de correlação de Pearson entre o Nitrogênio foliar (g kg^{-1}), os valores SPAD, e os índices de vegetação, em outubro de 2019 e janeiro de 2020.

Missão	Variáveis	N(g/kg)	CIVE	EXG	GLI	NGRDI	SAVI	VARI	SPAD
Outubro	N(g/kg)	1							
	CIVE	0,41	1						
	EXG	-0,40	-0,99**	1					
	GLI	-0,32	-0,44	0,45	1				

Janeiro	NGRDI	-0,50*	-0,93**	0,92**	0,30	1			
	SAVI	-0,49*	-0,93**	0,93**	0,30	0,99**	1		
	VARI	-0,51*	-0,90**	0,89**	0,27	0,99**	0,99**	1	
	SPAD	0,07	0,48	-0,48	0,06	-0,45	-0,45	-0,44	1
	N(g/kg)	1							
	CIVE	0,06	1						
	EXG	-0,07	-0,99	1					
	GLI	-0,07	-0,99**	0,99**	1				
	NGRDI	0,39	-0,24	0,20	0,20	1			
	SAVI	0,37	-0,33	0,29	0,29		1		
	VARI	0,41	0,25	-0,29	-0,29	0,88**	0,83**	1	
	SPAD	0,69**	-0,31	0,30	0,31	0,54	0,52	0,34	1

*Significativo ($p < 0.05$); ** Significativo ($p < 0.01$). Em que: CIVE (Color Vegetation Index), EXG (Excess Green), GLI (Green Leaf Index), NGRDI (Normalized Green Red Difference Index), SAVI (Soil-Adjusted Vegetation Index), e VARI (Visible Atmospherically Resistant Index).

Observa-se que, quando o teste de correlação foi realizado entre parcela x parcela, e não somente com os valores médios dos tratamentos, a correlação entre o N foliar e os valores SPAD é relativamente menor ($R = 0,68$), contudo, ainda é altamente significativa ($p < 0,01$).

Com a missão de outubro, o objetivo seria encontrar uma ou mais variáveis que se correlacionassem com o N foliar, para então gerar modelos preditivos úteis no planejamento da adubação. As melhores correlações significativas obtidas, entretanto, foram baixas e negativas, com os índices VARI, NGRDI e SAVI, respectivamente. Em janeiro, os IV também não se relacionaram significativamente com o N.

Tendo em vista as recomendações de parcelamento das adubações em cafeeiros (Guimarães *et al.*, 1999), a detecção de deficiência ou normalidade, ainda em janeiro, colaboraria com a tomada de decisão em relação ao restante das aplicações. Todavia os modelos de regressão logística, construídos com cada VI, individualmente, bem como com a combinação dos 6 índices testados no estudo, também não foram assertivos em detectar o status de N como baixo ou normal. Os resultados e a visualização dos modelos regressão logística para são mostrados na Tabela 5 e na Figura 7.

Tabela 5 Resultado dos modelos de regressão logística entre cada índice de vegetação referente ao mês de janeiro e o status do N foliar (sendo baixo, se $< 28,8 \text{ g kg}^{-1}$, ou normal, se $> 28,8 \text{ g kg}^{-1}$), e do modelo que combina todos os índices de vegetação (IV).

Índice de Vegetação	Acurácia	Kappa	Sensitividade	Especificidade
CIVE	0,56	-0,04	0,39	0,56
EXG	0,63	-0,017	0,41	0,63
GLI	0,56	-0,03	0,41	0,56
NGRDI	0,60	0,025	0,41	0,6
SAVI	0,58	0,015	0,44	0,58
VARI	0,43	-0,03	0,52	0,43

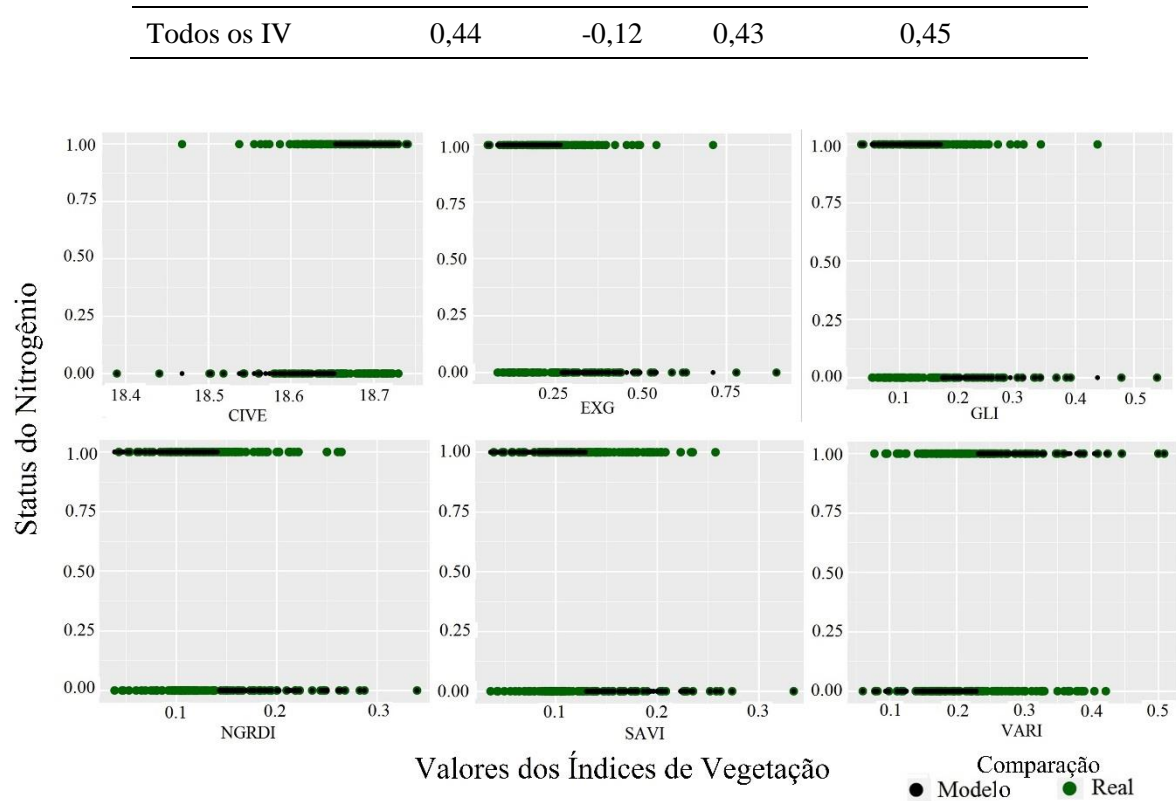


Fig. 7 Modelos de Regress o Log stica com os  ndices de vegeta o e o status do Nitrog nio (0 = deficiente e 1 = normal). A sobreposi o de pontos pretos e verdes indicam acertos do modelo, enquanto pontos verdes representam erros de classifica o.

Embora os modelos tenham atingido acur cia, sensibilidade e especificidade acima 0,5, o coeficiente de Kappa mostrou que n o houve nenhum n vel de concord ncia entre as classifica es e o real status do N nos pontos amostrados (McHugh, 2012).

 ndice de Cobertura Vegetal

De forma geral, todas as parcelas apresentaram crescimento m dio da cobertura vegetal de 15, 85% entre outubro e janeiro, e entre janeiro e mar o, uma queda m dia de 2,17%. Essa redu o foliar entre janeiro e mar o, ainda que baixa, era esperada, tendo em vista o avan o do per odo de desenvolvimento dos frutos, al m de que as temperaturas, m dias e m nimas, decrescem entre janeiro e mar o, e estes s o os principais fatores de restri o do crescimento vegetativo para cafeeiros (Amaral *et al.*, 2006). A Figura 8 mostra a varia o do  ndice de Cobertura Vegetal (ICV), por parcela, nos tr s meses do estudo, e a Figura 9 mostra a delimita o manual das linhas ocupadas pelas plantas nos tr s meses de estudo.




Fig. 8 Índice de cobertura vegetal (VCI), por parcela, em outubro de 2019, e janeiro e março 2020.

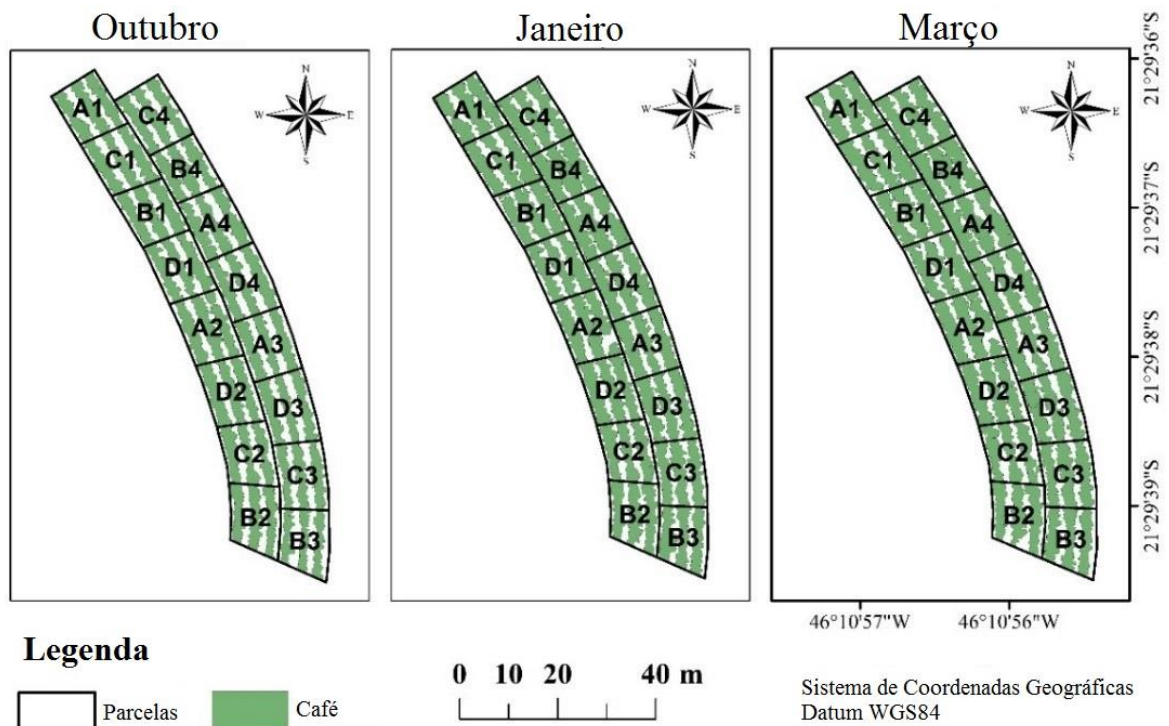


Fig. 9 Mapa de ocupação das plantas de café nos três meses de estudo.

Em outubro, não houve correlação significativa entre o ICV médio de cada um dos 4 blocos onde seriam aplicados os tratamentos (blocos 1, 2, 3 e 4), e o N foliar médio obtido com as análises ($R^2 = 0,09$) e, dessa forma, não se mostrou relevante para a tomada de decisão em relação à adubação.

Embora a taxa de crescimento do ICV entre outubro e janeiro tenha se relacionado diretamente com as doses dos tratamentos ($R^2 = 0,76$), o mesmo não ocorreu com o crescimento entre outubro e março ($R^2 = 0,20$). Além disso, análise de variância (ANOVA) que foi realizada com a porcentagem de crescimento, em relação aos tratamentos, mostrou que as diferenças entre as médias dos tratamentos não foram estatisticamente significativas ($p = 0,75$). O mesmo resultado foi obtido com o Teste de Kruskal-Wallis para o crescimento entre outubro e março ($p = 0,96$).

Discussão

De acordo com Clemente *et al.* (2013), a disponibilidade N adequada às necessidades das plantas proporciona maior ramificação de ramos plagiotrópicos, além de maior área foliar e produção de amidos e carboidratos que são necessários para o adequado desenvolvimento dos frutos. Contudo, em doses excessivas, pode haver queda da produção pelo aumento do crescimento vegetativo, gerando autosombreamento excessivo, reduzindo a eficiência fotossintética do cafeeiro.

O Nitrogênio é o elemento mais requisitado para o crescimento vegetativo de cafeeiros, e o segundo mais requisitado para o desenvolvimento dos grãos. Todavia, o crescimento e o desenvolvimento dos cafeeiros não pode ser explicado apenas pelo teor de N, uma vez que outros fatores como as variações de precipitação, temperatura, fotoperíodo, frutificação, relação de N com outros nutrientes como Fósforo (P) e Potássio (K) e orientação das linhas de plantio para obtenção da melhor interceptação da radiação fotossinteticamente ativa também são importantes (Amaral *et al.*, 2006; Clemente *et al.*, 2013).

Na literatura publicada há apenas um estudo envolvendo o uso de sensor RGB embarcado em UAV para monitorar o N em lavouras de café (Parreiras *et al.*, 2020) e, embora realizado em uma fase fenológica diferente e em uma área sem a diferenciação de tratamentos, os resultados também não foram promissores. Chemura *et al.* (2018) obtiveram melhores resultados usando imagens multiespectrais de satélite, embora tal metodologia seja melhor aplicável para áreas maiores.

Há, entretanto, outros estudos que foram realizados envolvendo a estimativa de parâmetros biofísicos como altura e diâmetro (Santos *et al.*, 2020), e volume do dossel (Cunha; Sirqueira Neto; Hurtado, 2019) de cafeeiros. Dessa forma, dadas as particularidades e complexidades que são próprias dessa planta, juntamente com o fato de que os estudos ainda são poucos, ainda serão necessárias mais pesquisas para determinar como de fato esta tecnologia pode ser útil para colaborar com a sustentabilidade da cafeicultura.

No que diz respeito aos valores SPAD, estes não se correlacionaram de forma significativa com nenhum IV do estudo, nem antes, nem após a adubação. Garza *et al.* (2020) também não encontraram correlação significativa entre os valores SPAD e o Triangular Vegetation Index (TGI) baseado em imagens RGB, em estudo com citrus. Contudo, Hunt Jr. *et al.* (2013) mostraram que o TGI possui alta performance no monitoramento da clorofila em lavoura de milho e Saberioon *et al.* (2014) encontraram correlações altamente significativas entre os valores SPAD e alguns IV do espectro visível na cultura do arroz. Dessa forma, entende-se que mais estudos são necessários para avaliar os efeitos do tipo de cultura, condições de voo, tipo de IV, bem como de outros fatores biofísicos nos resultados.

Alguns autores exploraram o potencial dos sensores RGB no monitoramento do N de outras culturas, e mostram resultados divergentes. Näsi *et al.* (2018) obtiveram correlações superiores a 0,8 ao estimar o N em lavouras de cevada, e os maiores coeficientes com menores erros foram alcançados com modelos que combinavam índices de vegetação e recursos tridimensionais das imagens. Também trabalhando com cevada, Escalante *et al.* (2019) aplicaram algoritmos de aprendizagem profunda de máquina em feições extraídas de imagens RGB obtidas com UAV e conseguiram distinguir entre 3 doses de N ha⁻¹ com acurácia superior a 80%.

Caturegli *et al.* (2019) encontraram altas correlações entre o *Dark Green Colour Index* (DGCI), um IV baseado em imagens RGB de baixo custo, construído após a conversão das

imagens em valores de matiz, brilho e saturação, e o teor de N foliar em duas espécies de gramíneas da família *Poaceae*.

Por outro lado, ao modelar parâmetros biofísicos em cultura de trigo, como biomassa, índice de área foliar (IAF), altura das plantas e nitrogênio total, Schirrmann *et al.* (2016) encontraram, para o N, os modelos menos assertivos. Em três missões em diferentes períodos da cultura, os autores obtiveram correlações significativas com o EXG e com a taxa de cobertura do dossel (CVR) apenas próximo da florada (R de -0,48 e -0,53, respectivamente).

Ao passo que estudos em que os autores buscam monitorar do N com imagens RGB não são tão comuns e produzam resultados variáveis dependendo do tipo de cultura, bem como da metodologia empregada, o uso de sensores que contém a banda infravermelho próximo (NIR) e, principalmente, a *Red-Edge* (RE) são mais frequentemente explorados e muitos autores já reportaram resultados promissores em diversas culturas, tais como citrus (Osco *et al.*, 2019), milho (Corti *et al.*, 2018), soja (Yuan *et al.*, 2019), arroz (Wen *et al.*, 2018; Stavrakoudis *et al.*, 2019), trigo (Geipel *et al.*, 2016; Zheng *et al.*, 2018; Jiang *et al.*, 2019), entre outros. Contudo, de forma geral, os autores apontam para a necessidade de mais estudos para compreender como fatores biofísicos das culturas podem interferir nos resultados.

As bandas NIR e, principalmente a RE, têm se mostrado diferenciadas em estudos que envolvem o N em culturas agrícolas porque possuem maior sensibilidade a níveis mais altos de clorofila, ao contrário da saturação observada nas regiões do azul e do vermelho (Van Der Meij *et al.*, 2017). As plantas podem absorver até 90% da radiação incidente do espectro visível, enquanto na região do infravermelho, do qual a RE faz parte, as taxas de reflectância podem atingir 70% (Jensen, 2011; Ponzoni; Shimabukuro; Keplich, 2012). Dessa forma, em índices de vegetação do visível, a partir de um determinado ponto, podem não sofrer alterações com o incremento de biomassa ou clorofila.

A principal questão para o uso das bandas NIR e RE se refere aos custos envolvidos, uma vez que as aeronaves geralmente são acompanhadas de sensores em RGB, e sensores multiespectrais e hiperespectrais são mais caros. Contudo, estes sensores são geralmente acompanhados de dispositivos para calibração das imagens, o que é importante tanto para a obtenção dos valores de reflectância das imagens, quanto melhorar a performance na comparação de imagens multitemporais (Hunt Jr. *et al.*, 2018), como é o caso deste estudo.

No que diz respeito à cobertura vegetal, Hunt Jr. *et al.* (2018a), em estudo em que não conseguiram monitorar o N em cultura de batata com índices de vegetação de imagens multiespectrais, indicaram que a alta resolução das imagens UAV poderia ser melhor utilizada para estimar a fração da cobertura vegetal, uma vez que o suprimento de N está diretamente ligado ao crescimento vegetativo das plantas.

Dessa forma, este estudo também buscou associar o crescimento vegetativo dos cafeeiros nas parcelas de estudo, com as variações de N aplicadas. Em janeiro, quando ainda seria possível tomar decisões quanto à adubação, a taxa de crescimento do índice de cobertura vegetal esteve altamente correlacionada com as diferentes doses de N, contudo, essas diferenças não foram estatisticamente significativas, como mostrado pelos modelos de ANOVA.

Todavia, recomenda-se esta investigação também com cafeeiros submetidos à fertilização sintética, tendo em vista que em janeiro a maioria das parcelas ainda apresentava teor de N considerado baixo ($< 28,8 \text{ g kg}^{-1}$), o que pode ser explicado pela decomposição mais lenta do composto orgânico. Além disso, recomenda-se análises foliares por períodos maiores, para plena compreensão desse processo.

Portanto, embora neste estudo não tenha sido possível monitorar o N nem antes da adubação, nem durante um período onde ainda seria colaborar na tomada de decisão sobre

possíveis correções em campo, é preciso que novas investigações que envolvam o uso de sensores acoplados em UAV no estudo de cafeeiros sejam feitas. Processos como calibração radiométrica e geométrica das imagens com painéis específicos e sistemas de posicionamento de alta precisão, variação nas altitudes de voo, além do teste de novos IV, como o TGI e DGCI, bem como monitoramento durante maior tempo, considerando, por exemplo, a bianualidade e as variações fisiológicas durante um ano inteiro, podem ajudar a ampliar e solidificar as conclusões.

Conclusões

Não houve correlação significativa entre os índices de vegetação da faixa do visível e as diferentes doses de Nitrogênio aplicadas na adubação (0, 87,5, 175 e 262 kg N ha⁻¹), nem com o teor de Nitrogênio foliar (g kg⁻¹) em nenhum período do estudo.

Os índices de vegetação da faixa do visível não se correlacionaram significativamente com os valores SPAD.

O crescimento do índice de cobertura vegetal não variou significativamente entre os tratamentos entre outubro e janeiro, e entre outubro e março, embora tenha se relacionado diretamente com as doses de adubação entre outubro e janeiro.

As leituras do clorofilômetro SPAD não se relacionaram com o Nitrogênio foliar (g kg⁻¹) em outubro, mas se correlacionaram significativamente, tanto com os tratamentos (R² de 0,75), quanto com o teor de Nitrogênio foliar (R² de 0,97) em janeiro.

As imagens visíveis de alta resolução, obtidas com veículos aéreos não-tripulados, não foram, neste estudo, aptas para o monitoramento no Nitrogênio em lavouras de café sob sistema de cultivo orgânico. As leituras do teor de clorofila, feitas com o clorofilômetro SPAD 502, por outro lado, reafirmaram sua utilidade para tal tarefa, embora os resultados tenham variado entre os períodos de florada e de desenvolvimento dos frutos.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código Financeiro 001, à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelas bolsas concedidas aos autores. Agradecimentos também à Legado Cafés, por ceder a área de estudo, e à equipe do Laboratório de Nutrição Experimental da Faculdade de Nutrição da Universidade Federal de Alfenas, pelo apoio nas análises foliares.

Referências

- Ahmand, A., Quegan, S. (2012). Analysis of maximum likelihood classification on multispectral data. *Applied Mathematical Sciences*, 6(129), 6425-6436.
- Alvares, C. A., Stape, J.L., Sentelhas, P.C., Moraes Gonçalves, J.L., Spavorek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711-728.
- Amaral, J. A. T., Rena, A. B., Amaral, J. F. A. (2006). Crescimento vegetativo sazonal do cafeeiro e sua relação com fotoperíodo, frutificação, resistência estomática e fotossíntese (Seasonal vegetative growth of coffee and its relationship with photoperiod, fruiting, stomatal resistance and photosynthesis). *Pesquisa*

- Agropecuária Brasileira*, 41(3), 377-384. <https://doi.org/10.1590/S0100-204X2006000300002>.
- Association of Official Analytical Chemists (AOAC). (1995). Official methods of analysis. 8th ed.
- Arroyo, J., Guijarro, M., Pajares, G. (2016). An instance-based learning approach for thresholding in crop images under different outdoor conditions. *Computers and Electronics in Agriculture*, 127, 669- 679. <https://doi.org/10.1016/j.compag.2016.07.018>.
- Beniaich, A., Silva, M.L.N., Avalos, F.A.P., Menezes, M.D., Cândido, B.M. (2019). Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. *Semina: Ciências Agrárias*, 40(1), 49-66. <https://doi.org/10.5433/1679-0359.2019v40n1p49>.
- Camargo, A. P., Camargo, M. B. P. (2001). Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil (Definition and schematization of the phenological phases of arabica coffee in tropical conditions in Brazil). *Bragantia*, 60(1), 65-68.
- Caturegli, L., Gaetani, M., Volterrani, M., Magni, S., Minelli, A., Baldi, A. (2019). Normalized Difference Vegetation Index versus Dark Green Colour Index to estimate nitrogen status on bermudagrass hybrid and tall fescue. *International Journal of Remote Sensing*, 41, 1-16. <https://doi.org/10.1080/01431161.2019.1641762>.
- Chagas, W. F. T., Guelfi, D. R., Lacerda, J. R., Pinto, L. C., Andrade, A. B., Faquin, V. (2019). Nitrogen fertilizer technologies for coffee plants. *Coffee Science*, 14(1), 55-66. <https://doi.org/10.25186/cs.v14i1.1528>.
- Chemura, A., Mutanga, O., Odindi, J., Kutuywayo, D. (2018). Mapping spatial variability of foliar nitrogen in coffee (*Coffea arabica* L.) plantations with multispectral Sentinel-2 MSI data, 138, 1-11. <https://doi.org/10.1016/j.isprsjprs.2018.02.004>.
- Chen, Z., Miao, Y., Lu, J., Zhou, L., Li, Y., Zhang, H. *et al.* (2019). In-Season Diagnosis of Winter Wheat Nitrogen Status in Smallholder Farmer Fields Across a Village Using Unmanned Aerial Vehicle-Based Remote Sensing. *Agronomy*, 9(619), 1-23. <https://doi.org/10.3390/agronomy9100619>.
- Clemente, J. M., Martinez, H. E. P., Alves, L. C., Lara, M. C. R. (2013). Effect of N and K doses in nutritive solution on growth, production and coffee bean size. *Ceres*, 60(2), 279-285.
- Corti, M., Cavalli, D., Cabassi, G., Vigoni, A., Degano, L., Gallina, P. M. (2019). Application of a low-cost camera on a UAV to estimate maize nitrogen-related variables. *Precision Agriculture*, 20, 675-696. <https://doi.org/10.1007/s11119-018-9609-y>.
- Cunha, J. P. R., Sirqueira Neto, M. A., Hurtado, S. M. C. (2019). Estimating Vegetation volume of coffee crops using images from unmanned aerial vehicles. *Engenharia Agrícola*, 39, 41-47. <https://doi.org/0000-0001-8872-3366>.
- Escalante, H. J., Rodríguez-Sánchez, S., Jiménez-Lizárraga, M., Morales-Reyes, J., De La Calleja, J., Vazquez, R. (2019). Barley yield and fertilization analysis from UAV imagery: a deep learning approach. *International Journal of Remote Sensing*, 40(7), 2493-2516. <https://doi.org/10.1080/01431161.2019.1577571>.
- França, A. C., Carvalho, F. P. (2016). Correlations between SPAD readings, chlorophyll and leaf nitrogen in coffee cultivars during fruiting stage. *Revista Agrarian*, 9(34), 319-325.
- Gama-Rodrigues, A. C., Gama-Rodriguez, E. F., Brito, E. C. (2007). Decomposição e liberação de nutrientes de resíduos culturais de plantas de cobertura em Argissolo vermelho-

- amarelo na região noroeste fluminense (RJ) (Decomposition and release of nutrients from cultural residues of cover plants in red-yellow Argisol in the northwest region of Rio de Janeiro). *Revista Brasileira de Ciência do Solo*, 31, 1421-1428. <https://doi.org/10.1590/S0100-0683200700600019>.
- Garza, B. N., Ancona, V., Enciso, J., Perotto-Baldivieso, H. L., Kunta, M., Simpson, C. (2020). Quantifying citrus tree health using true color UAV images. *Remote Sensing*, 12(170), 1-13. <https://doi.org/10.3390/rs12010170>.
- Geipel, J., Link, J., Wirwahn, J. A., Claupein, W. (2016). A Programmable aerial multispectral camera system for in-season crop biomass and nitrogen content estimation. *Remote Sensing*, 6(4), 1-19. <https://doi.org/10.3390/agriculture6010004>.
- Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9).
- Guimarães, P. T. G., Garcia, A. W., Alvarez V, V. H., Prezotti, A. S., Miguel, A. E., Malavolta, E. *et al.* (1999). Cafeeiro (Coffee Plant). In Ribeiro, A. C., Guimarães, P. T. G., Alvarez V, V. H., *Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação* (Recommendations for the use of correctives and fertilizers in Minas Gerais: 5th approach) (pp. 289-302). Viçosa: Universidade Federal de Lavras.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(2), 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).
- Hunt Jr., E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry C. S. T., Perry, E. M., Akhmedov, B. (2013). A visible band index for remote sensing leaf chlorophyll content at the canopy scale. *International Journal of Applied Earth Observation and Geoinformation*, 21, 103-112. <https://doi.org/10.1016/j.jag.2012.07.020>.
- Hunt Jr. E. R, Daughtry, C. S. T. (2018). What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? *International Journal of Remote Sensing*, 39(15-16), 5345-5376. <https://doi.org/10.1080/01431161.2017.1410300>.
- Hunt Jr., E. R., Horneck, D. A., Spinelli, C. B., Turner, R. W., Bruce, A. E., Gadler, D. J. *et al.* (2018a). Monitoring nitrogen status of potatoes using small unmanned aerial vehicles. *Precision Agriculture*, 19, 314-333. <https://doi.org/10.1007/s11119-017-9518-5>.
- Instituto Nacional de Meteorologia (INMET). Estações Convencionais (Conventional Stations). <http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesConvencionais>. Accessed July 4 2020.
- Jensen, J. R. (2011). *Sensoriamento Remoto do ambiente: uma perspectiva em recursos terrestres* (Remote Sensing of the environment: a perspective on terrestrial resources). São José dos Campos: Parênteses.
- Jiang, J., Cai, W., Zheng, H., Cheng, T., Tian, Y., Zhu, Y. *et al.* (2019). Using digital cameras on an unmanned aerial vehicle to derive optimum color vegetation indices for leaf nitrogen concentration monitoring of winter wheat. *Remote Sensing*, 11(2667), 1-18. <https://doi.org/10.3390/rs11222667>.
- Kataoka, T., Kaneko, T., Okamoto, H., Hata, S. (2003). Crop growth system using machine vision. *Proceedings 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, 2(1), 1079-1083.
- Louhaichi, M., Borman, M. M., Johnson, D. E. (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto*

- International*, Hong Kong, 16(1), 65-70. <https://doi.org/10.1080/10106040108542184>.
- Maes, W. H.; Steppe, K. (2019) Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in Plant Science*, 24(2), 152-164. <https://doi.org/>
- McHugh, M. L. (2012). Interrater reliability: the kappa statistic. *Biochemia Medica*, 22, 276-282. <https://doi.org/10.1016/j.tplants.2018.11.007>.
- Mozgeris, G., Jonikavičius, D., Jovarauskas, D., Zinkevičius, R., Petkevičius, S., Steponavičius, D. (2018). Imaging from manned ultra-light and unmanned aerial vehicles for estimating properties of spring wheat. *Precision Agriculture*, 19, 876-894. <https://doi.org/10.1007/s11119-018-9562-9>.
- Näsi, R., Viljanen, N., Kaivosoja, J., Alhonoja, K., Hakala, T., Markelin, L. *et al.* (2018). Estimating Biomass and Nitrogen Amount of Barley and Grass Using UAV and Aircraft Based Spectral and Photogrammetric 3D Features. *Remote Sensing*, 10(1082), 1-32. <https://doi.org/10.3390/rs10071082>.
- Oscó, L. P., Ramos, A. P., Pereira, D. R., Moriya, E. A. S., Imai, N. N., Matsubara, E. T. *et al.* (2019). Predicting canopy nitrogen content in citrus-trees using random forest algorithm associated to spectral vegetation indices from UAV-Imagery. *Remote Sensing*, 11(2925), 1-17. <https://doi.org/10.3390/rs11242925>.
- Ponzoni, F. J., Shimabukuro, Y. E., Kuplich, T. M. (2012). *Sensoriamento Remoto da Vegetação* (Remote Sensing of Vegetation). São Paulo: Oficina de Textos.
- R Development Core Team. R: A language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2019. Retrieved July 4, 2020, from <https://www.R-project.org>.
- Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T., Moscholios, I. (2020). A compilation of UAV applications for precision agriculture. *Computer Networks*, 172, 1-18. <https://doi.org/10.1016/j.comnet.2020.107148>.
- Reis, A. R., Favarin, J. L., Malavolta, E., Lavres Júnior, J., Moraes, M. F. (2009). Photosynthesis, chlorophylls, and SPAD readings in coffee leaves in relation to nitrogen supply. *Communications in Soil Science and Plant Analysis*, 40(9), 1512-1518. <https://doi.org/10.1080/00103620902820373>.
- Saberioon, M., Amim, M. S. M., Gholizadeh, M. H. (2014). A review of optical methods for assessing nitrogen contents during rice growth. *Applied Engineering in Agriculture*, 30(4), 657-669. <https://doi.org/10.13031/aea.30.10478>.
- Santos, C. G., Cruz, L. O. M., Moraes, M. L. B., Fernandes, P. R. M., Michel, R. F. M., Alexandrino, R. C. S. (2010). Mapa de Solos do Estado de Minas Gerais (Soil Map of Minas Gerais State). Universidade Federal de Viçosa. http://www.dps.ufv.br/?page_id=742. Accessed July 4 2020.
- Santos, F. S., Souza, P. E., Pozza, E. A., Miranda, J. C., Carvalho, E. A., Fernandes, L. H. M. *et al.* (2008). Adubação orgânica, nutrição e progresso de cercosporiose e ferrugem do-cafeeiro (Organic fertilization, nutrition and progress of cercosporiosis and coffee rust). *Pesquisa Agropecuária Brasileira*, 43(7), 783-791. <https://doi.org/10.1590/S0100-204X2008000700001>.
- Santos, L. M., Ferraz, G. A. S., Barbosa, B. D. S., Diotto, A. V., Maciel, D. T., Xavier, L. A. G. (2020). Biophysical parameters of coffee crop estimated by UAV RGB images. *Precision Agriculture*. <https://doi.org/10.1007/s11119-020-09716-4>.
- Schirrmann, M., Giebel, A., Gleiniger, F., Pflanz, M., Lentschke, J., Dammer, K. H. (2016). Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery. *Remote Sensing*, 8(176), 1-19. <https://doi.org/10.3390/rs8090706>.

- Stavrakoudis, D., Katsantonis, D., Kadoglidou, K., Kalaizidis, A., Gitas, I. Z. (2019). Estimating rice agronomic traits using drone-collected multispectral imagery. *Remote Sensing*, 11(545), 1-25. <https://doi.org/10.3390/rs11050545>.
- Thompson, R. L., Lassaletta, L., Patra, P. K., Wilson, C., Wells, K. C., Gressent, A. *et al.* (2019). Acceleration of global N₂O emissions seen from two decades of atmospheric inversion. *Nature Climate Change*, 9, 993-998. <https://doi.org/10.1038/s41558-019-0613-7>.
- Torrez-Sánchez, J., Peña, J. M., de Castro, A. I., López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104 – 113. <https://doi.org/10.1016/j.compag.2014.02.009>.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8, 127-150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).
- Unigarro-Muñoz, C. A., Hernández-Arredondo, J. D., Montoya-Restrepo, E. C., Medina-Rivera, R. D., Ibarra-Ruales, L. N., Carmona-González, C. Y. *et al.* (2015). Estimation of leaf area in coffee leaves (*Coffea arabica* L.) of the Castillo® variety. *Bragantia*, 74(4), 412-416. <https://doi.org/10.1590/1678-4499.0026>.
- Van der Meij, B., Kooistra, L., Soumalainen, J., Barel, J. M., De Deyn, G. (2017). Remote sensing of plant trait responses to field-based plant-soil feedback using UAV-based optical sensors. *Biogeosciences*, 14, 733-749. <https://doi.org/10.5194/bg-14-733-2017>.
- Vega, F. A., Ramírez, F. C., Saiz, M. P., Rosúa, F. O. (2015). Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. *Biosystems Engineering*, 132, 19-27. <https://doi.org/10.1016/j.biosystemseng.2015.01.008>.
- Vieira, R. F. (2017). *Ciclo do Nitrogênio em sistemas agrícolas* (Nitrogen cycle in agricultural systems). Brasília: Empresa Brasileira de Pesquisa Agropecuária.
- Wen, D., Tongyu, X., Fenghua, Y., Chunling, C. (2018). Measurement of nitrogen content in rice by inversion of hyperspectral reflectance data from an unmanned aerial vehicle. *Ciência Rural*, 48(6), 1-10. <https://doi.org/10.1590/0103-8478cr20180008>.
- Wöbbecke, D. M., Meyer, G. E., Von Bargen, K., Mortensen, D. A. (1999). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269. <https://doi.org/10.13031/2013.27838>.
- Yuan, M., Burjel, J. C., Isermann, J., Goeser, N. J., Pittelkow, C. M. (2019). Unmanned aerial vehicle-based assessment of cover crop biomass and nitrogen uptake variability. *Journal of Soil and Water Conservation*, 74(4), 350-359. <https://doi.org/10.2489/jswc.74.4.350>.
- Zhang, X., Davidson, E. A., Mauzerall, D. L., Searchinger, T. D., Dumas, P., Shen, Y. (2015). Managing nitrogen for sustainable development. *Nature*, 528, 51-59. <https://doi.org/10.1038/nature15743>.
- Zheng, H., Li, W., Jiang, J., Liu, Y., Cheng, T., Tian, Y. *et al.* (2018). A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, 10(2026), 1-16. <https://doi.org/10.3390/rs10122026>.

2 CONSIDERAÇÕES FINAIS

Os índices de vegetação, apesar de não terem atingido o objetivo de monitorar o Nitrogênio foliar, possuem alta performance na detecção de falhas, na determinação e monitoramento da cobertura vegetal, o que pode ser feito de forma manual, semiautomatizada (por classificação supervisionada), ou totalmente automatizada, com algoritmos de classificação, tanto em ambiente de um SIG (Sistema de Informação Geográfica), quanto em ambiente R.

A partir dessas classificações é possível acompanhar, com precisão, o crescimento e o desenvolvimento das plantas, identificando possíveis falhas, zonas de baixo de crescimento vegetativo que podem indicar presença de pragas e doenças, por exemplo, bem como zonas de alto crescimento. Essas informações são importantes para o manejo e aplicação de insumos agrícolas em taxas variadas, o que reduz não somente desperdícios e prejuízos econômicos, mas que minimizam os danos ambientais.

No que diz respeito ao clorofilômetro SPAD, este se mostrou eficiente no monitoramento do Nitrogênio foliar após a adubação. Devido às recomendações de parcelamento das aplicações, a ferramenta pode ser utilizada para tomadas de decisão dentro do período de fertilização.

Embora este estudo tenha sido realizado em áreas pequenas (< 1 ha), o Nitrogênio foliar variou especialmente em todas as fases do estudo, o que mostra a relevância de um monitoramento em maiores escalas para aprimorar a gestão da fertilização e reduzir impactos ambientais.

As imagens RGB de alta resolução, obtidas com aeronaves remotamente pilotadas, não se mostraram eficientes no monitoramento do Nitrogênio foliar de cafeeiros da variedade Catuaí vermelho, em sistema de cultivo orgânico, em nenhuma fase do ciclo fenológico. Contudo, os resultados com este tipo de imagem na literatura são muito variáveis, o que indica que ainda são necessários novos estudos para verificar os fatores que possam influenciar no sucesso desta tarefa, tais como: tipo de cultura e de dossel, ciclos fenológicos, ocorrência de doenças e/ou pragas, tipo de sensor e bandas, variações da altura de voo, e correções radiométricas e geométricas, entre outros.

A análise da literatura mostrou que presença da banda NIR (*Near Infrared*) e, principalmente, a *Red-Edge* pode ser determinante para o monitoramento do Nitrogênio, uma vez que o nível de saturação de imagens RGB é alta em relação à biomassa e clorofila, por

exemplo, o que ficou evidente com a baixa variância entre os valores médios dos índices de vegetação. Todavia, a aquisição de sensores com estes canais envolve custos que podem ser limitantes, portanto, o desenvolvimento de técnicas com as imagens do visível representaria uma solução alternativa de baixo custo, portanto, deve continuar a ser testada.