



LUANA MENDES DOS SANTOS

**MONITORAMENTO DE CARACTERÍSTICAS
MORFOFISIOLÓGICAS DE CAFEEIROS A PARTIR DE
IMAGENS DE AERONAVE REMOTAMENTE PILOTADA**

**LAVRAS - MG
2021**

LUANA MENDES DOS SANTOS

**MONITORAMENTO DE CARACTERÍSTICAS MORFOFISIOLÓGICAS DE
CAFEEIROS A PARTIR DE IMAGENS DE AERONAVE REMOTAMENTE
PILOTADA**

Tese apresentado à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Máquinas e mecanização agrícola, para a obtenção do título de Doutor.

Dr. Gabriel Araújo e Silva Ferraz

Orientador

Dra. Milene Alves de Figueiredo Carvalho

Coorientadora

LAVRAS - MG

2021

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Santos, Luana Mendes dos.

Monitoramento de características morfofisiológicas de
cafeeiros a partir de imagens de aeronave remotamente pilotada /
Luana Mendes dos Santos. - 2021.

107 p.

Orientador(a): Gabriel Araújo e Silva Ferraz.

Coorientador(a): Milene Alves de Figueiredo Carvalho.

Tese (doutorado) - Universidade Federal de Lavras, 2021.

Bibliografia.

1. Veículo Aéreo Não Tripulado. 2. Sensoriamento Remoto. 3.
Agricultura Digital. I. Ferraz, Gabriel Araújo e Silva. II. Carvalho,
Milene Alves de Figueiredo. III. Título.

LUANA MENDES DOS SANTOS

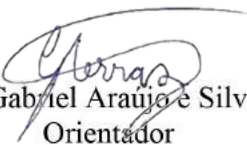
**MONITORAMENTO DE CARACTERÍSTICAS MORFOFISIOLÓGICAS DE
CAFEIROS A PARTIR DE IMAGENS DE AERONAVE REMOTAMENTE
PILOTADA**

**MONITORING MORPHO-PHYSIOLOGICAL CHARACTERISTICS OF COFFEE
PLANTS FROM REMOTELY PILOTED AIRCRAFT IMAGES**

Tese apresentado à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Máquinas e mecanização agrícola, para a obtenção do título de Doutor.

APROVADA em 14 de outubro de 2021.

Dra. Francisca Nivanda de Lima Estevam UEMG
Dr. Mauro Antônio Homem Antunes UFRRJ
Dr. Adão Felipe dos Santos UFLA


Prof. Dr. Gabriel Araújo e Silva Ferraz
Orientador

Dra. Milene Alves de Figueiredo Carvalho
Coorientadora

**LAVRAS-MG
2021**

A Deus, OFEREÇO.

*Dedico esta tese ao meu amado esposo, Ricardo, por todo amor, carinho, paciência e
companheirismo. Aos meus pais, Ivani e João, minha força e sustento.
Aos meus irmãos, Fabiana, Fernanda, Bruno, Lucas e Melissa por me amarem e
compreenderem a distância.*

AGRADECIMENTOS

À Deus, por me dares muito mais do que eu preciso, por me abençoares muito mais do que eu mereço, por Teus planos para a minha vida serem sempre maiores do que os meus sonhos, pelas cruzes e tribulações do dia-a-dia que me fizeram crescer e descobrir os muitos “Cirineus” que Tu me deste de presente para me ajudar na caminhada e pela misericórdia Divina que sempre me sustentou.

À Universidade Federal de Lavras, Departamento de Engenharia Agrícola (DEA), seu corpo docente, direção e administração, pela oportunidade de aprendizado a mim concedida.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro. Ao Consórcio Pesquisa Café pelo apoio ao projeto.

Ao meu orientador professor Dr. Gabriel Araújo e Silva Ferraz, pelas orientações desde a graduação, passando pelo mestrado e finalizando com o doutorado, agradeço imensamente toda a paciência, conselhos, conversas, atenção, boa vontade, incentivos constantes para seguir na área acadêmica, todo o suporte e disposição em ajudar, além de todo o conhecimento compartilhado.

À pesquisadora e coorientadora Milene Alves de Figueiredo Carvalho pela parceria no experimento, pelas palavras de conselho, instruções, ensinamentos e por todo apoio que deu no desenvolvimento deste trabalho.

Aos membros da banca, Profa. Dra. Francisca Nivanda de Lima Estevam, Prof. Dr. Mauro Antônio Homem Antunes, Prof. Dr. Adão Felipe dos Santos, Dra. Mirian de Lourdes Oliveira e Silva (membra suplente) e Prof. Dr. Carlos Eduardo Silva Volpato (membro suplente) por toda atenção despendida e por todas as contribuições para o presente este trabalho.

Aos alunos de iniciação científica envolvidos nas coletas, Leticia Xavier Gonçalves e Sabrina Aparecida Teodoro, ao NESA e ao NECAF pelo apoio nas coletas de campo e na pesquisa.

A todos os amigos do departamento, em especial Brenon Diennevan Souza Barbosa, Maria Alice Junqueira e Marco Zanella pela companhia, amizade, conversas, risadas, choros e conselhos. Assim como, as grandes amizades conquistadas nestes cinco anos de UFLA. A todos que estão envolvidos e que direta ou indiretamente contribuem para dias melhores e para esta jornada fosse cumprida com êxito!

À minha família, por ter acreditado em mim, por me apoiar e auxiliar nos momentos em que precisei e por compreender a minha ausência.

Ao meu amado esposo, aquela pessoa que Deus colocou em minha vida para levantar em minhas quedas, enxugar minhas lágrimas, não me deixar desistir, sempre colocar um sorriso em meu rosto e por ser meu auxiliar de campo e piloto dos drones!

MUITO OBRIGADA!

“É justo que muito custe o que muito vale.” Santa Teresa D’Ávila

RESUMO GERAL

As Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft* –RPA) são utilizadas como plataformas para o sensoriamento remoto (SR) para realizar monitoramentos constantes da lavoura, bem como identificação de anomalias nas mesmas, no tempo e no espaço, o que possibilita auxiliar no manejo da cultura. Diante deste cenário, este trabalho analisou as potencialidades de imagens de alta resolução geradas por dados de SR multiespectral obtidos a partir de RPA na caracterização de parâmetros morfofisiológicos de cafeeiros. O primeiro estudo objetivou avaliar a relação entre a produção e a desfolha quantificada em campo e obtida por meio de imagens de RPA. Com o processamento das imagens do ano de 2020, a lavoura apresentou uma redução de 17,3 % e de 18,4 % de área e volume foliar, respectivamente, após a colheita. E, em 2021, a lavoura apresentou uma redução de 12,8 % e 9,8 % de área e volume foliar, respectivamente, após a colheita. Deste modo, foi possível quantificar a área e o volume de uma lavoura cafeeira após a colheita por meio de imagem obtida por RPA e, também, analisar as interações entre dados de campo com a produção do mesmo ano de colheita, sendo estes diretamente proporcional, e a interação de dados da imagem de um ano com a produção anterior, sendo inversamente proporcionais. O segundo estudo teve como objetivo identificar qual Índice de Vegetação (IV) é adequado para explicar a metodologia de inversão de Clorofila (Chl) e avaliar as relações entre os IVs obtidos a partir de imagem de RPA e os índices de clorofila da folha (Chl_{leaf}) e de clorofila do dossel (Chl_{canopy}) em cafeeiros no período chuvoso e da seca. Os IVs que melhor explicaram a Chl no período chuvoso foram os IVs $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} . Para ambos os períodos da seca avaliados, não encontrou um padrão nas relações entre Chl_{leaf} , Chl_{canopy} e os IVs. Por fim, o terceiro estudo objetivou caracterizar a temperatura obtida por meio de RPA e avaliar sua relação com o potencial hídrico (PH) e condutância estomática (g_s) de uma lavoura experimental de cafeeiros por meio do uso das técnicas geoestatísticas. Com os dados de g_s , PH e os mapas de temperatura, pode-se observar que com a redução do PH, houve o fechamento estomático e a redução da g_s , favorecendo o aumento da temperatura por déficit hídrica nos períodos estudados. Além disso, foi possível observar a distribuição espacial da temperatura obtida por meio de câmera termal embarcada na RPA. Os mapas de distribuição da temperatura permitiram visualizar a distribuição espacial heterogênea, o que permitiu identificar as áreas em que as plantas estavam expostas a condições de variações climáticas podendo ser indicativo de deficiência hídrica.

Palavras-chave: Veículo Aéreo Não Tripulado. Sensoriamento Remoto. Agricultura de Precisão. Agricultura Digital. Índices de Vegetação. Desfolha. Cafeicultura. Clorofila. Condutância estomática. Potencial Hídrico.

GENERAL ABSTRACT

Remotely Piloted Aircraft (RPA) are used as platforms for remote sensing (SR) to carry out constant monitoring of the crop, as well as the identification of anomalies in them, in time and space, which makes it possible to assist in the management of the culture. Given this scenario, this work analyzed the potential of high-resolution images generated by multispectral SR data obtained from RPA in the characterization of morphophysiological parameters of coffee trees. The first study aimed to evaluate the relationship between yield and defoliation measured in the field and obtained through RPA images. With the processing of images from the year 2020, the crop showed a reduction of 17.3% and 18.4% in leaf area and volume, respectively, after harvest. And, in 2021, the crop showed a reduction of 12.8% and 9.8% of leaf area and volume, respectively, after harvest. In this way, it was possible to quantify the area and volume of a coffee crop after harvesting through the image obtained by RPA and also to analyze the interactions between field data with the production of the same harvest year, which are directly proportional, and the interaction of one-year image data with the previous production, being inversely proportional. The second study aimed to identify which Vegetation Index (VI) is suitable to explain the Chlorophyll inversion (Chl) methodology and to evaluate the relationships between the IVs obtained from the RPA image and leaf chlorophyll (Chl_{leaf}) indices) and canopy chlorophyll (Chl_{canopy}) in coffee trees during the rainy and dry seasons. The IVs that best explained Chl in the rainy season were the IVs $MCARI2_{RPA}$, MSR_{RPA} and SR_{RPA} . Both drought periods evaluated did not find a pattern in the relationships between Chl_{leaf} , Chl_{canopy} , and IVs. Finally, the third study aimed to characterize the temperature obtained by through RPA and evaluate its relationship with the water potential (PH) and stomatal conductance (gs) of an experimental coffee plantation through geostatistical techniques. With the data of gs, PH and the temperature maps, it can be observed that with the reduction of the PH, there was a stomatal closure and a reduction of the gs, favoring the increase in temperature due to water deficit in the studied periods. In addition, it was possible to observe the spatial distribution of temperature obtained through a thermal camera embedded in the RPA. The temperature distribution maps allowed to visualize the heterogeneous spatial distribution, which allowed to identify the areas where the plants were exposed to climatic conditions, which could be indicative of water deficit.

Keywords: Unmanned Aerial Vehicle. Remote Sensing. Precision Agriculture. Digital Agriculture. Vegetation Index. Defoliation. Coffee Crop. Chlorophyll. Stomatal Conductance. Water Potential.

LISTA DE FIGURAS

SEGUNDA PARTE

ARTIGO 1

Figura 2.1-	Delimitação do estado de Minas Gerais, do município de Lavras e do talhão de estudo.....	43
Figura 3.1-	Regressão e correlação. a) P-2020 e D.C.P-2020; b) P-2021 e D.C.P-2021 e c) P-2021 e D.C.V-2021.....	49
Figura 3.2-	Regressão e correlação. a) P-2019 e a D.A.A-2020; b) P-2020 e a D.A.A-2021 e c) P-2020 e a D.A.V-2021.....	50
Figura 3.3-	Área foliar de cafeeiros a) antes da colheita de 2020, b) depois da colheita de 2020, c) antes da colheita de 2021 e d) depois da colheita de 2021.....	51

ARTIGO 2

Figura 2.1-	Localização da área de estudo.....	64
Figura 2.2-	Equipamentos: (a) Aeronave Remotamente Pilotada (<i>Remotely Piloted Aircraft</i> - RPA) Matrice 100 utilizado para o levantamento; (b) a câmera Parrot SequoiaTM (sensores de imagem e irradiância); (c) o alvo de calibração da câmera; (d) um exemplo dos pontos de controle.	65
Figura 2.3-	Representação gráfica das variáveis meteorológicas registradas, mensalmente, em Lavras - MG, no período novembro 2019 a agosto de 2021.....	69
Figura 3.1-	Coefficientes de correlação e não significância do teste de t de Student (representada com x) entre os IVs e os parâmetros morfofisiológicos de cafeeiros, no período chuvoso (novembro de 2019). As correlações positivas são exibidas em azul e as correlações negativas em vermelho. Assim como as correlações fortes estão em tons intensos e as correlações fracas estão em tons claros.	70
Figura 3.2-	Relação entre (a) MCARI2 _{RPA} e medições do conteúdo de clorofila A no dossel (ChlA _{canopy}); (b) MSR _{RPA} e ChlA _{canopy} ; (c) SR _{RPA} e ChlA _{canopy}	72
Figura 3.3-	Relação entre (a) MCARI2 _{RPA} e medições do conteúdo de clorofila T na folha (ChlT _{canopy}); (b) MSR _{RPA} e ChlT _{canopy} ; (c) SR _{RPA} e ChlT _{canopy} . ..	73
Figura 3.4-	Resíduos dos valores estimados pelos IV _{RPA} e os parâmetros medidos em campo: (a) MCARI2 _{RPA} e ChlA _{canopy} (b) MSR _{RPA} e ChlA _{canopy} (c)	

	SR _{RPA} e ChlA _{canopy} (d) MCARI2 _{RPA} e ChIT _{canopy} (e) MSR _{RPA} e ChIT _{canopy} (f) SR _{RPA} e ChIT _{canopy}	74
Figura 3.5-	Mapas dos IV da área de estudo: (a) MCARI2 _{RPA} ; (b) MSR _{RPA} ; (c)SR _{RPA}	74
Figura 3.6-	Coefficientes de correlação e não significância do teste de t de Student (representada com x) entre os IVs e os parâmetros morfofisiológicos de cafeeiros, no período seco (Agosto de 2020). As correlações positivas são exibidas em azul e as correlações negativas em vermelho, correlações fortes estão em tons intensos e as correlações fracas estão em tons claros.	76
Figura 3.7-	Coefficientes de correlação e não significância do teste de t de Student (representada com x) entre os IVs e os parâmetros morfofisiológicos de cafeeiros, no período seco (Agosto de 2021). As correlações positivas são exibidas em azul e as correlações negativas em vermelho. Assim como as correlações fortes estão em tons intensos e as correlações fracas estão em tons claros.....	77
ARTIGO 3		
Figura 2.1-	Limite da área de estudo e localização dos pontos amostrais de cada parcela.	89
Figura 2.2-	Equipamentos: (a) RPA utilizado para o levantamento, Matrice 100; (b) a câmera Termal, FLIR DUO; (c) um exemplo das placas de controle utilizado na área de estudo.....	91
Figura 2.3-	Representação gráfica das variáveis meteorológicas registradas, mensalmente, em Lavras - MG, no período novembro 2019 a agosto de 2020.....	92
Figura 3.1-	Distribuição espacial temperatura e condutância estomática (gs) dos cafeeiros. a) período chuvoso; b) período seco.....	95
Figura 3.2-	Distribuição espacial temperatura e potencial hídrico (MPa) dos cafeeiros. a) período chuvoso; b) período seco.....	97

LISTA DE TABELAS

PRIMEIRA PARTE

Tabela 3.1-	Bandas espectrais utilizadas em Sensoriamento Remoto.	24
-------------	--	----

SEGUNDA PARTE

ARTIGO 1

Tabela 2.1-	Dados do processamento das imagens RPA.	45
Tabela 3.1-	Coefficientes de correlação de Pearson das variáveis de estudo, em negrito as relações que foram significativas.	47
Tabela 3.2-	Análise Exploratória dos dados.	48

ARTIGO 2

Tabela 2.1-	Especificações da câmera Parrot Sequoia.	66
Tabela 2.2-	Índices de vegetação obtidos a partir da refletância das bandas multiespectrais das imagens RPA.	67

ARTIGO 3

Tabela 3.1-	Método ML, modelo Gaussiano e parâmetros estimados de semivariogramas experimentais para temperatura na lavoura cafeeira durante o período chuvoso (novembro) e período seco (agosto).	94
-------------	---	----

LISTA DE ABREVIATURA E SIGLAS

a'	Alcance prático
AP	Agricultura de Precisão
$C_0 + C_1$	Patamar
C_0	Efeito pepita
C_1	Contribuição
CCCI	Canopy Chlorophyll Content Index
CHM	Canopy Height Model
CIgreen	Chlorophyll Index green
CIred edge	Chlorophyll Index red edge
CIA	Clorofila A
CIB	Clorofila B
CIT	Clorofila total
CP	Cafeicultura de Precisão
D.A.A.	Desfolha da aeronave em área
D.A.V.	Desfolha da aeronave em volume
D.C.P.	Desfolha de campo com base no peso
D.C.V.	Desfolha de campo com base no volume
DGPS	Differential global positioning system
DJI	Dà-Jiāng Innovations Science and Technology Co.
EVI2green	Enhanced Vegetation Index 2-Green
FLIR	Forward Looking Infrared
GMR	Green Minus Red
GNDVI	Green normalized difference vegetation index
GNSS	Global Navigation Satellite System
gs	Condutância estomática foliar
IAF	Índice de Área Foliar
IV	Índice de Vegetação
MCARI1	First modified chlorophyll absorption ratio index
MCARI2	Second modified chlorophyll absorption ratio index
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDT	Modelo Digital do Terreno
ME	Erro Médio
ML	Máxima Verossimilhança
MNGRDI	Modified normalized green red difference index
MSAVI	modified SAVI
MSR	modified SR
MTVI1	Modified normalized difference vegetation index 1
MTVI2	Modified normalized difference vegetation index 2
NDRE	Normalized Difference Red Edge
NDVI	Normalized Difference Vegetation Index
NDVI	Normalized difference vegetation index
NGRDI	Normalized Green-Red Difference Index
NIR	Near Infrared
OSAVIgreen	Optimized Soil Adjusted Vegetation Index-Green
PH	Potencial Hídrico Foliar
RDVI	Renormalized Difference Vegetation Index
RE	Erro Médio Reduzido

REG	Red Edge
REM	Radiação Eletromagnética
RGB	Red, Green and Blue
RPA	Remotely Piloted Aircraft
SAVIgreen	Soil Adjusted Vegetation Index-Green
SDD	Grau de Dependência Espacial
SDME	Desvio Padrão dos Erros Médios
SDRE	Desvio Padrão dos Erros Médios Reduzidos
SfM	Structure from Motion
SIG	Sistemas de Informação Geográfica
SR	Simple Ratio
SR	Sensoriamento Remoto
TVI	Triangular Vegetation Index
UAS	Unmanned Aircraft System
UAV	Unmanned Aerial Vehicles
VANT	Veículos Aéreos Não Tripulados
VC	Validação Cruzada

SUMÁRIO

PRIMEIRA PARTE

1	INTRODUÇÃO.....	14
2	OBJETIVOS.....	17
2.1	Objetivo geral.....	17
2.2	Objetivos específicos	17
3	REFERENCIAL TEÓRICO	18
3.1	Aspectos gerais da cultura do cafeeiro	18
3.1.1	Parâmetros Morfológicos	19
3.1.2	Parâmetros Fisiológicos	21
3.2	Sensoriamento Remoto	23
3.2.1	Índices de Vegetação (IV)	25
3.3	Agricultura de Precisão e Cafeicultura de Precisão.....	26
3.3.1	Uso de Aeronaves remotamente pilotadas na cafeicultura de precisão	27
4	CONSIDERAÇÕES GERAIS	31
	REFERÊNCIAS.....	32

SEGUNDA PARTE- ARTIGOS

ARTIGO 1- POTENCIAL DAS INFORMAÇÕES ESPACIAIS DE IMAGENS RPA PARA QUANTIFICAR DESFOLHA APÓS A COLHEITA DE CAFEEIROS

1	INTRODUÇÃO.....	41
2	MATERIAL E MÉTODOS	43
3	RESULTADOS E DISCUSSÃO.....	47
4	CONCLUSÃO.....	54
	REFERÊNCIAS.....	56

ARTIGO 2- USANDO RPA PARA ACESSAR A INVERSÃO DA CLOROFILA NA CULTURA DO CAFÉ EM DUAS ESTAÇÕES DE CRESCIMENTO

1	INTRODUÇÃO.....	62
2	MATERIAL E MÉTODOS	64
3	RESULTADOS E DISCUSSÃO.....	70
4	CONCLUSÃO.....	79
	REFERÊNCIAS.....	81

ARTIGO 3- AVALIAÇÃO DA DISTRIBUIÇÃO ESPACIAL DA TEMPERATURA DE CAFEIROS OBTIDA POR CAMERA TERMAL ABORDO DE AERONAVE REMOTAMENTE PILOTADA		85
1	INTRODUÇÃO.....	88
2	MATERIAL E MÉTODOS	89
3	RESULTADOS E DISCUSSÃO.....	93
4	CONCLUSÃO.....	99
	REFERÊNCIAS.....	101
	CONSIDERAÇÕES GERAIS.....	104

PRIMEIRA PARTE

1 INTRODUÇÃO

A estimativa de produção do café (*Coffea spp.*) para a safra 2020/2021 em escala mundial é de 175,5 milhões de sacas (60 kg) (USDA, 2021). O Brasil tem participação significativa nestes dados, ocupando a primeira posição contribuindo com cerca de 38,7% da produção mundial de café (USDA, 2021). Já quando observamos a nível estadual, Minas Gerais representa cerca de 55% da produção total do país alcançando uma safra recorde em 2021, com 34,6 milhões de sacas do grão beneficiado (CONAB, 2021).

De acordo com USDA (2021), estima-se que, no corrente ano-safra, haverá um crescimento de 1,5% na demanda mundial em relação ao período anterior (expansão de 2,5 milhões de sacas). Diante deste cenário de aumento de consumo, a cafeicultura tem o desafio de suprir a demanda alimentícia e, para isso, é necessário ter eficiência e aumentar a produção do grão.

Diante desta demanda, programas de melhoramento do cafeeiro estudam a resistência a doenças, o alto rendimento e a qualidade de bebida do café. Entretanto, existem características naturais do cafeeiro, como o ciclo bienal, que consiste na alternância de um ano com grande florada seguido por outro com florada menos intensa de modo que, este ciclo bienal representa um desafio para superar a produção de grão (CARVALHO et al., 2020).

Além do ciclo bienal, adversidades climáticas como: temperaturas elevadas, estiagem e geadas, tratos culturais e manejos, como a colheita, também podem influenciar na produtividade, ocasionando variações espaciais e temporais na lavoura. Segundo Voltolini et al. (2019), fatores como nutrição, relações hídricas, características do solo, dentre outros, podem interferir na produtividade e qualidade dos frutos. Destaca-se também parâmetros fisiológicos (por exemplo clorofila- Chl) (PUTRA; SONI, 2018; CHEMURA; ODINDI, 2017) como bons indicadores da condição da vegetação e auxiliam no monitoramento da cultura, além de ter a possibilidade de estarem relacionados com a produtividade. Segundo Ahmad et al. (2021), os Índices de Vegetação (IV) fornecem informações vitais para o monitoramento da cultura, auxiliando na tomada de decisão.

Enquanto as pesquisas de Seleção Genômica ainda estão emergindo para saber como lidar com a bienalidade (CARVALHO et al., 2020; SOUSA et al., 2019; FERRÃO et al., 2019), torna-se necessário desenvolver técnicas produtivas e de monitoramento das características morfofisiológicas da cultura, de forma a identificar anomalias fazendo com que se possa agir em campo de forma rápida, precisa e localizada, auxiliando os cafeicultores nas tomadas de decisão.

No âmbito das ciências que abordam o espaço geográfico, o sensoriamento remoto (SR) é utilizado nos diversos campos de estudo sobre a superfície terrestre, dada a vasta cobertura espacial e a repetitividade das observações (GAIDA et al., 2020). A partir das informações detectadas pelo SR podem ser estimados diversos parâmetros morfofisiológicos importantes para o monitoramento constante, além de permitir identificar anomalias na lavoura no tempo e no espaço, auxiliando no manejo da cultura.

O avanço da agricultura digital aliada a ferramentas computacionais, Aprendizado de Máquina (*Machine Learning*), Sistemas de Aeronaves Não- Tripuladas (*Unmanned Aircraft System- UAS*), sensores ópticos (câmeras multiespectrais e termais), tem possibilitado a coleta de dados permitindo a extração de índices de vegetação, parâmetros morfológicos e fisiológicos, identificação de anomalias em lavouras, dentre outras informações.

A exploração destes dados de imagens obtidas por Aeronaves Remotamente Pilotada (*Remotely Piloted Aircraft –RPA*) é uma estratégia que visa auxiliar o produtor na detecção de variabilidades e anomalias que possam ocorrer nas lavouras, contribuindo para alerta precoce afim de realizar manejos e controles efetivos na cultura do cafeeiro. Além de possuir grande potencial como ferramenta para analisar situações críticas no cultivo do café (OLIVEIRA et al., 2018) como deficiência hídrica, nutricional, falhas de plantio, ataque de pragas e doenças.

Com isso, estas ferramentas podem contribuir de forma significativa para cafeicultura, obtendo informações e dados de maneira rápida (alta resolução temporal); detalhada (alta resolução espacial) (AHMAD et al. 2021; SANTOS et al. 2020a) e não invasiva. Deste modo, este monitoramento agrícola faz-se necessário devido ao aumento da demanda por alimentos no mundo e o resultado deste monitoramento constante servirá como uma base de apoio para tomadas de decisões (ATZBERGUER, 2013).

Além disso, os produtos de SR tem grande potencial nas aplicações da Agricultura de Precisão, incentivando o desenvolvimento de novas abordagens metodológicas e aplicações que produzam informações espaciais de boa qualidade permitindo que o produtor rural possa tomar decisões de manejo e melhorar o planejamento de culturas (MORIYA, 2015).

Sendo o café uma cultura de grande valor comercial agregado, importante para o agronegócio brasileiro, estudos desta natureza se mostram promissores e necessários para o monitoramento dessa cultura. Na literatura, diversas pesquisas já foram realizadas aplicando a Agricultura de Precisão na cafeicultura (FERRAZ et al., 2011; FERRAZ et al., 2017; CARVALHO et al., 2017; FERRAZ et al., 2018).

Ademais, estudos utilizando RPAs para monitoramento da cafeicultura, estão desabrochando bem como os estudos para estimativa de parâmetros morfológicos (SANTOS et

al., 2020a), coeficiente de cultura (Kc) (SANTOS et al., 2020b), Índice de área foliar (SANTOS et al., 2020c; BARBOSA et al., 2021), estimativa de volume (CUNHA et al., 2019), monitoramento de nitrogênio foliar (PARREIRAS et al. 2020, MARIN et al., 2021b), para monitoramento de danos causados por geadas (MARIN et al., 2021a), e de maturação de frutos (MARTINS et al., 2021). Desta maneira, a utilização das RPAs pode contribuir para o avanço nas pesquisas cafeicultura de precisão auxiliando na identificação de pragas e doenças e deficiências hídricas e nutricionais que reduzem e prejudicam a produtividade das lavouras.

2 OBJETIVOS

2.1 Objetivo geral

Analisar as potencialidades de imagens de alta resolução geradas por dados de sensoriamento remoto multiespectral obtidos a partir de RPA na caracterização de parâmetros morfofisiológicos de cafeeiros.

2.2 Objetivos específicos

- Avaliar a relação entre a produção e a desfolha quantificada em campo e obtida por meio de imagens de RPA;
- Identificar qual índice de Vegetação (IV) é adequado para explicar a metodologia de inversão de Chl e avaliar as relações entre os IVs obtidos a partir de imagem RPA e os índices de Chl_{leaf} e de Chl_{canopy} em cafeeiros no período chuvoso e da seca;
- Caracterizar a temperatura obtida por meio de uma RPA e avaliar sua relação com o potencial hídrico e condutância estomática de uma lavoura experimental de cafeeiros por meio do uso das técnicas geoestatísticas.

3 REFERENCIAL TEÓRICO

3.1 Aspectos gerais da cultura do cafeeiro

O cafeeiro, pertencente ao gênero *Coffea*, é um arbusto perene da família Rubiaceae, tendo como espécies principais a *Coffea arabica* (café arábica) e a *Coffea canephora* (café robusta e café conilon). É uma planta de crescimento contínuo, com ramos ortotrópicos que crescem verticalmente e ramos plagiotrópicos que crescem horizontalmente e apresenta um ciclo fenológico de dois anos, resultando em uma frutificação anual alternada, com alta e baixa produtividade, conhecido também como bienalidade. Sendo assim um ano a quantidade de frutos aumenta e no ano seguinte diminui (SILVA; REIS, 2013).

O café é uma *commodite* agrícola, com importância na pauta de exportação brasileira. Além disso, é um produto de destaque na história do desenvolvimento do país, sendo uma bebida de grande receptividade, com consumo habitual, além de ter agradável aroma e sabor (BLISKA et al., 2009). Quanto ao consumo, o USDA (2021) estima que, no corrente ano-safra, a demanda mundial deverá crescer 1,5% em relação ao período anterior (expansão de 2,5 milhões de sacas).

Sendo um dos principais produtos agrícolas, o café tem grande importância no mercado nacional e internacional. Segundo USDA (2021) a estimativa de produção de café para a safra 2020/2021 em escala mundial é de 175,5 milhões de sacas (60 kg). Dentre os países produtores de café, o Brasil ocupa a primeira posição contribuindo com 38,7 % da produção mundial de café, seguido de Vietnã e Colômbia, sendo o maior produtor e exportador de *Coffea arabica*, e o segundo maior produtor de *Coffea canephora* da produção mundial destas cultivares (USDA, 2021).

A nível de estado, Minas Gerais concentra sua maior área com a produção de café da espécie *Coffea arabica*, 1.262,6 mil hectares, correspondendo, na safra de 2020/2021, a quase 71% da área ocupada com café arábica no país, além de registrar recorde de produção na última safra de 2019/2020, alcançando cerca de 34,6 milhões de sacas do grão beneficiado o que representando 55% da produção total do país (CONAB, 2021).

Pelo seu alto valor agregado e por ser um dos principais produtos agrícolas, o desenvolvimento de pesquisas e novas tecnologias no ramo da cafeicultura tornam-se indispensáveis, principalmente nas regiões com destaque na produção, como Minas Gerais, visto sua importância comercial e demanda de consumo. Os cafeicultores veem se empenhando para aumentar a produtividade com a utilização de insumos como fertilizantes, herbicidas e pesticidas, com a adoção de variedades modernas de plantas, cultivares, mecanização e novas

técnicas agrícolas (FENG et al., 2017), no entanto, frequentemente se faz o uso destas técnicas sem critérios preestabelecidos e de forma imprudente gerando gastos desnecessários.

3.1.1 Parâmetros Morfológicos

Os atributos de uma lavoura cafeeira que podem ser determinados por meio de mensurações físicas ou visuais são denominados de parâmetros morfológicos (COGO et al., 2018), sendo estes atributos relacionados à estrutura externa da planta. Destaca-se alguns parâmetros morfológicos que podem inferir sobre o crescimento e desenvolvimento de cafeeiros como: altura de planta (m), diâmetro de copa (m), espaçamento entre linhas (m), espaçamento entre plantas (m), índice de área foliar (IAF) ($m^2.m^{-2}$), porcentagem de cobertura do terreno pelas plantas de café (%), rugosidade (m), densidade populacional (número de plantas ha^{-1}), biomassa ($t ha^{-1}$), desfolha (kg, m^2, m^3, L), enfolhamento (%), força de desprendimento dos frutos (N), produção (L), dentre outros.

O IAF é um parâmetro morfológico que pode ser mensurado na lavoura sendo a relação entre a área foliar e a área do terreno ocupado pela cultura. Segundo Favarin et al. (2002), a área foliar de uma cultura é um parâmetro indicativo de produtividade devido ao processo fotossintético ocorrido nas folhas. Deste modo, a compreensão da área foliar da planta é essencial para estudos morfofisiológicos, pois de acordo com Partelli et al. (2006), as características morfológicas foliares, como a área foliar, estão diretamente relacionadas com a interceptação de luz, taxa fotossintética e crescimento da planta em geral.

Segundo Ferreira et al. (2015), estudos sobre a área foliar abrange análises de crescimento e até quantificação de danos causados por pragas e doenças. Assim, com este parâmetro é possível inferir a eficiência fotossintética, padrões de crescimento e desenvolvimento, variações no crescimento causadas por diferenças ambientais e genéticas, danos decorrentes de pragas e doenças (FONSECA; CONDÉ, 1994).

No nível orbital, estudos realizados por Ramirez e Júnior (2010) conseguiram estimar alguns parâmetros morfológico como: espaçamentos entre linhas e plantas, altura, IAF, diâmetro da copa, porcentagem de cobertura vegetal, rugosidade, variedade e biomassa, de uma lavoura cafeeira a partir de imagens de satélites com alta resolução. Já em nível aéreo, Santos et al. (2020a) estudaram a estimativa de parâmetros morfológicos de cafeeiros como: altura e diâmetro de copa, com base em nuvem de pontos *structure from motion* (SfM) obtida por uma *Unmanned Aerial Vehicles* (UAV), e concluíram que a obtenção deste tipo de estimativa apresenta uma importância prática, pois facilita a obtenção de dados de forma indireta de

lavouras, evitando a necessidade de medições do solo e podendo criar séries históricas afim de monitoramento da cultura.

Sendo assim, parâmetros morfológicos, como a área foliar, são variáveis relevantes, pois indicam o estado da cultura. De acordo com Usha e Singh (2013), as variações do IAF podem indicar vários tipos de estresse na vegetação como nutricional ou hídrica. Além disso, o IAF pode indicar severidade de infestações de pragas e doenças, uma vez que um dos sintomas dessas injúrias é a desfolha, além de outros estresse abióticos que a lavoura venha a sofrer como déficit hídrico ou variação de temperatura.

Entender a relação entre parâmetros morfológicos e a refletância da vegetação é importante para os estudos e aplicações do sensoriamento remoto (SR) na vegetação, bem como contribuir de maneira efetiva no uso das imagens de alta resolução espacial para o cadastro da cultura e também auxiliar os métodos atuais de previsão e monitoramento de safras (RAMIREZ et al., 2010).

Segundo Marin et al. (2019) metodologias de SR estão sendo aplicadas nas culturas agrícolas a fim de se obter melhores práticas de manejo. Segundo Bernardes et al. (2012), na cafeicultura, o uso de dados de SR é oportuno diante da dificuldade de obtenção de dados *in situ* em escala regional visto que requer mão de obra qualificada, vistorias *in situ*, demanda de tempo excessivo e, como consequência, o aumento do custo de produção.

Outro parâmetro morfológico que pode ser mensurado na lavoura é a desfolha, a qual é um dos principais danos causados pela colheita, e isso afeta diretamente a produtividade das lavouras. Com isso, a quantificação da desfolha na colheita é um fator importante para acompanhar a produção da lavoura. Com a desfolha, a planta produzirá menos no ano seguinte, pois utilizará suas reservas para recompor a vegetação e terá uma menor frutificação como consequência (SILVA et al., 2010). Desta maneira, a ocorrência frequente de tal fato proporcionará o estresse na planta e redução de sua longevidade (BÁRTHOLO; GUIMARÃES, 1997; OLIVEIRA et al., 2007).

Souza et al. (2006) ressaltam a importância de as máquinas colhedoras de cafeeiros apresentarem um baixo índice de desfolhamento, pois preservam a estrutura arbórea da planta e também garantem um produto de melhor qualidade e com menos impurezas. Ressalta-se que a desfolha nem sempre é prejudicial, embora ocorra um aumento das impurezas nos frutos colhidos, ela é um indicador de queda de folhas e galhos velhos e doentes (ARISTIZÁBAL-TORRES et al., 2000). Assim, segundo Souza et al. (2006), a desfolha favorece uma poda sanitária da planta.

Entretanto esta desfolha deve ser mínima a fim de não comprometer o desenvolvimento das plantas. Magalhães (1964) estudou o efeito da redução da superfície foliar sobre o desenvolvimento de cafeeiros, os autores concluíram que a eliminação de 25, 50 e 75% da área foliar resultou em retardamento no desenvolvimento das folhas de 32,6, 42,7 e 54% e decréscimos de 10,5; 36,2 e 47,3% respectivamente, no desenvolvimento das partes aéreas das plantas.

Estudos sobre a desfolha reverbera a importância da perda de área foliar, visto que qualquer fator que reduza a área foliar influenciará negativamente sobre a capacidade fotossintetizadora da planta (MAGALHÃES, 1964). Esta perda de área foliar deve ser levada em consideração diante da característica da bienalidade própria dos cafeeiros devido a alternância nos padrões de desfolha que tendem a refletir na produção.

Diante deste cenário, analisar as potencialidades de imagens de alta resolução geradas por dados de SR multiespectral obtidos a partir de RPA na caracterização de parâmetros morfológicos é de grande relevância, visto que na literatura as pesquisas são incipientes para explorar tais parâmetros na cafeicultura.

3.1.2 Parâmetros Fisiológicos

Podem ser citados alguns parâmetros fisiológicos como pigmentos fotossintéticos, condutância estomática, quantidade de material senescente, umidade e potencial hídrico. Tais parâmetros são importantes pois as propriedades espectrais da vegetação podem ser fortemente determinadas por parâmetros morfológico e fisiológicos (FORMAGGIO; SANCHES, 2017).

Os principais pigmentos fotossintéticos presentes nas plantas são a clorofila a e b, os carotenóides (carotenos e as xantofilas). Estes pigmentos absorvem energia em diferentes comprimentos de onda, sendo a clorofila a absorve de 0,43 a 0,66 μm , a clorofila b absorve de 0,453 a 0,643 μm , α -Caroteno em 0,42; 0,44 e 0,47 μm , β -Caroteno em 0,425; 0,45 e 0,48 μm e as xantofilas em 0,425; 0,445 e 0,475 μm (MOREIRA, 2012). Segundo Santos et al. (2019), os pigmentos fotossintéticos desempenham papel essencial na fisiologia da planta, além de serem correlacionados com as concentrações de nitrogênio (N) e magnésio foliar (Mg). Sendo assim, podemos considerar que dentre os pigmentos fotossintéticos o teor de clorofila da folha é um indicador que representa o estado de crescimento das culturas sendo crucial para práticas agrícolas (HAN et al., 2019).

O N é um macro nutriente exigido pelas plantas cafeeiras em alta quantidade, por isso é considerado um dos nutrientes essenciais às lavouras tornando-o um fator limitante à produção

de café (PARREIRAS et al., 2020). Esta limitação se deve à participação do N na síntese de componentes celulares, como a clorofila, aminoácidos e ácidos nucleicos, desempenhando um papel essencial na fotossíntese, além de fazer parte da estrutura, do metabolismo e da osmorregulação das plantas (TAIZ; ZEIGER, 2017).

De acordo com Guimarães et al. (2002) a deficiência de N causa a redução de tamanho e da quantidade de cloroplastos, resultando-os em amarelados (falta de clorofila), provocando uma menor atividade fotossintética e conseqüentemente, uma menor produção de amido.

O teor de clorofila das plantas está entre os principais indicadores de deficiência de N, com isso, equipamentos como: clorofilômetros, sensores óticos e sensores multiespectrais são úteis para avaliar o status de N nas plantas (FORMAGGIO; SANCHES, 2017).

Tais equipamentos podem ser amplamente utilizados devido a obtenção de medidas de índices de clorofila de forma indireta, rápida e pouco onerosa. Estimativas de teores de clorofila nas folhas são úteis para aplicações agrícolas, que são relativamente importantes para o crescimento das safras agrícolas (LEE et al., 2011). A clorofila a e a clorofila b têm relações com N e Mg, pois apresentam em sua constituição tais nutrientes, na qual o Mg é considerado a molécula central destes pigmentos (TAIZ; ZEIGER, 2017).

A condutância estomática destaca-se como sendo outro parâmetro fisiológico. O processo de transpiração das folhas ocorre devido a evaporação da água das superfícies celulares para os espaços intercelulares e dos espaços intercelulares para a atmosfera, através dos estômatos, sendo considerada o ponto final no movimento do vapor de água da folha para a atmosfera. A condutância estomática é o grau de abertura dos estômatos e, é diretamente proporcional à transpiração. Segundo Souza et al. (2011) o porômetro é um equipamento que permite obter a regulação da transpiração em função das variáveis micrometeorológicas, ou seja, é um equipamento que permite medir a condutância estomática.

Outro parâmetro fisiológico utilizado como indicativo de estresse hídrico na cafeicultura é o potencial hídrico (PH). O PH indica o seu estado energético na qual sua medida está relacionada com os fluxos da água no sistema solo-planta-atmosfera, e indica a diferença entre o estado energético no sistema considerado e em um estado de referência conceituado como zero (BERGONCI et al., 2000). De acordo com Costa e Marengo (2007) o PH diminui se a planta perde água a uma taxa superior à sua capacidade de absorção e transporte, como consequência tem-se o fechamento dos estômatos e redução da fotossíntese, o que leva a um aumento de temperatura da folha.

Deste modo, os parâmetros fisiológicos são geralmente associados aos processos de crescimento e desenvolvimento das plantas, sendo úteis para indicar interrupções ocorridas

nestes processos. Neste contexto, metodologias que permitam monitorar tais parâmetros e tenham baixo custo e flexibilidade operacional são úteis para aplicações de agricultura de precisão a fim de obter-se uma gestão melhor e mais eficiente da lavoura.

3.2 Sensoriamento Remoto

Para identificar as variações no campo e aplicar estratégias para lidar com a variabilidade espacial das lavouras, pode-se utilizar tecnologias geoespaciais (ZHANG & KOVACS, 2012). Dentro destas tecnologias pode-se citar: Sistemas de Informação Geográfica (SIG), Sistema Global de Navegação por Satélite (*Global Navigation Satellite System*-GNSS), Sensoriamento Remoto (SR), que permitem auxiliar na obtenção de dados e dar suporte localizado no manejo agrícola.

O SR é a aquisição de informações sobre um objeto à distância, utilizando sensor acoplado à uma plataforma como: um satélite no nível orbital ou uma Aeronave Remotamente Pilotada do termo em inglês *Remotely Piloted Aircraft* (RPA) no nível aéreo, que medem a radiação eletromagnética (REM) refletido ou emitido pelo objeto (WEISS; JACOB; DUVEILLER, 2020).

A REM refletida pela superfície terrestre pode ser subdividida em faixas espectrais denominadas bandas espectrais com diferentes comprimentos de ondas. A banda espectral do visível que compreende as bandas azul, verde e vermelho do termo em inglês RGB (*Red- R, Green- G, and Blue- B*), são ondas nas quais consegue-se captar e interpretar. Existem outras bandas não visíveis como as bandas do Infravermelho, nas quais podemos destacar as bandas da borda do vermelho (*Red Edge- REG*) com comprimento de onda de variando de 0,73–0,74 μm e a banda do infravermelho próximo (*Near Infrared- NIR*) com comprimento de onda de 0,77–0,81 μm . Na tabela 2.2.1, é possível observar outras bandas espectrais utilizadas em SR.

Tabela 3.1- Bandas espectrais utilizadas em Sensoriamento Remoto.

Classe		Comprimento de onda
Visível		0,4-0,7 μm
Infravermelho	Próximo	0,7-1,3 μm
	Ondas Curtas	1,3-3 μm
	Médio	3-8 μm
	Termal	8-14 μm
	Distante	14 μm - 1mm

Fonte: Adaptado de Formaggio e Sanches (2017).

A banda do infravermelho termal está relacionada com a energia envolvida que é derivada de vibrações moleculares decorrentes da temperatura dos corpos sendo que, qualquer corpo que possua temperatura acima do zero absoluto (0°K ou -273°C) emite REM, que pode ser captada por sensores termais (KUENZER; DECH, 2013).

O tipo de informação obtida a partir do SR depende das propriedades específicas do sensor como: resolução espacial, resolução espectral, resolução radiométrica e resolução temporal, e de sua plataforma (WEISS; JACOB; DUVEILLER, 2020).

Segundo Formaggio e Sanches (2017), a resolução espacial corresponde ao tamanho do menor objeto no terreno que poderá ser identificado na imagem. Jensen (2009) pontua que a resolução espacial é uma medida da menor separação angular ou linear entre dois objetos que pode ser determinada pelo sistema de sensoriamento remoto, na qual quanto menor a resolução espacial nominal, maior o poder de resolução espacial do sistema de sensoriamento remoto. A resolução espectral é o número e o tamanho de intervalos de comprimentos de onda específicos no espectro eletromagnético, denominadas de bandas, aos quais um instrumento de sensoriamento remoto é sensível (JENSEN, 2009). Segundo Formaggio e Sanches (2017), a resolução espectral está relacionada à quantidade de bandas, ou seja, um sensor que tem uma quantidade elevada de bandas é chamado de sensor de alta resolução espectral.

Já a resolução temporal de um sistema de sensoriamento remoto segundo Jensen (2009) refere-se à frequência que o sensor registra imagens de uma determinada área. Ou seja, esta resolução refere-se ao tempo em que um mesmo ponto da superfície terrestre leva para ser revisitado (FORMAGGIO; SANCHES, 2017). E, por fim, a resolução radiométrica, segundo Formaggio e Sanches (2017), refere-se à menor variação de intensidade possível detectada pelo sensor.

Segundo Zhang & Kovacs (2012), em casos emergenciais de acompanhamento de culturas, análise de déficit nutricional, previsão de safra, os sensores orbitais não podem

fornecer dados contínuos, com alta frequência e com um nível de detalhamento alto. Além disso, apresentam limitações como custos elevados, falta de flexibilidade operacional e baixa resolução espacial e temporal (WHITEHEAD & HUGENHOLTZ, 2014). Outro fator que interfere na aquisição de imagens com sensores orbitais são as condições climáticas, em dias nublados, por exemplo, há o impedimento da passagem da energia solar ocorrendo a perda de informação de dados da superfície (HONKAVAARA et al, 2013).

Dentro deste contexto, as RPAs estão sendo estudadas e utilizadas para obtenção de imagens de alta resolução temporal (por exemplo, adquiridas várias vezes por dia), resolução espacial (em centímetros) além de baixos custos operacionais (HARDIN & HARDIN, 2010; HONKAVAARA et al. 2013; HUNT et al. 2005; LALIBERTE & RANGO, 2011; MAES & STEPPE, 2019; WEISS; JACOB; DUVEILLER, 2020; XIANG & TIAN 2011).

Outras peculiaridades que tornam as RPAs uma tecnologia com elevado potencial de detecção remota é a obtenção de dados de forma autônoma e capacidade de realizar missões, capacidade de operar em condições climáticas adversas e em ambientes perigosos e, menor risco de exposição do piloto (WHITEHEAD & HUGENHOLTZ, 2014). Desta maneira, esta tecnologia pode ser aplicada em áreas menores e em locais pontuais com facilidade de obtenção de dados em menor tempo, acompanhando o crescimento de diversas culturas, por exemplo.

3.2.1 Índices de Vegetação (IV)

Diante da possibilidade de utilizar câmeras multiespectrais com diferentes bandas a bordo das RPAs, os IVs podem ser utilizados como uma ferramenta de processamento das imagens para diferenciar e indicar variações espaço temporais nas lavouras.

Os IVs consistem em uma combinação de duas ou mais bandas espectrais o que permite monitorar e detectar alterações na lavoura a partir da resposta espectral que cada cultura possui em sua fenologia. Segundo Ahmad et al. (2021), os IVs fornecem informações vitais para o monitoramento da cultura e tomada de decisão servindo como um guia enquanto se planeja a coletar de dados específicos da cultura.

Os parâmetros como índice de vegetação por diferença normalizada (NDVI-*Normalized Difference Vegetation Index*), conteúdo de água na folha, cobertura do solo, índice de área foliar (IAF) e conteúdo de clorofila podem ser quantificados usando câmeras multiespectrais embutidas em RPA (SAHA et al. 2018).

Ahmad et al. (2021) citam os índices de vegetação mais comumente usados para monitoramento de safra e avaliação biofísicas e fisiológica de culturas como: RVI (*Ratio*

vegetation index) utilizado para estimativa de biomassa verde e monitoramento; SAVI (*Soil-Adjusted Vegetation Index*) melhora a sensibilidade do NDVI para imagens com solo exposto; OSAVI (*Optimized Soil-Adjusted Vegetation Index*) calcula a biomassa acima do solo, teor de nitrogênio foliar e teor de clorofila; MTVI2 (*Second modified Triangular vegetation index*) predição do status de N na folha; CIgreen (*Chlorophyll index – Green*) determina conteúdo de clorofila na folha, dentre outros que podem ser aplicados na cafeicultura de precisão.

Diante disso, os IVs são um método não destrutivo sendo úteis para estimativas de diversos parâmetros morfológicos e fisiológicos da vegetação bem como, monitorar lavouras para obter informações e produtos em tempo hábil, com baixo custo, alto valor tecnológico e com precisão.

3.3 Agricultura de Precisão e Cafeicultura de Precisão

O monitoramento ao longo do ano, de forma frequente e com mais precisão se faz necessário para atender a demanda e, também, para manter a agricultura atualizada com o intuito de melhorar a produtividade e diminuir custos de produção. Neste cenário podemos destacar a Agricultura de Precisão ou agricultura 4.0 ou ainda agricultura digital, termos que surgiram com o aporte de novas tecnologias no campo (AHMAD et al., 2021).

A Agricultura de Precisão (AP) pode ser amplamente definida como um sistema em que a prática de gestão é realizada no lugar certo, com a intensidade certa e no momento certo (MULLA, 2013). Segundo Unal e Topakci (2014) a AP pode ser definida também como um sistema de produção agrícola com base tecnológica e de informação na qual é utilizada para analisar, determinar e gerenciar fatores do campo como variabilidade espacial e temporal para obter o máximo de sustentabilidade, lucro e proteção ambiental.

Ao invés de tratar a lavoura de maneira homogênea, como nos manejos convencionais, nos quais fazem manejos para toda a lavoura, a AP faz-se divisões em zonas de manejo, zonas de gerenciamento ou em blocos que recebem tratamentos de maneira diferenciada e ajustada, obtendo economia de recursos, redução de impacto ambiental e aumento das receitas (MAES; STEPPE, 2019).

No setor cafeeiro, a aplicação das tecnologias de AP é comumente conhecida como cafeicultura de precisão (CP) (FERRAZ et al., 2017). A AP no campo do café representa técnicas e tecnologias que auxiliam os cafeicultores no manejo de singularidades de produção, como propriedades do solo, fertilização e colheita para aumentar a eficiência, produtividade e qualidade da produção do café (FERRAZ et al., 2018). Contudo, a técnica de AP aplicada na cultura do café pode ser economicamente viável para os produtores (FERRAZ et al., 2011).

Para a aplicação da AP no campo é necessário o uso de tecnologias e sistemas de informação que favorecem dados sobre a variabilidade espacial e temporal da cultura. Neste contexto uma recente forma de aquisição de imagens digitais remotas tem emergido, os Sistemas de Aeronaves Não Tripuladas correspondente à terminologia em inglês *Unmanned Aircraft Systems* (UAS), ou também conhecidos como RPA, “drone” ou ainda Veículos Aéreos Não Tripulados (VANT), correspondente à terminologia em inglês *Unmanned Aerial Vehicles* (UAV), que podem captar dados e informações de alvos de forma indireta a qualquer momento, desde que tenha condições favoráveis e bateria e, com alta resolução espacial.

Segundo Ahmad et al. (2021) a incorporação de RPAs na AP é uma tendência agrícola crescente com um potencial de abrir novos caminhos agrícolas que sejam mais viáveis economicamente. Deste modo, observou-se um aumento exponencial nos últimos 10 anos nas pesquisas usando RPA com aplicações na AP (MAES; STEPPE, 2019).

Diante disso, o emprego da AP e CP para monitorar e realizar aplicações de forma precisa e localizada e, minimizar custos operacionais na cafeicultura são relevantes. Portanto, há oportunidades de pesquisas utilizando estas tecnologias emergentes na CP.

3.3.1 Uso de Aeronaves remotamente pilotadas na cafeicultura de precisão

Recentes pesquisas utilizando RPA na CP estão sendo desenvolvidas utilizando câmeras comerciais RGB (vermelho-verde-azul) (SANTANA et al., 2021; SANTOS et al. 2020a; SANTOS et al. 2020b; SANTOS et al. 2020c; CUNHA et al., 2019; PUTRA; SONI, 2018; OLIVEIRA et al., 2018). As câmeras comerciais RGB são baratas e têm uma alta resolução espacial, entretanto apresentam uma resolução espectral relativamente pobre (NIJLAND et al. 2014).

Para cafeicultura alguns estudos vêm sendo desenvolvidos utilizando câmeras convencionais, a exemplo de Cunha et al. (2019), que desenvolveram um método para determinar o volume da vegetação de lavouras de café a partir de imagens de câmera convencional a bordo de RPA e compararam com a estimativa tradicional de volume de vegetação coletada. Com isso, os autores concluíram que o método é possível, rápido e permite a avaliação de grandes áreas, não apresentando diferenças significativas em relação ao método tradicional.

Em um estudo realizado por Santana et al. (2021), foi utilizado uma câmera convencional a bordo de uma RPA em lavoura cafeeira para avaliar a influência da densidade de pontos de controles alocados em diferentes distribuições e submetido a diferentes altitudes

de voo para avaliar a precisão geométrica das imagens. Os autores observaram que uma boa distribuição dos pontos de controles é importante, mas a densidade dos pontos por imagem foi mais relevante na obtenção de um RMSE inferior. Este estudo demonstra a importância de se utilizar pontos de controle para o georreferenciamento correto das imagens obtidas por RPAs.

Em outro estudo desenvolvido por Oliveira et al. (2018) também utilizou-se câmera convencional a bordo de uma RPA, os autores propuseram uma metodologia para detecção de falhas em lavouras cafeeiras utilizando imagens aéreas de alta resolução, os resultados do estudo mostram que o método proposto é confiável para identificar com precisão falhas em linhas de lavouras de café.

Para monitoramento de nitrogênio foliar, Parreiras et al. (2020) utilizaram índices de vegetação baseados em imagens RGB obtidas a partir de RPA com *Random Forest* para monitorar o status de nitrogênio das plantas. Como resultado, os autores observaram que os índices utilizando as bandas do visível não foram capazes de monitorar o nitrogênio, e recomendam pesquisas pois representar uma alternativa mais econômica, uma vez que podem ser obtidos utilizando câmeras convencionais.

Estudos sobre a obtenção de parâmetros morfológicos como altura e diâmetro de lavoura cafeeira (SANTOS et al. 2020a) e obtenção de Índice de Área Foliar (*Leaf area index-LAI*) (SANTOS et al. 2020b) a partir de câmera convencional RGB a bordo de RPA comercial foram altamente significativos quando comparados com dados coletados a campo. E, estudos realizados por Santos et al. (2020c), propuseram uma metodologia de estimativa do coeficiente de cultura (K_c) em curto prazo, utilizando relações entre K_c e parâmetros morfológicos do cafeeiro (área foliar, densidade de plantas e manejo de plantas daninhas), isso foi possível devido a um compilado de dados disponíveis na literatura e comparando com o K_c determinado a partir de dados de imagem obtidas por uma câmera convencional RGB acoplada a uma RPA e, também, de dados obtidos a campo.

Putra e Soni (2018), estudaram a possibilidade de estimativa de clorofila a e b, Carotenóides e nitrogênio utilizando índices de vegetação em cafeeiros Robusta em diferentes estádios de crescimento e condições de campo usando uma câmera digital para medição de folhas direta. Ressalta-se que os autores realizaram a obtenção dos dados com uma câmera a partir do solo. Pesquisas deste tipo possibilitam comparativo entre diferentes tipos de câmeras além de obter resultados utilizando câmeras convencionais de baixo custo acoplado em RPA em uma visão aérea.

Outros sensores que podem ser embarcados nas RPAs são as câmeras multiespectrais e hiperespectrais, nos quais apresentam melhor resolução espectral. Estas câmeras consistem em

um conjunto de sensores com lentes diferentes, com cada sensor sensível em uma região espectral (MAES; STEPPE, 2019), e por serem mais sensíveis conseguem captar várias regiões espectrais possibilitando cálculo de uma infinidade de IV.

Poucos trabalhos exploraram a utilização de câmeras multiespectrais em lavouras cafeeiras. Cita-se o estudo desenvolvido por Johnson et al. (2004), que coletaram imagens de uma câmera multiespectral georreferenciada da cultura do café na safra de 2002, utilizando RPA, e comparou os pixels da imagem com os dados de refletância coletados em campo, criando um índice de maturação da cultura para monitorar o momento propício para realizar a colheita. E, também, o estudo desenvolvido por Herwitz et al. (2004), no qual os autores também utilizaram uma câmera multiespectral a bordo de uma RPA para coleta de imagens com objetivo de monitorar e apoiar as decisões na plantação de café. Para os autores vários aspectos de manejo da cultura podem se beneficiar da observação aérea. O estudo demonstrou a capacidade de monitoramento da RPA em um período prolongado, além de obter imagens com alta resolução espacial, mapear focos de capim-colonião e diferenciar a cobertura do solo nas áreas monitoradas, assim concluíram que as RPAs são uma ferramenta ampla que complementam a utilização de satélites e aeronaves pilotadas para apoio à agricultura.

Dentro do contexto de utilização de câmera multiespectral a bordo de RPA, Marin et al. (2021b) utilizaram o método de aprendizado *Random Forest* aplicado a índices de vegetação para mapear a variabilidade espacial do teor de nitrogênio nas plantações de café além de determinar o índice de vegetação mais eficiente para prever o teor de N em cafeeiros. Com este estudo os melhores resultados foram obtidos usando o *Green Normalized Difference Vegetation* (GNDVI) e *Green Optimized Soil Adjusted Vegetation Index* (GOSAVI). Os autores concluíram que o modelo possibilitou avaliar a distribuição espacial de N nos cafeeiros, bem como quantificar a deficiência de N na cultura para toda a área. Pesquisas como estas otimizam o suprimento de N na lavoura, melhorando a produtividade, diminuindo recursos além de reduzir os danos ambientais de aplicações em excesso.

Destaca-se também as câmeras termais, que atuam no infravermelho termal, estas câmeras podem auxiliar na detecção de estresse hídrico, por exemplo. Além destas câmeras, existem sensores como os radares de abertura sintética (*synthetic aperture radar-SAR*) a bordo de RPA que podem ser utilizados em pesquisas na CP, como o estudo de Oré et al. (2020), no qual os autores desenvolveram um novo método para estimar o crescimento de diferentes culturas através da execução de trajetórias circulares de vôo com uma interferometria diferencial SAR a bordo de uma RPA. Os autores concluíram que é possível estimar com segurança pequenas variações de altura, e no caso do café, obtiveram o crescimento estimado

de 11 cm em aproximadamente quatro meses, com desvio padrão de 6 cm. E, mencionaram ainda que, essa taxa de crescimento é difícil de perceber visualmente ou de medir com ferramentas convencionais.

Diante do potencial das câmeras termais, multiespectrais, hiperespectrais e radares tem-se a possibilidade de expandir as pesquisas na CP uma vez que as pesquisas utilizando tais câmeras e sensores são emergentes nesta cultura e ainda existem lacunas como parâmetros, configurações e potencialidades. Além disso, existem outras limitações que podem ser desenvolvidas por meio de pesquisas, tais como: a melhoria no tempo de processamento das imagens para obtenção de produtos; a automação do processamento das imagens; uso de aprendizado de máquina para análise de imagem; a divulgação dos produtos em tempo real; a capacidade dos sensores embarcados; a melhoria na autonomia das RPA e difusão da tecnologia para agricultores.

Dentro deste contexto, encontra-se possibilidades para estudar o uso destas plataformas aéreas combinadas com sensores, multiespectrais, hiperespectrais e sensores termais para correlacionar com parâmetros fisiológicos, estresse hídrico, estresse nutricional, pragas e doenças e outros fatores relacionados à saúde da planta nos quais faixas maiores do espectro eletromagnético conseguem captar com mais eficiência.

4 CONSIDERAÇÕES GERAIS

A utilização das RPAs na agricultura teve avanços significativos na última década sendo uma tecnologia que pode contribuir para a Agricultura e Cafeicultura de Precisão a fim de identificar variabilidades na lavoura, realizar monitoramentos, detectar anomalias, pragas e doenças, com benefício das imagens de alta resolução espacial.

Pesquisas sobre as potencialidades desta tecnologia na cafeicultura de forma mais aprofundada são úteis para obter-se uma eficiência do uso da tecnologia. Assim, por meio dos conceitos de sensoriamento remoto aplicados no processamento das imagens de RPA, pode-se obter um vasto conjunto de dados da cultura de interesse e transformá-los em informações relevantes e confiáveis ao produtor. Diante disso, é possível obter resultados que podem auxiliar o produtor a identificar, de forma clara e rápida, variações na lavoura podendo assim adotar manejos precisos e localizados na cultura, reduzindo assim os custos de produção e visando maximizar a produtividade.

REFERÊNCIAS

AHMAD, A.; ORDOÑEZ, J.; CARTUJO, P.; MARTOS, V. Remotely Piloted Aircraft (RPA) in Agriculture: A Pursuit of Sustainability. **Agronomy**, [S. l.], v.11, n.1, p.7, 2021.

ARISTIZÁBAL-TORRES, I.D.; OLIVEROS-TASCÓN, C.E.; SANZ-URIBE, J.R.; MONTOYA-RESTREPO, E.C.; ALVAREZ-MEJÍA, F. Cosecha mecánica de café aplicando vibraciones circulares al tallo del cafeto. **Cenicafé**, [S. l.], v.51, p.41-53, 2000.

ATZBERGER, C. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. **Remote sensing**, [S. l.], v.5, n.2, p.949-981, 2013.

BARBOSA, B. D. S.; FERRAZ, G.A.S.; SANTOS, L.M.D.; SANTANA, L. S.; MARIN, D.B.; ROSSI, G.; CONTI, L. Application of RGB Images Obtained by UAV in Coffee Farming. **Remote Sensing**, [S. l.], v. 13, p. 2397, 2021.

BÁRTHOLO, G.F.; GUIMARÃES, P.T.G. Cuidados na colheita e preparo do café. **Informe Agropecuário**, Belo Horizonte, v.18, n.187, p.33-42, 1997.

BERGONCI, J.I.; BERGAMASCHI, H.; BERLATO, M.A.; SANTOS, A.O. Potencial da água na folha como um indicador de déficit hídrico em milho. **Pesquisa Agropecuária Brasileira**, [S. l.], 35(8): 1531-1540, 2000.

BERNARDES, T.; MOREIRA, M. A.; ADAMI, M.; GIAROLLA, A.; RUDORFF, B. F. T. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **Remote Sensing**, v.4, n.9, 2492-2509, 2012.

BLISKA, F. M. M.; VEGRO, C. L. R.; AFONSO JÚNIOR, P. C.; MOURÃO, E. A. B.; CARDOSO, C. H. S. Custo de produção do café nas principais regiões produtoras do País. **Informações Econômicas**, [S. l.], v.39, n.09, p.5-20, 2009.

CARVALHO, H.F.; GALLI, G.; FERRÃO, L. F. V.; NONATO, J. V. A.; PADILHA, L.; MALUF, M. P.; FRITSCHÉ-NETO, R. The effect of bienniality on genomic prediction of yield in arabica coffee. **Euphytica**, [S. l.], v.216, n.101, 2020.

CARVALHO, L. C. C.; SILVA, F. M. D.; FERRAZ, G. A.; FIGUEIREDO, V. C.; CUNHA, J. P. B. Comparação entre amostragem foliar convencional e de precisão para análise de micronutrientes na cafeicultura. **Coffee Science**, Lavras, v.12, n.2, p. 272 - 281, 2017.

COGO, F. D.; LOPES, F. A. B.; PIRES, F. R.; ALMEIDA, S. L. S.; CAMPOS, K. A. Parâmetros de crescimento de mudas de café: meta-análise. **The Journal of Engineering and Exact Sciences**, [S. l.], v.4, n.3, 0304-0310, 2018.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da Safra Brasileira de Café, Brasília, DF, v. 8, safra 2021, n. 1, primeiro levantamento, jan. 2021.

COSTA, G. F. D.; MARENCO, R. A. Fotossíntese, condutância estomática e potencial hídrico foliar em árvores jovens de andiroba (*Carapa guianensis*). **Acta amazônica**, [S. l.], v.37, p.229-234, 2007.

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

FAVARIN, J. L.; NETO, D.D.; GARCÍA, A.G.; NOVA, N.A. V.; FAVARIN, M.G.G.V. Equações para a estimativa do índice de área foliar do cafeeiro. **Pesquisa Agropecuária Brasileira**, Brasília, v.37, n.6, p.769-773, 2002.

FENG, L.; DAI, J. L.; TIAN, L. W.; ZHANG, H. J.; LI, W. J.; DONG, H. Z. Review of the technology for high-yielding and efficient cotton cultivation in the northwest inland cotton-growing region of China. **Field Crops Research**, [S. l.], v. 208, p. 18–26, 2017.

FERRÃO, L.F.V.; FERRÃO, R.G.; FERRÃO, M.A.G; FONSECA, A.; CARBONETTO, P.; STEPHENS, M.; GARCIA, A.A.F. Accurate genomic prediction of *Coffea canephora* in multiple environments using whole-genome statistical models. **Heredity**, [S. l.], v.122, p.261–275, 2019.

FERRAZ, G. A. E. S.; SILVA, F. M. da; OLIVEIRA, M. S. de; CUSTÓDIO, A. A. P.; e FERRAZ, P. F. P. Spatial variability of plant attributes in a coffee plantation. **Revista Ciência Agronômica**, [S. l.], v.48, n.1, p.81-91, 2017.

FERRAZ, G. A.; OLIVEIRA, M. S. D.; SILVA, F. M. D.; SALES, R. S.; CARVALHO, L. C. C. Plant sampling grid determination in precision agriculture in coffee field. **Coffee Science**, Lavras, v.13, n.1, p.112-121, 2018.

FERRAZ, G.A.S.; SILVA, F.M.; CARVALHO, F.M.; COSTA, P.A.N.; CARVALHO, L.C.C. Viabilidade econômica do sistema de adubação diferenciado comparado ao sistema de adubação convencional em lavoura cafeeira: um estudo de caso. **Engenharia Agrícola**, [S. l.], v.31, p. 906-915, 2011.

FERREIRA, A. D.; PARTELLI, F. L.; OLIOSI, G.; AYOAMA, E. M.; GILES, J. A. D.; KROHLING, C. A. Morfologia foliar de quatro genótipos de café arábica e conilon na região norte do Espírito Santo. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 9., 2015, Curitiba. Consórcio pesquisa café: oportunidades e novos desafios: anais. Brasília, DF: Embrapa Café, 2015.

FONSECA, C. E. L. DA & CONDÉ, R. DE C.C. Estimativa da Área Foliar em mudas de Mangabeira (*Hancornia speciosa* Gom.). **Pesquisa Agropecuária Brasileira**, Brasília, v.29, n.4, p.593-599, 1994.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em agricultura**. São Paulo: Oficina de textos, 2017. 288p.

GAIDA, W.; BREUNIG, F. M.; GALVÃO, L. S.; PONZONI, F. J. Correção Atmosférica em Sensoriamento Remoto: Uma Revisão. **Revista Brasileira de Geografia Física**, v. 13, n. 01, p. 229-248, 2020.

GUIMARÃES, R. J.; MENDES, A. N. G.; SOUZA, C. A. S.; CAIXETA, I. F.; MORAES, J. C.; SOUZA, S. M. C.; PEDROSO, S. A.; THEODORO, V. C. A.; CARVALHO, V. L. **Cafeicultura**. 1. ed. Lavras-MG: UFLA/FAEPE. v. 1. 317p. 2002.

HAN, L.; YANG, G.; DAI, H.; XU, B.; YANG, H.; FENG, H.; LI, Z.; YANG, X. Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. **Plant Methods**, [S. l.], v.15, n.1, p.1-19, 2019.

HARDIN, P. J., & HARDIN, T. J. Small-scale remotely piloted vehicles in environmental research. **Geography Compass**, v.4, p.1297–1311, 2010.

HERWITZ, S. R.; JOHNSON, L. F.; DUNAGAN, S. E.; HIGGINS, R. G.; SULLIVAN, D. V.; ZHENG, J.; SLVE, R. E. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. **Computers and Electronics in Agriculture**, [S. l.], v.44, n.1, p.49–61, 2004.

HONKAVAARA, E.; SAARI, H.; KAIVOSOJA, J.; PÖLÖNEN, I.; HAKALA, T.; LITKEY, P.; PESONEN, L. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, v. 5, n. 10, p. 5006-5039, 2013.

HUNT, E. R., CAVIGELLI, M., DAUGHTRY, C. S. T., MCMURTREY, J. E., & WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v.6, p.359–378, 2005.

JENSEN, J.R. **Sensoriamento remoto do ambiente: Uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora, 672 p., 2009

JOHNSON, L. F.; HERWITZ, S. R.; LOBITZ, B. M.; DUNAGAN, S. E. Feasibility of monitoring coffee field ripeness with airborne multispectral imagery. **Applied Engineering in Agriculture**, [S. l.], v. 20, n. 6, p. 845-849, 2004.

KUENZER, Claudia; DECH, Stefan (Ed.). **Thermal infrared remote sensing: sensors, methods, applications**. Springer Science & Business Media, 2013.

LALIBERTE, A. S.; RANGO, Albert. Image processing and classification procedures for analysis of sub-decimeter imagery acquired with an unmanned aircraft over arid rangelands. **GIScience and Remote Sensing**, v. 48, n. 1, p. 4-23, 2011.

LEE, Y.-J.; YANG, C.-M.; CHANG, K.-W.; SHEN, Y. Effects of nitrogen status on leaf anatomy, chlorophyll content and canopy reflectance of paddy rice. **Botanical Studies**, [S. l.], v.52, p.295–303, 2011.

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

MAGALHÃES, A. C. N. Efeito da redução da superfície foliar sobre o desenvolvimento de cafeeiros. **Bragantia**, Campinas, 23: 337-342, 1964.

MARIN, D. B. ; FERRAZ, G. A. S. ; SCHWERZ, F. ; BARATA, R. A. P. ; FARIA, R. O. ; DIAS, J. E. L. . Unmanned aerial vehicle to evaluate frost damage in coffee plants. **Precision Agriculture**, [S. l.], v.1, p. 1-15, 2021a.

MARIN, D. B.; ALVES, M. de C.; POZZA, E. A.; BELAN, L. L.; FREITAS, M. L. de O. Multispectral radiometric monitoring of bacterial blight of coffee. **Precision Agriculture**, [S. l.], v.20, n.5, p.959-982, 2019.

MARIN, D. B.; FERRAZ, G. A. S.; GUIMARAES, P. H. S.; SCHWERZ, F.; SANTANA, L. S.; BARBOSA, B. D. S.; BARATA, R. A. P.; FARIA, R. O.; DIAS, J. E. L.; CONTI, L.; ROSSI, G. Remotely Piloted Aircraft and Random Forest in the evaluation of the spatial variability of foliar nitrogen in coffee crop. **Remote Sensing**, [S. l.], v. 13, p. 1-15, 2021b.

MARTINS, R.N; PINTO, F. de A. de C.; QUEIROZ, D. M. de; VALENTE, D. S. M.; ROSAS, J. T.F. A Novel Vegetation Index for Coffee Ripeness Monitoring Using Aerial Imagery. **Remote Sensing**, [S. l.], v.13, n. 2, p. 263, 2021.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4ª Edição atualizada e ampliada – Viçosa, MG: Ed. UFV, 2012

MORIYA, E. A. S. Identificação de bandas espectrais para detecção de cultura de cana-de-açúcar sadia e doente utilizando câmara hiperespectral embarcada em VANT. **Tese de doutorado. Programa de Pós-Graduação Ciências Cartográficas, do Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente**, 2015.

MULLA, D.J. Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering**, [S. l.], v.114, p.358–371, 2013.

NIJLAND, W.; COOPS, N. C. Monitoring plant condition and phenology using infrared sensitive consumer grade digital cameras. **Agricultural and Forest Meteorology**, [S. l.], v.184, p.98–106, 2014.

OLIVEIRA, E. D; SILVA, F. M. da; SALVADOR, N.; FIGUEIREDO, C. A. P.; Influência da vibração das hastes e da velocidade de deslocamento da colhedora no processo de colheita mecanizada do café. **Engenharia Agrícola**, Jaboticabal, v. 27, n.3, p. 714-721, 2007.

OLIVEIRA, H. C.; GUIZILINI, V. C.; NUNES, I. P.; SOUZA, J. R. Failure detection in row crops from UAV images using morphological operators. **IEEE Geoscience and Remote Sensing Letters**, [S. l.], v. 15, n. 7, p. 991-995, 2018.

ORÉ, G.; ALCÂNTARA, M.S.; GÓES, J.A.; OLIVEIRA, L.P.; SIM, J.; TERUEL, B.; CASTRO, V.; BINS, L.S.; CASTRO, F.; LUEBECK, D.; MOREIRA, L.F.; GABRIELLI, L.H.; HERNANDEZ-FIGUEROA, H.E. Monitoramento do crescimento da safra com DInSAR transmitido por drones. **Remote Sensing**, [S. l.], v.12, p.615, 2020.

PARREIRAS, T.C.; LENSE, G.H.E.; MOREIRA, R.S.; SANTANA, D.B.; MINCATO, R.L. Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee. **Coffee Science**, Lavras, v.15, p.1–9, 2020.

PARTELLI, F. L.; VIEIRA, H. D.; DETMANN, E.; CAMPOSTRINI, E. Estimativa da área foliar do cafeeiro conilon a partir do comprimento da folha. **Revista Ceres**, [S. l.], v.53, n.306, p.204-210, 2006.

PUTRA, B. T. W.; SONI, P. Enhanced broadband greenness in assessing Chlorophyll a and b, Carotenoid, and Nitrogen in Robusta coffee plantations using a digital camera. **Precision Agriculture**, [S. l.], v.19, n.2, p.238-256, 2018.

RAMIREZ, G. M. e JÚNIOR J. Z. Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial. **Engenharia Agrícola**, 2010.

SAHA, A.K.; SAHA, J.; RAY, R.; SIRCAR, S.; DUTTA, S.; CHATTOPADHYAY, S.P.; SAHA, H.N. IOT based drone for improvement of crop quality in agricultural field. In **Proceedings of the 2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)**, Las Vegas, NV, USA, 8–10, p.612–615, 2018.

SANTANA, L. S.; FERRAZ, G. A. F.; MARIN, D. B.; BARBOSA, B. D. S.; SANTOS, L. M.; FERRAZ, P.F.P.; ROSSI, G. Influence of flight altitude and control points in the georeferencing of images obtained by unmanned aerial vehicle. **European Journal of Remote Sensing**, [S. l.], v.54, n.1, 59-71, 2021.

SANTOS, L. M.; FERRAZ, G. A. S.; BARBOSA, B. D. S.; DIOTTO, A. V.; MACIEL, D. T.; XAVIER, L. A. G. Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture**, [S. l.], v.21, n.6, p.1227-1241, 2020a.

SANTOS, L. M.; FERRAZ, G. A. S.; BARBOSA, B. D. S.; DIOTTO, A. V.; ANDRADE, M. T.; CONTI, L.; ROSSI, G. Determining the Leaf Area Index and Percentage of Area Covered by Coffee Crops Using UAV RGB Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v.13, p.6401-6409, 2020b.

SANTOS, L. M.; FERRAZ, G. A. S.; DIOTTO, A. V.; BARBOSA, B. D. S.; MACIEL, D. T.; ANDRADE, M. T.; ROSSI, G. Coffee crop coefficient prediction as a function of biophysical variables identified from RGB UAS images. **Agronomy Research**, [S. l.], v.18, n.2, p.1463-1471, 2020c.

SANTOS, P. L. F.; DE CASTILHO, R. M. M.; GAZOLA, R. P. D. Pigmentos fotossintéticos e sua correlação com nitrogênio e magnésio foliar em grama bermuda cultivada em substratos. **Acta Iguazu**, [S. l.], v.8, n.1, p.92-101, 2019.

SILVA, B. A. O.; REIS, E. A. A bienalidade da cafeicultura e o resultado econômico da estocagem. **Revista Custos e Agronegócio Online**, [S. l.], v. 9, n. 3, 2013.

SILVA, F. M. D.; ALVES, M. D. C.; SOUZA, J. C. S.; OLIVEIRA, M. S. D. Efeitos da colheita manual na bienalidade do cafeeiro em Ijaci, Minas Gerais. **Ciência e Agrotecnologia**, [S. l.], v.34 n.3, p. 625-632, 2010.

SOUSA, T.V.; CAIXETA, E.T.; ALKIMIM, E.R.; OLIVEIRA, A.C.B.; PEREIRA, A.A.; SAKIYAMA, N.S.; ZAMBOLIM, L.; RESENDE, M.D.V. Early selection enabled by the implementation of genomic selection in *Coffea arabica* breeding. **Frontiers in Plant Science**, [S. l.], v.9, p.1-12, 2019.

SOUZA, C. M. A.; QUEIROZ, D. M.; RAFULL, L. Z. L. Derrçadora portátil na colheita total e seletiva de frutos do cafeeiro. **Pesquisa Agropecuária Brasileira**, [S. l.], v.41, n.11, p.1637-1642, 2006.

SOUZA, C.D.; FERNANDES, D.P.; BARROSO, M. R.; PORTES, T. A. Transpiração de espécies típicas do cerrado por transpirômetro de equilíbrio e porômetro. **Revista Cerne**, [S. l.], v.17, n.4, p.509-515, 2011

TAIZ, L; ZEIGER, E. **Fisiologia e Desenvolvimento Vegetal**. São Paulo: Artmed, 2017.

UNAL, I.; TOPAKCI, M. A review on using drones for precision farming applications. **In Proceedings of the 12th International Congress on Agricultural Mechanization and Energy**, Nevsehir, Turkey, v.3, n.6; p.276–283, 2014.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Disponível em:<<http://usda.mannlib.cornell.edu/MannUsda/viewDocumentInfo.do?documentID=1801>> Acesso em: Fevereiro de 2021.

USHA, K.; SINGH, B. Potential applications of remote sensing in horticulture-A review. **Scientia Horticulturae**, [S. l.], v.153, p. 71–83, 2013.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: a meta-review. **Remote Sensing of Environment**, [S. l.], v. 236, 2020.

WHITEHEAD, Ken; HUGENHOLTZ, Chris H. Remote sensing of the environment with small unmanned aircraft systems (UASs), part 1: A review of progress and challenges. **Journal of Unmanned Vehicle Systems**, v. 2, n. 3, p. 69-85, 2014.

XIANG, H.; TIAN, L. Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. **Biosystems Engineering**, v. 108, n. 2, p. 104-113, 2011.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision agriculture**, v. 13, n. 6, p. 693-712, 2012.

SEGUNDA PARTE- ARTIGOS

**ARTIGO 1- POTENCIAL DAS INFORMAÇÕES ESPACIAIS DE IMAGENS
RPA PARA QUANTIFICAR DESFOLHA APÓS A COLHEITA DE CAFEEIROS**

(VERSÃO PRELIMINAR)

RESUMO

O café é uma *commodity* agrícola com importância comercial mundial com capacidade de impactar a cadeia produtiva. A quantificação da desfolha na colheita é um fator importante para acompanhar a produtividade da lavoura por ser um dos principais danos causados por esta operação agrícola na cultura cafeeira. Neste sentido, o objetivo deste trabalho foi avaliar a relação entre a produtividade e a desfolha quantificada em campo e obtida por meio de imagens de RPA. O experimento foi realizado em uma lavoura cafeeira pertencente à Universidade Federal de Lavras, Lavras, Minas Gerais, Brasil. Utilizou-se uma aeronave remotamente pilotada (*Remotely Piloted Aircraft-RPA*) de asa rotativa, em modo de voo autônomo, contendo uma câmera multiespectral, altura de 30 m, com sobreposição de imagem de 80 % e velocidade de 3 m/s. As imagens foram coletadas antes e depois da colheita de 2020 e 2021, dados de desfolha quantificada em campo foram medidos nos anos de 2020 e 2021 e produtividade no período de 2019 a 2021. O processamento das imagens foi realizado no software PhotoScan e o pós-processamento das imagens foi realizado no QGis sendo as análises estatísticas realizadas do software R. Com o processamento das imagens do ano de 2020, a lavoura apresentou uma redução de 17,3 % e de 18,4 % de área e volume foliar, respectivamente, após a colheita. E, em 2021, a lavoura apresentou uma redução de 12,8 % e 9,8 % de área e volume foliar, respectivamente, após a colheita. Foi possível quantificar a área e o volume de uma lavoura cafeeira após a colheita por meio de imagem obtida por RPA, com isso observou-se a perda de área e de volume da lavoura cafeeira. Ainda, foi possível analisar as interações entre dados de campo com a produtividade do mesmo ano de colheita, sendo diretamente proporcional, e a interação de dados da imagem de um ano com a produtividade anterior, sendo inversamente proporcionais.

Palavras-chave: *Coffea arabica* L. Colheita. Sistemas de Aeronaves Não Tripuladas. Imagem Digital. Processamento. Volume do Dossel.

ABSTRACT

Coffee is an agricultural commodity of global commercial importance with the ability to impact the production chain. The quantification of defoliation at harvest is an important factor to monitor crop yield as it is one of the major damages caused by this agricultural operation in the coffee crop. In this sense, the objective of this work was to evaluate the relationship between yield and defoliation measured in the field and obtained through RPA images. The experiment was conducted in a coffee plantation belonging to the Federal University of Lavras, Lavras, Minas Gerais, Brazil. A rotary-wing RPA was used, in autonomous flight mode, containing a conventional camera, 30 m high, with 80% image overlap and 3 m / s speed. The images were collected before and after harvesting in 2020 and 2021 and, subsequently, data were collected from the defoliation in the same years and yield from 2019 to 2021. Image processing was performed in the PhotoScan software, and the post-processing of images was performed in QGis, with statistical analyzes performed using the R software. With the processing of images from the year 2020, the crop showed a reduction of 17.3% and 18.4% in leaf area and volume, respectively, after harvest. And, in 2021, the crop showed a reduction of 12.8% and 9.8% of leaf area and volume, respectively, after harvest. It was possible to quantify the area and volume of a coffee plantation after harvesting through an image obtained by RPA, thus observing the loss of area and volume of the coffee plantation. Furthermore, it was possible to analyze the interactions between field data with the yield of the same harvest year, being directly proportional, and the interaction of image data from one year with the previous yield, being inversely proportional.

Keywords: *Coffea arabica* L. Harvest. Unmanned Aircraft System (UAS). Digital Image Processing. Canopy Volume.

1 INTRODUÇÃO

O café é uma *commodity* agrícola de importância mundial com capacidade de impactar a cadeia produtiva. A estimativa de produção de café para a safra 2020/2021 em escala mundial é de 175,5 milhões de sacas (60 kg). O Brasil tem participação significativa nestes dados, ocupando a primeira posição contribuindo com cerca de 38,6 % da produção mundial de café (USDA, 2021) se consolidando como maior produtor e exportador de *Coffea arabica* e o segundo maior produtor de *Coffea canephora* da produção mundial desta cultivar.

Estes dados reverberam a expressiva importância econômica e social desta cultura para o Brasil. Além disso, devido à crescente demanda global por cafés especiais, torna-se necessário desenvolver técnicas produtivas e de monitoramento da cultura para diferenciar o produtor brasileiro. No entanto, esta cultura sofre oscilações como as citadas por Silva et al. (2010), nos quais fatores como manejo da lavoura também podem acarretar variações espaciais e temporais na lavoura.

A quantificação da desfolha na colheita é um fator importante para acompanhar a produtividade da lavoura por ser um dos principais danos causados por esta operação agrícola na cultura cafeeira. Com a desfolha, a planta produzirá menos no ano seguinte, pois utilizará suas reservas para recompor a vegetação e terá como consequência uma menor frutificação como consequência (SILVA et al., 2010). Com isso, a ocorrência frequente de tal fato proporcionará o estresse da planta e redução de sua longevidade (BÁRTHOLO; GUIMARÃES, 1997; OLIVEIRA et al., 2007b).

A agricultura de precisão aliada a ferramentas computacionais tem sido estudada e amplamente difundida na cultura cafeeira. Segundo Amaral et al. (2020) houve uma evolução significativa em termos de sensores e aplicações em sensoriamento remoto (SR) em todos os níveis (orbital, aéreo e terrestre), no entanto, no nível aéreo, as Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft- RPAs*) foi uma das ferramentas que mais se desenvolveu nos últimos anos. Esta ferramenta possibilita a captura de imagens de alta resolução espacial (podendo obter resolução espacial da ordem de mm, dependendo da altura de voo) e alta resolução temporal (sendo possível utilizar a RPA sempre que tiver boas condições climáticas e bateria), que podem ser processadas utilizando o algoritmo *Structure from Motion* (SfM).

O SfM se baseia nos princípios da fotogrametria tradicional estereoscópica, na qual utiliza sobreposição de múltiplas imagens, obtidas por câmeras convencionais, para obter características geométricas gerando uma nuvem de pontos 2D e 3D (MARTÍNEZ-CARRICONDO et al. 2018; SANTOS et al. 2020a). Com a nuvem de pontos é possível gerar

Modelo Digital de Superfície (MDS) e o Modelo Digital de Elevação (MDE), tais produtos podem ser utilizados para a produção de mosaico de ortofotos, modelagem 3D e obtenção de informações métricas como cálculo de área, volume, alturas, entre outras. (NEX e REMONDINO, 2014; SANTOS et al. 2020a).

Neste contexto, o uso de RPAs tem possibilitado a coleta de dados que permitem a estimativa de parâmetros morfológicos (BARBOSA et al., 2021; SANTOS et al., 2020a), coeficiente de cultura (K_c) (SANTOS et al., 2020b), índice de área foliar (SANTOS et al., 2020c), estimativa de volume (CUNHA et al., 2019), monitoramento de nitrogênio foliar (PARREIRAS et al., 2020; MARIN et al., 2021b), monitoramento de danos causados por geadas (MARIN et al., 2021a), e maturação de frutos (MARTINS et al., 2021).

Cunha et al. (2019) desenvolveram uma metodologia para determinar o volume da vegetação das lavouras de café a partir de imagens RPA e comparar essa abordagem com a estimativa tradicional do volume da vegetação (método do volume de fileiras de árvores-TRV). Os autores estudaram este método em condições normais da lavoura a fim de obter volume para definição de técnicas de aplicação de pesticidas. Estes concluíram que, o volume da vegetação dos cafeeiros, pode ser determinada de forma prática e precisa pelo processamento digital das imagens capturadas por RPA por ser um método rápido e permite a avaliação de grandes áreas.

Diante disso, não foram explorados estudos sobre a quantificação de área e volume de lavouras cafeeiras após a colheita utilizando imagens obtidas por RPA para obtenção da desfolha. Com base nisso, tem-se como hipótese de que é possível quantificar área e volume de lavouras cafeeiras antes e depois da colheita afim de quantificar a desfolha usando RPAs, sendo útil para subsidiar estudos sobre bienalidade e produtividade de lavouras que passam por esta operação agrícola. Neste sentido, objetivou-se avaliar a relação entre a produtividade e a desfolha quantificada em campo e obtida por meio de imagens de RPA.

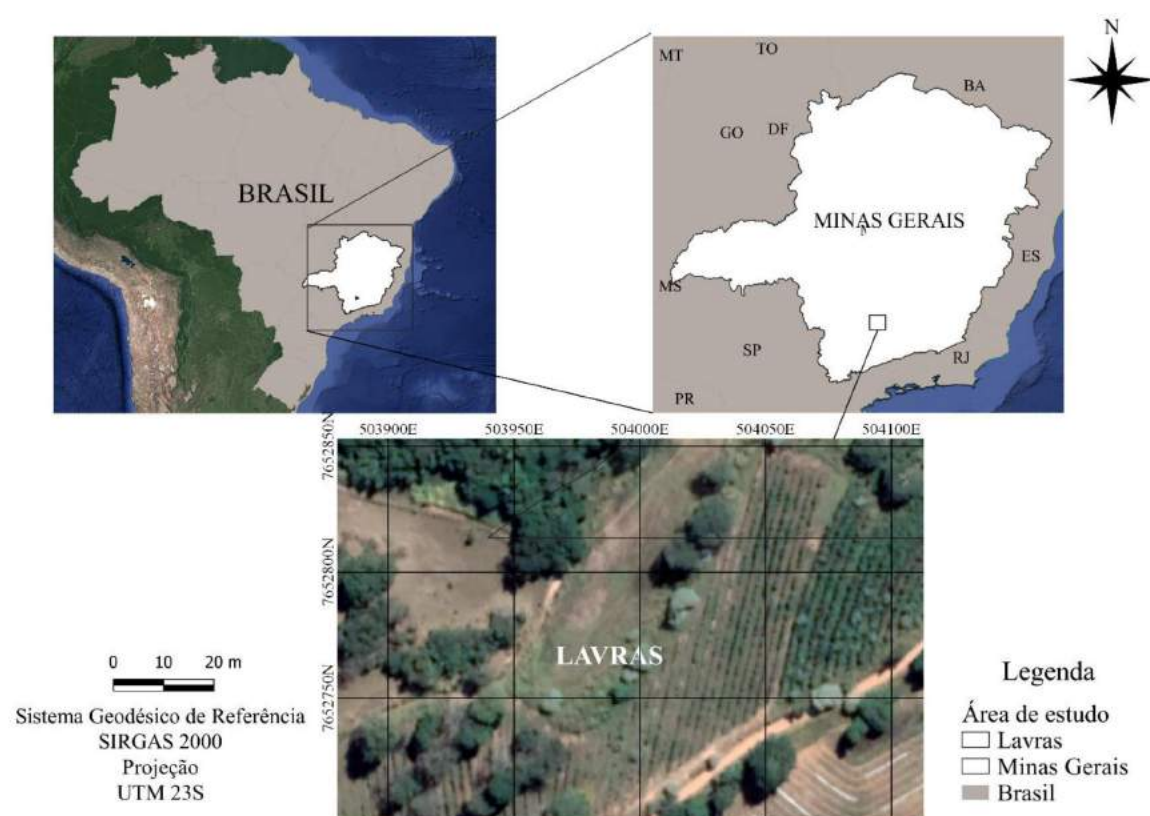
2 MATERIAL E MÉTODOS

Área de estudo

O experimento foi realizado em uma área de 0,48 ha de lavoura experimental de cafeeiro (*Coffea arabica L.*), pertencente ao Setor de Cafeicultura do Departamento de Agricultura - DAG, na Universidade Federal de Lavras - UFLA, em Lavras – MG. Utilizou-se a cultivar “Mundo Novo 379-19”, plantada em janeiro de 2016, no espaçamento 3,6 metros nas entrelinhas de plantio e 0,75 metros entre as plantas, cujos tratamentos estão descritos por Castanheira et al. (2019) e Alecrim et al. (2020).

As coordenadas geográficas da área são latitude 21°13'36.47" Sul e longitude 44°57'40.35 Oeste, com altitude média de 975 metros (Figura 2.1).

Figura 2.1- Delimitação do estado de Minas Gerais, do município de Lavras e do talhão de estudo.



Fonte: Da autora (2021).

Utilizou-se 90 parcelas experimentais, em que cada parcela experimental foi composta por seis plantas, sendo consideradas como plantas úteis as quatro centrais. Entre as linhas de tratamento, utilizou-se uma linha de bordadura, de forma a evitar interferência. A área em

estudo, as parcelas amostradas e pontos de controle, foram georreferenciadas com auxílio de um sistema global de posicionamento diferencial (DGPS- *differential global positioning system*; Trimble Navigation Limited, Sunnyvale, California, USA) com precisão horizontal e vertical de 0,007m.

Aquisição e processamento das imagens RPA

Neste estudo, um quadricóptero (Matrice 100, DJI) foi usado como plataforma RPA, equipado com uma câmera multiespectral de alta resolução espacial (Parrot SEQUOIA) carregando uma carga útil de 72 g, para capturar imagens na faixa espectral do visível RGB (*Red- R, Green- G and Blue- B*), e imagens nas faixas espectrais não visíveis como: borda do vermelho (*Red Edge- REG*) e infravermelho próximo (*Near Infrared- NIR*).

A câmera RGB tem resolução de 16 megapixels com distância focal da lente de 5 mm. Além disso, a câmera possui outro sensor de 1,2 megapixels, com uma distância focal de lente de 4 mm, captura quatro bandas espectrais em G (comprimento de onda de 530-570 nm), R (comprimento de onda de 640–680 nm), REG (comprimento de onda de 730–740 nm) e NIR (comprimento de onda de 770–810 nm), que neste estudo não foram utilizadas as duas últimas bandas citadas.

As imagens foram coletadas simultaneamente de uma altitude de voo de 30 m acima do nível do solo com 80% de sobreposição frontal e lateral, em velocidades de 3 m/s, conforme a metodologia de Santos et al. (2020a), alcançando uma resolução espacial de 0,86 cm com a câmera RGB.

Foram realizados quatro voos, o primeiro antes da colheita, no dia 01 de maio de 2020, o segundo após a colheita no dia 08 de maio de 2020, terceiro antes da colheita, no dia 01 de maio de 2021 e o quarto depois da colheita, no dia 12 de maio de 2021. As imagens foram coletadas por volta de meio-dia, com céu claro e ensolarado, afim de minimizar os efeitos das nuvens e geração de sombras nas imagens.

As imagens foram processadas no software PhotoScan Professional 1.4.0 (Agisoft LLC, St. Petersburg, Rússia) (Tabela 2.1), seguindo o workflow de processamento disponível, na qual as fotos foram alinhadas geometricamente para construir a nuvem de pontos, modelo 3D, modelo digital de terreno (MDT), modelo de superfície digital (MDS) e ortomosaico.

Tabela 2.1-Dados do processamento das imagens RPA.

Informações	Pré-Colheita	Pós-Colheita	Pré-Colheita	Pós-Colheita
Data (dd/mm/aa)	01/05/2020	08/05/2020	01/05/2021	12/05/2021
Tempo (duração)	8 min 52 s			
Número de imagens	120	121	119	120
Altura de Vôo (m)	30			
Tamanho dos dados (GB)	1,03	1,08	1,08	1,02
Tempo de Processamento (h)	5,47	6,14	4,88	5,44
Plataforma de Software	Microsoft Windows 7 (64 bits)			
Resolução espacial (cm/pix)	1,03	1,13	1,04	1,01
Erro de reprojeção (RMS <i>reprojection error</i>) (pix)	1,34	1,43	1,81	1,84

Fonte: Da autora (2021).

Os ortomosaicos foram georreferenciados utilizando a transformação polinomial de segunda ordem com método de reamostragem vizinho mais próximo, utilizando 6 pontos de controles (PC) distribuídos na área. Foi adotado o Sistema de Referência Geocêntrico para as Américas (SIRGAS 2000) e a projeção Universal Transversa de Mercator- UTM (fuso 23S). Utilizou o software Qgis versão 3.10 (Quantum GIS) para o pré-processamento e elaboração de mapas.

A determinação da altura de plantas foi calculada utilizando calculadora raster no QGis, na qual obtém-se um Modelo de Altura do Dossel (*Canopy Height Model-CHM*) através da subtração entre o MDS e o MDT, conforme metodologia utilizada por Santos, et al. (2020a); Panagiotidis et al. (2017) e Iizuka et al. (2017).

Para obter a área e o volume da lavoura em cada uma das 90 parcelas experimentais em estudo, utilizou-se o puglin volume da superfície do raster disponível no QGis. Esse algoritmo calcula o volume acima do nível base da superfície do CHM. O algoritmo gera o volume calculado, a área total e o número total de pixels analisados. As parcelas da área e do volume calculado dependem do sistema de referência de coordenadas do arquivo raster de entrada. Assim, como o sistema de projeção utilizado foi o UTM, em metros, a altura CHM em metros, o valor calculado é apresentado em m^2 e m^3 , para a área e para o volume respectivamente.

Os dados de desfolha da aeronave em área (D.A.A) ($m^2/planta$) e os dados de desfolha da aeronave em volume (D.A.V) ($m^3/planta$) foram obtidos através da subtração entre os dados obtidos, de área e volume, antes e depois da colheita, e dividido pelo número de plantas úteis de cada parcela experimental, utilizando uma planilha Excel.

Coleta de dados de Campo

Foram coletados dados de produção de café de cada parcela experimental (L/parcela) dos anos de 2019 e 2020. Estes dados foram obtidos por meio da colheita manual no pano, após a retirada de galhos e folhas, realizou-se a abanação e o volume dos frutos foram coletados em um recipiente graduado em litros. Com esta medição obteve-se a produtividade (L/planta) (P-2019 e P-2020) como sendo a média das plantas úteis de cada parcela experimental.

Ao realizar a colheita no pano, retirou e pesou as folhas que caíram no pano devido a este processo. A desfolha de campo foi quantificada com base no peso fresco de folhas (D.C.P) (kg) após a colheita manual, utilizando uma balança portátil até 12kg, seguindo a metodologia de Silva et al. (2010). Com esta medição obteve-se a desfolha (kg/planta) como sendo a desfolha média das plantas úteis de cada parcela experimental. As amostras de produtividade e desfolha foram obtidas no dia 7 de maio de 2020.

A produção de café de cada parcela experimental (L/parcela) da colheita realizada no ano de 2021, foi obtida por meio da colheita semimecanizada utilizando derriçadoras portáteis. Ao realizar a colheita no pano, retirou-se e pesou-se as folhas e galhos que caíram no pano devido a este processo. Com esta medição, obteve-se a produtividade das plantas úteis (L/planta) (P-2021). A desfolha de campo foi quantificada com base no peso fresco de folhas e galhos (D.C.P) (kg) utilizando uma balança portátil até 12kg, seguindo a metodologia de Bordin et al. (2019). A desfolha de campo quantificada com base no volume de folhas e galhos frescos (D.C.V) (L) foi medida em balde de 14L. Esta metodologia foi adotada para avaliar a correlação entre os dados de desfolha em campo e os dados obtidos a partir das imagens da RPA. Com estas medições, obteve-se a desfolha (Kg/planta e L/planta). As amostras de produtividade e desfolha foram obtidas no dia 11 de maio de 2021.

Aplicou-se a correlação de Pearson entre todas as variáveis estudadas: P-2019, D.A.A-2020, D.A.V-2020, D.C.P-2020, P-2020, D.A.A-2021, D.A.V-2021, D.C.P-2021, D.C.V-2021 e P-2021, com o intuito de avaliar a relação entre elas. Para verificar a significância foi adotado $\alpha = 5\%$ (coeficiente de correlação). Calculou-se os resíduos como a diferença entre a desfolha e a produtividade, também calculou a Média Absoluta do Erro (MAE), bem como a Raiz Quadrada do Erro Médio (RMSE). As análises estatísticas descritivas foram realizadas no software estatístico R (R Core Team, Viena, Áustria).

3 RESULTADOS E DISCUSSÃO

Houveram variações significativas ($p \leq 0,05$) e insignificantes ($p > 0,05$) entre as variáveis estudadas. Diante deste resultado, este estudo considerou somente as análises com variações significativas positivo e/ou negativo, destacadas na Tabela 3.1 em negrito.

Tabela 3.1- Coeficientes de correlação de Pearson das variáveis de estudo, em negrito as relações que foram significativas.

	P-2019	D.A.A-2020	D.A.V-2020	D.C.P-2020	P-2020	D.A.A-2021	D.A.V-2021	D.C.P-2021	D.C.V-2021	P-2021
P-2019	-									
D.A.A-2020	-0,25	-								
D.A.V-2020	-0,10	0,63	-							
D.C.P-2020	0,04	-0,13	0,00	-						
P-2020	0,15	-0,14	-0,06	0,56	-					
D.A.A-2021	-0,11	0,17	0,13	-0,25	-0,17	-				
D.A.V-2021	-0,15	0,16	0,15	-0,19	-0,19	0,87	-			
D.C.P-2021	0,01	0,13	0,15	0,41	0,12	0,15	0,14	-		
D.C.V-2021	0,13	0,09	0,19	0,34	0,15	0,20	0,18	0,70	-	
P-2021	0,14	-0,02	0,16	0,06	-0,25	0,28	0,21	0,54	0,72	-

Dados de desfolha da aeronave em área (D.A.A) ($m^2/planta$); dados de desfolha da aeronave em volume (D.A.V) ($m^3/planta$); desfolha de campo quantificada com base no peso fresco de folhas (D.C.P- 2020) ($kg/planta$); desfolha de campo quantificada com base no peso fresco de folhas e galhos (D.C.P-2021) ($kg/planta$); desfolha de campo quantificada com base no volume de folhas e galhos frescos (D.C.V-2021) ($L/planta$) e P- produtividade ($L/planta$).

Fonte: Da autora (2021).

Logo, foram analisadas as relações entre P-2020 e D.C.P-2020; P-2021 e D.C.P-2021; P-2021 e D.C.V-2021, sendo estas correlações adequados, estatisticamente, para analisar as relações entre desfolha de campo e produtividade. E as relações entre P-2019 e D.A.A-2020; P-2020 e D.A.A-2021; P-2020 e D.A.V-2021 para analisar a desfolha obtida pela aeronave e produtividade. Ressalta-se ainda que não houve correlações significativas para as desfolhas obtidas em campo e as desfolhas obtidas pela aeronave.

Além disso, a correlação entre D.A.V-2020 e D.A.A-2020 apresentou correlações forte e positiva ($R=0,63$) e as relações entre D.A.V-2021 e D.A.A-2021 ($R=0,87$), estes resultados eram esperados, visto que a metodologia utiliza o CHM para obtenção da área e do volume das imagens processadas (SANTOS, et al., 2020a). A relação entre D.C.V-2021 e D.C.P-2021

($R=0,70$) foi outro resultado esperado pois, são dados de campo do mesmo ano mensurados de forma diferente.

Análise de desfolha de campo e produtividade

A D.C.P-2020 após a colheita manual, apresentou valores de 0 a 0,64 kg/planta, como pode ser observado na Tabela 3.2. Os valores de desfolha observados no presente estudo foram próximos do encontrado por Silva et al. (2000), situado próximo a 0,64 kg/planta. Silva et al. (2010) encontraram valores de desfolha das plantas causada pela colheita manual de 0 a 0,9 kg/planta.

Já a D.C.P-2021 após a colheita semimecanizada, apresentou valores de 0 a 4 kg/planta, como pode ser observado na Tabela 3.2. Ressalta-se que a D.C.P-2021 com relação a D.C.P-2020 foi maior, devido a quantificação de galhos e folhas que caíram no pano em razão do processo de colheita. Entretanto, estas medições não são passíveis de comparação por serem de épocas e metodologias diferentes.

Tabela 3.2- Análise Exploratória dos dados.

Estatística	2020		2021	
	D.C.P (kg/planta)	Produtividade (L/planta)	D.C.P (kg/planta)	Produtividade (L/planta)
Mínimo	0	0	0	0
1º Quartil	0,01	2,38	0,1	0,1
Mediana	0,06	4,67	0,38	1,71
Média	0,08	4,59	0,45	3,64
3º Quartil	0,13	6,71	0,72	5,67
Máximo	0,64	13	4	26

Desfolha de campo quantificada com base no peso fresco de folhas (D.C.P- 2020) (kg/planta); desfolha de campo quantificada com base no peso fresco de folhas e galhos (D.C.P-2021)

Fonte: Da autora (2021).

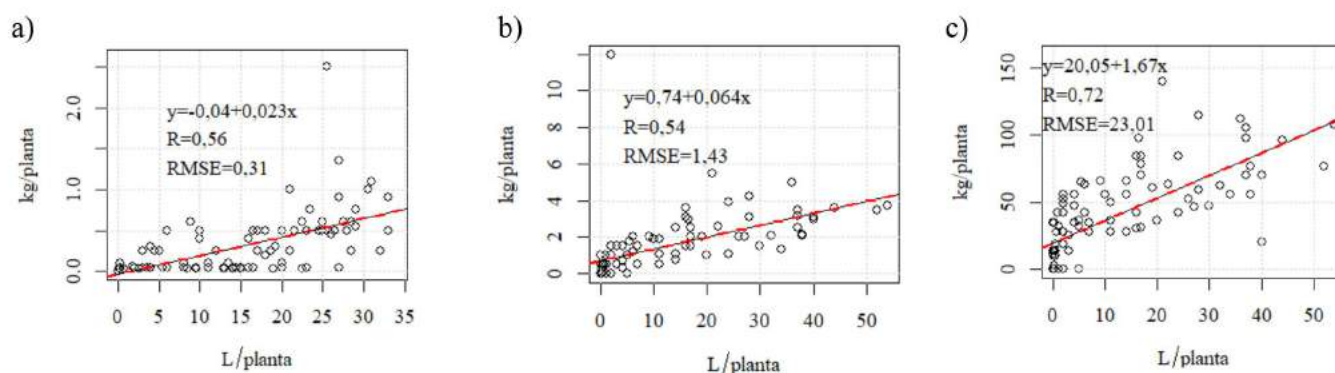
A P-2020 apresentou valores variando de 0 a 13 L/planta e para P-2021 de 0 a 26 L/planta (Tabela 3.2). Ao observar as duas colheitas, notou-se que o ano de 2020 foi de alta produtividade na lavoura, sendo a média da produtividade maior quando comparado com o ano de 2021. Em 2021, a lavoura apresentou uma produtividade 20% menor comparado com ano anterior, sendo atribuído à este ano baixa produtividade na lavoura.

Os valores de produtividade encontrados neste estudo foram condizentes com o estudo conduzido por Ferraz et al. (2012), que ao estudarem uma lavoura com 2 anos e sete meses de

idade, encontraram valores de produtividade de 0,025 a 3,95 L/planta. Já o estudo de Silva et al. (2010), encontraram valores de produtividade de 0 a 11,8 L/planta em uma lavoura de 16 anos de idade.

A interação entre P-2020 e D.C.P-2020 foi moderada e positiva de 56 % (Figura 3.1a), assim como a interação entre P-2021 e D.C.P-2021 de 54 % (Figura 3.1b) e P-2021 e D.C.V-2021 de 73 % (Figura 3.1c). Tais resultados de correlação positiva indicam que a produtividade é diretamente proporcional à desfolha do mesmo ano, com isso quanto maior a produtividade maior será a desfolha em função da colheita. Estes resultados corroboram com o trabalho conduzido por Oliveira et al. (2007a), no qual os autores concluíram que o aumento do volume de grãos colhidos foi proporcional ao aumento da desfolha.

Figura 3.1- Regressão e correlação. a) P-2020 e D.C.P-2020; b) P-2021 e D.C.P-2021 e c) P-2021 e D.C.V-2021.



Fonte: Da autora (2021).

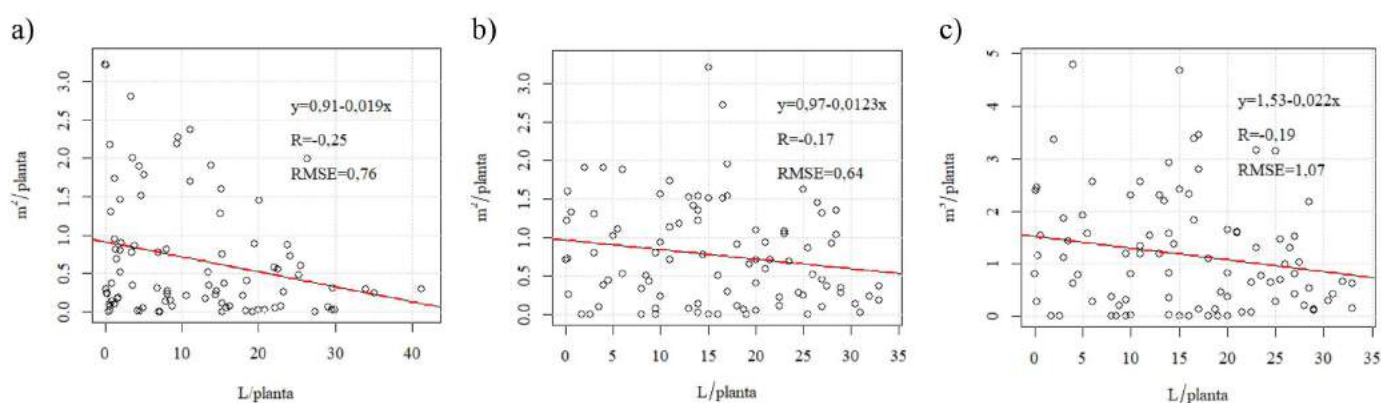
A desfolha é o principal dano causado ao cafeeiro pela ação da colheita. Com a desfolha, a planta produzirá menos no ano seguinte, uma vez que utilizará suas reservas para a recomposição da vegetação e, conseqüentemente, terá menor frutificação (OLIVEIRA et al., 2007b). Trabalhos realizados por Silva et al. (2010) constataram que a colheita manual desfolhou mais em locais de maior produtividade, e reduziu a produtividade no ano subsequente, conforme também observado neste trabalho. Isso se deve à perda de área foliar e à redução da área fotossinteticamente ativa característica da cultura.

Análise de desfolha obtida pela aeronave e produtividade

Verificou-se correlações significativas ao nível de 5% de significância. A correlação entre a P-2019 e a D.A.A-2020 (Figura 3.2a) apresentou interação fraca e negativa de 25%. Os

resultados da correlação negativa indicam que a produtividade de um ano é inversamente proporcional à desfolha do ano seguinte, sendo assim, correlações negativas implicam em dizer que quanto maior a produtividade de um ano, menor será a desfolha do ano seguinte ao qual está correlacionado, justamente pela característica bienal do cafeeiro. Resultado semelhante foi encontrado para a correlação entre a P-2020 e a D.A.A-2021 de -17 % (Figura 3.2b) e para a P-2020 e a D.A.V-2021 de -19 % (Figura 3.2c).

Figura 3.2- Regressão e correlação. a) P-2019 e a D.A.A-2020; b) P-2020 e a D.A.A-2021 e c) P-2020 e a D.A.V-2021.



Fonte: Da autora (2021).

Ao comparar os dados obtidos pelas imagens da lavoura após a colheita de 2020 com os dados obtidos pelas imagens da lavoura antes da colheita de 2021, foi possível quantificar a recuperação da lavoura de um ano para o outro, na qual houve um acréscimo de área foliar de 22,8 % e um acréscimo de volume de 19,6 % na lavoura. Este resultado expressa a característica fisiológica do cafeeiro, a bienalidade, além de ser possível observar as perdas ocasionadas pela colheita.

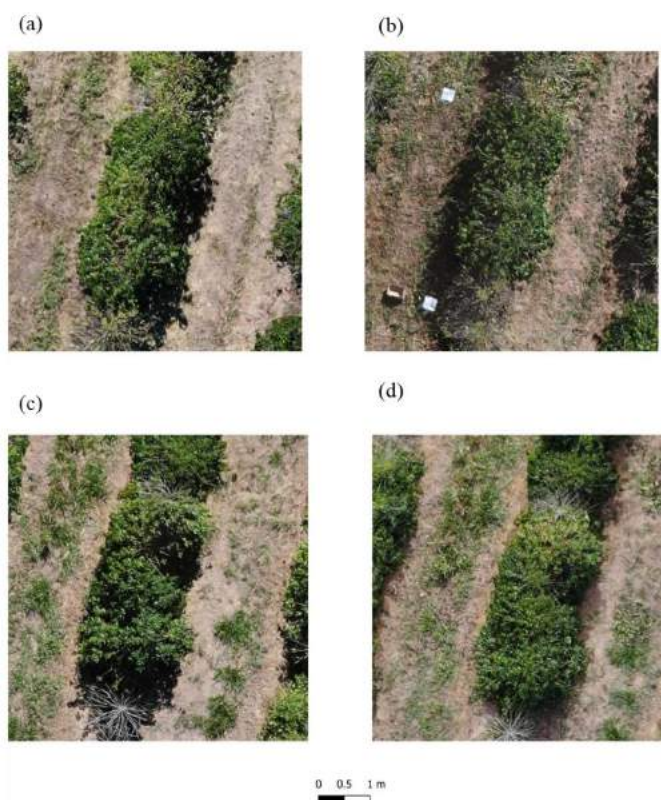
Este estudo reflete a importância da perda de área foliar. Uma vez que qualquer fator que reduz a área foliar influenciará negativamente sobre a capacidade fotossintetizadora da planta (MAGALHÃES, 1964). Esta perda de área foliar deve ser levada em consideração diante da característica da bienalidade própria dos cafeeiros, pois a alternância nos padrões de desfolha tendem a refletir na produtividade. Fazendo uma analogia com o estudo realizado por Magalhães (1964), o efeito da redução de 25% da área foliar resultou em um retardamento de 32,6% no desenvolvimento das folhas e um decréscimo de 10,5% no desenvolvimento das partes aéreas das plantas. Neste estudo, esta perda de área foliar ficou abaixo de 20%, sendo possível observar a recuperação da planta no ano subsequente. Isto reforça ainda mais a

necessidade de se realizar amostragens como estas, para que ações possam ser tomadas de forma rápida e precisa.

Com o processamento das imagens do ano de 2020, a área da lavoura quantificada foi de 354,6 m² (Figura 3.3a) e 293,1 m² (Figura 3.3b), antes e depois da colheita, respectivamente. Este resultado demonstra uma redução de 17,3 % de área foliar após a colheita. O volume da lavoura foi de 505,6m³ e 412,7m³, antes e depois da colheita, respectivamente, o que resultou em uma redução de 18,4 % de volume foliar após a colheita nas parcelas em estudo.

A área da lavoura quantificada no ano de 2021 foi de 379,9 m² antes da colheita (Figura 3.3c) e 331,2 m² (Figura 3.3d) depois da colheita. Este resultado reverbera redução de 12,8 % de área foliar após a colheita. O volume da lavoura foi de 524,9 m³ e 473,4 m³, antes e depois da colheita, respectivamente, o que resultou em um decréscimo de 9,8 % de volume foliar após a colheita nas parcelas em estudo.

Figura 3.3- Área foliar de cafeeiros a) antes da colheita de 2020, b) depois da colheita de 2020, c) antes da colheita de 2021 e d) depois da colheita de 2021.



Fonte: Da autora (2021).

Os resultados das análises da relação entre a produtividade e a desfolha quantificada em campo e da relação entre a produtividade e a desfolha obtida por meio das imagens de RPA,

foram complementares. Ressalta-se que no ano de 2020, a lavoura apresentou uma maior redução de área foliar após a colheita quantificada pela RPA, e uma maior produtividade comparado com o ano de 2021. Tais resultados vão de encontro com a desfolha quantificada em campo com a produtividade do mesmo ano de 2020 e menor produtividade no ano seguinte, validando o observado ao utilizar ambas metodologias. Sendo assim observamos que a alta produtividade aliada a alta desfolha no mesmo ano é complementar à alta produtividade do ano aliada a baixa desfolha no ano seguinte (devido à menor produtividade desse ano). Recomenda-se realizar estas análises em um período consecutivo de quatro anos, a fim de obter dados relevantes e repetidos em um ciclo bienal do cafeeiro, para ambas as metodologias.

Otsu et al. (2019) estudaram uma classificação *Random Forest* combinada para a detecção de desfolha em uma área florestal por meio de análise de limiar de histograma com quatro índices de vegetação derivados de imagens RPA. Os autores obtiveram bons resultados, entretanto esta metodologia para obter desfolha de uma determinada vegetação requer câmeras multiespectrais para calcular índices de vegetação que utilizam bandas espectrais na faixa do NIR, sendo uma metodologia mais onerosa quando comparada com a metodologia deste estudo na qual, apesar de utilizar-se de câmera multiespectral, não fez o uso das bandas do não visível. Deste modo, não foi necessário realizar a calibração no processamento dos dados, como nos estudos realizados por Cunha et al. (2019), na qual os autores utilizaram câmera RGB para realizar o estudo. Com isso, a metodologia proposta é acessível para pequenos produtores cafeeiros que queiram obter parâmetros morfológico de sua lavoura como: altura, diâmetro de copa, área de planta, volume de planta e desfolha da lavoura utilizando uma câmera acessível, de fácil manuseio e processamento.

Este estudo tem relevância, pois quantifica áreas e volume de cafeeiros sem a necessidade de realização de amostragem direta em campo, obtendo dados de forma remota, facilitando intervenções na lavoura com mais rapidez e precisão. Cunha et al. (2019) desenvolveram um método para determinar o volume de vegetação das lavouras cafeeiras a partir de imagens obtidas por RPAs, no entanto, os autores utilizaram uma rotina computacional implementada no software Pix4D que permite estimar o volume do alvo. Esta diferença de processamento pode acarretar um subestimativa ou superestimativa do volume do dossel, uma vez que os autores não individualizaram as plantas.

A vantagem deste estudo é que se leva em consideração a altura das plantas obtidas por meio do CHM, sendo uma metodologia ágil para obter esta informação de toda a área em estudo sem precisar realizar medições de campo, além de possibilitar a obtenção de parâmetros

morfológico da cultura remotamente, favorecendo a identificação de forma mais eficiente de anomalias na lavoura e agilizando procedimentos de tratos culturais necessários em campo.

Para esta metodologia alguns pontos devem ser levados em consideração como: parâmetros de sobreposição de voo que interferem na qualidade das imagens, a topografia do terreno, GCPs com georreferenciamento obtido com um receptor GNSS para melhorar a precisão e processamento das imagens com qualidade.

Como trabalhos futuros, sugere-se testar a metodologia em terrenos diferentes, desenvolver plugins que automatizem e padronizem este processamento e tecnologias que permitam obter estas informações em tempo real. Além disso, sugere-se também a constatação da tecnologia Unmanned Aerial Vehicle Laser Scanning (UAV-LS) (BREDE et al., 2019) na cultura cafeeira.

4 CONCLUSÃO

Foi possível analisar e correlacionar a relação entre a produtividade e a desfolha quantificada em campo e obtida por meio de imagens de RPA. As interações entre dados de desfolha quantificada em campo com a produtividade do mesmo ano de colheita apresentou uma relação diretamente proporcional e, a interação da produtividade com a dados de desfolha obtido pela RPA do ano subsequente, apresentou uma relação inversamente proporcionais.

Agradecimentos

À Universidade Federal de Lavras (UFLA) e ao Programa de pós-graduação em engenharia agrícola (PPGEA) pelo apoio ao estudo. Ao Consórcio Pesquisa Café (projeto aprovado no edital nº 20/2018) - Embrapa Café pelo financiamento à pesquisa. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro. Ao Setor de Cafeicultura da UFLA, ao NESA e NECAF pelo apoio e desenvolvimento da pesquisa.

REFERÊNCIAS

- ALECRIM, A. O.; CASTANHEIRA, D. T.; VOLTOLINI, G. B.; NETTO, P. M.; GUIMARÃES, R. J.; GONÇALVES, A. H. Phytosociology of weeds in coffee plants with different soil management techniques. **Scientia Agraria Paranaensis**, [S. l.], v.19, n.3, p.270-279, 2020.
- AMARAL, L. R. D.; ZERBATO, C.; FREITAS, R. G. D.; BARBOSA JÚNIOR, M. R.; SIMÕES, I. O. P. D. S. UAV applications in Agriculture 4.0. **Revista Ciência Agronômica**, [S. l.], v. 51, Special Agriculture 4.0, e20207748, 2020.
- BARBOSA, B. D. S.; FERRAZ, G.A.S.; SANTOS, L.M.D.; SANTANA, L. S.; MARIN, D.B.; ROSSI, G.; CONTI, L. Application of RGB Images Obtained by UAV in Coffee Farming. **Remote Sensing**, [S. l.], v. 13, p. 2397, 2021.
- BÁRTHOLO, G.F.; GUIMARÃES, P.T.G. Cuidados na colheita e preparo do café. **Informe Agropecuário**, Belo Horizonte, v.18, n.187, p.33-42, 1997.
- BORDIN, B. C.D.M.; RONCHI, C. P.; CAMPOS, A. A. V.; MIRANDA, F. R.; BATISTA, L. B.; RIBEIRO, A. J.; MEWES, W. L. C. RESPOSTAS PRODUTIVAS DE LAVOURA DE PRIMEIRA SAFRA ÀS COLHEITAS MANUAL E MECANIZADA. X Simpósio de Pesquisa dos Cafés do Brasil, 2019.
- BREDE, B.; CALDERS, K.; LAU, A.; RAUMONEN, P.; BARTHOLOMEUS, H. M.; HEROLD, M.; KOOISTRA, L. Non-destructive tree volume estimation through quantitative structure modelling: Comparing UAV laser scanning with terrestrial LIDAR. **Remote Sensing of Environment**, [S. l.], v.233, p. 1-14, 2019.
- CASTANHEIRA, D. T.; BARCELOS, T. R.; GUIMARÃES, R. J.; CARVALHO, M. A. D. F.; REZENDE, T. T.; BASTOS, I. D. S.; CRUVINEL, A. H. Agronomic techniques for mitigating the effects of water restriction on coffee crops. **Coffee Science**, Lavras, v. 14, n. 1, p. 104 - 115, 2019.
- CUNHA, J. P. A. R. da; SIRQUEIRA NETO, M. A.; HURTADO, S. M. C. Estimating vegetation volume of coffee crops using images from unmanned aerial vehicles. **Engenharia Agrícola**, [S. l.], v.39, p. 41-47, 2019.
- FERRAZ, G. A.; SILVA, F. M. D.; COSTA, P. A. N. D.; SILVA, A. C.; CARVALHO, F. D. M. Agricultura de precisão no estudo de atributos químicos do solo e da produtividade de lavoura cafeeira. **Coffee Science**, Lavras, v.7, n. 1, p. 59-67, 2012.
- IIZUKA, K.; YONEHARA, T.; ITOH, M.; KOSUGI, Y. Estimating tree height and diameter at breast height (DBH) from digital surface models and orthophotos obtained with an unmanned aerial system for a Japanese cypress (*Chamaecyparis obtusa*) forest. **Remote Sensing**, [S. l.], v.10 n.13, p.1-14,2017.
- MAGALHÃES, A. C. N. Efeito da redução da superfície foliar sobre o desenvolvimento de cafeeiros. **Bragantia**, Campinas, v.23, p.337-342, 1964.

MARIN, D. B. ; FERRAZ, G. A. S. ; SCHWERZ, F. ; BARATA, R. A. P. ; FARIA, R. O. ; DIAS, J. E. L. . Unmanned aerial vehicle to evaluate frost damage in coffee plants. **Precision Agriculture**, [S. l.], v.1, p. 1-15, 2021a.

MARIN, D. B.; FERRAZ, G. A. S.; GUIMARAES, P. H. S.; SCHWERZ, F.; SANTANA, L. S.; BARBOSA, B. D. S.; BARATA, R. A. P.; FARIA, R. O.; DIAS, J. E. L.; CONTI, L.; ROSSI, G. Remotely Piloted Aircraft and Random Forest in the evaluation of the spatial variability of foliar nitrogen in coffee crop. **Remote Sensing**, [S. l.], v. 13, p. 1-15, 2021b.

MARTÍNEZ-CARRICONDO, P.; AGÜERA-VEGA, F.; CARVAJAL-RAMÍREZ, F.; MESAS-CARRASCOSA, F. J.; GARCÍA-FERRER, A.; PÉREZ-PORRAS, F. J. Assessment of UAV-photogrammetric mapping accuracy based on variation of ground control points. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v.72, p.1-10, 2018.

MARTINS, R.N; PINTO, F. de A. de C.; QUEIROZ, D. M. de; VALENTE, D. S. M.; ROSAS, J. T.F. A Novel Vegetation Index for Coffee Ripeness Monitoring Using Aerial Imagery. **Remote Sensing**, [S. l.], v.13, n. 2, p. 263, 2021.

NEX, F.; REMONDINO, F. UAV for 3D mapping applications: a review. **Applied Geomatics**, [s.l.], v.6, n.1, p.1-15, mar.2014.

OLIVEIRA, E. D.; SILVA, F. M. D.; SOUZA, Z. M. D.; FIGUEIREDO, C. A. P. D. Influência da colheita mecanizada na produção cafeeira. **Ciência Rural**, [S. l.], v. 37, p. 1466-1470, 2007a.

OLIVEIRA, E. D; SILVA, F. M. da; SALVADOR, N.; FIGUEIREDO, C. A. P.; Influência da vibração das hastes e da velocidade de deslocamento da colhedora no processo de colheita mecanizada do café. **Engenharia Agrícola**, Jaboticabal, v. 27, n.3, p. 714-721, 2007b.

OTSU, K.; PLA, M.; DUANE, A.; CARDIL, A.; BROTONS, L. Estimating the threshold of detection on tree crown defoliation using vegetation indices from UAS multispectral imagery. **Drones**, [S. l.], v.3, n.4, p.80, 2019.

PANAGIOTIDIS, D.; ABDOLLAHNEJAD, A.; SUROVÝ, P.; CHITECULO, V. Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, [S. l.], v.38 n.(8–10), p.2392–2410, 2017.

PARREIRAS, T.C.; LENSE, G.H.E.; MOREIRA, R.S.; SANTANA, D.B.; MINCATO, R.L. Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee. **Coffee Science**, Lavras, v.15, p.1–9, 2020.

SANTOS, L. M. dos; BARBOSA, B. D. de S.; DIOTTO, A. V.; MACIEL, D. T.; XAVIER, L. A. G. Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture**, [S. l.], v.21, n.6, p.1227-1241, 2020a.

SANTOS, L. M., FERRAZ, G. A. S., BARBOSA, B. D. S., DIOTTO, A. V., ANDRADE, M. T., CONTI, L., ROSSI, G. Determining the Leaf Area Index and Percentage of Area Covered by Coffee Crops Using UAV RGB Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v. 13, p. 6401-6409, 2020c.

SANTOS, L. M., FERRAZ, G. A. S., DIOTTO, A. V., BARBOSA, B. D. S., MACIEL, D. T., ANDRADE, M. T., ROSSI, G. (2020). Coffee crop coefficient prediction as a function of biophysical variables identified from RGB UAS images. **Agronomy Research**, [S. l.], v.18, n.2, p.1463-1471, 2020b.

SILVA, F. M. D.; ALVES, M. D. C.; SOUZA, J. C. S.; OLIVEIRA, M. S. D. Efeitos da colheita manual na bienalidade do cafeeiro em Ijaci, Minas Gerais. **Ciência e Agrotecnologia**, [S. l.], v.34 n.3, p. 625-632, 2010.

SILVA, F.M.; RODRIGUES, R.F.; SALVADOR, N.; TOURINO, E.S.; SILVA, S.S.S. Custo da colheita mecanizada de café com colhedoras automotrizes no Sul de Minas. **Engenharia na Agricultura**, Viçosa, v.8, n.1, p.54-60, 2000.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Disponível em:<
<http://usda.mannlib.cornell.edu/MannUsda/viewDocumentInfo.do?documentID=1801>>
Acesso em: Fevereiro de 2021.

**ARTIGO 2- USANDO RPA PARA ACESSAR A INVERSÃO DA CLOROFILA
NA CULTURA DO CAFÉ EM DUAS ESTAÇÕES DE CRESCIMENTO**

(VERSÃO PRELIMINAR)

RESUMO

O café tem importância comercial por ser uma *commodity* agrícola, além de ser fonte de renda familiar rural no Brasil. O método de inversão da clorofila (Chl) para estimar teor de clorofila do dossel (Chl_{canopy}), utiliza o teor de clorofila da folha (Chl_{leaf}) e o Índice de Área Foliar (LAI). Arelado a esta metodologia e no contexto do Sensoriamento Remoto (SR), a utilização de Índice de Vegetação (IV) que caracteriza o conteúdo de Chl_{canopy} se faz relevante uma vez que os IVs fornecem informações vitais para o monitoramento da cultura, auxiliando na tomada de decisão. Neste sentido, o objetivo deste trabalho foi identificar qual Índice de Vegetação (IV) é adequado para explicar a metodologia de inversão de Clorofila (Chl) e avaliar as relações entre os IVs obtidos a partir de imagem de *Remotely Piloted Aircraft* (RPA) e os índices de clorofila da folha (Chl_{leaf}) e de clorofila do dossel (Chl_{canopy}) em cafeeiros no período chuvoso e da seca. O experimento foi realizado em uma lavoura cafeeira pertencente à Universidade Federal de Lavras, Lavras, Minas Gerais, Brasil. As imagens foram coletadas no dia 26 de novembro de 2019, no dia 11 de agosto de 2020 e no dia 26 de agosto de 2021. Dados de altura, diâmetro e Chl de plantas foram coletadas em campo. O processamento das imagens foi realizado no software Pix4D, o pós-processamento e o cálculo dos IVs foram realizados no Quantum Gis. Posteriormente, as análises estatísticas foram realizadas do software R. Os IVs que melhor explicaram a Chl no período chuvoso foram os IVs $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} . Tais IVs apresentam alta sensibilidade e, por isso, são mais afetados pela variabilidade da clorofila. Para ambos os períodos da seca estudados, não encontrou um padrão nas relações de Chl_{leaf} , Chl_{canopy} e os IVs. Foi possível utilizar a metodologia de inversão de Chl na cultura do cafeeiro na época da chuva.

Palavras-chave: Sistemas de Aeronaves Não Tripuladas. Clorofila do dossel. Cafeeiros. *Coffea arabia* L.

ABSTRACT

Coffee is commercially important because it is an agricultural commodity and a source of rural family income in Brazil. The chlorophyll inversion (Chl) method to estimate canopy chlorophyll content (Chl_{canopy}) uses the leaf chlorophyll content (Chl_{leaf}) and the Leaf Area Index (LAI). Linked to this methodology and in the context of Remote Sensing (SR), the use of the Vegetation Index (IV) that characterizes the content of Chl_{canopy} is relevant since the IVs provide vital information for monitoring the crop, assisting in taking decision. In this sense, the objective of this work was to identify which Vegetation Index (VI) is suitable to explain the Chlorophyll inversion (Chl) methodology and to evaluate the relationships between the IVs obtained from Remotely Piloted Aircraft (RPA) image and the Leaf chlorophyll (Chl_{leaf}) and canopy chlorophyll (Chl_{canopy}) indices in coffee trees during the rainy and dry seasons. The experiment was conducted in a coffee plantation belonging to the Federal University of Lavras, Lavras, Minas Gerais, Brazil. A rotary-wing RPA was used, in autonomous flight mode, containing a conventional camera, 30 m high, with 80% image overlap and 3 m / s speed Images were collected on November 26, 2019, August 11, 2020, and August 26, 2021. Plant height, diameter, and Chl data were collected in the field. The image processing was performed in the PhotoScan software, the post-processing and the calculation of the IVs were performed in the Quantum Gis. Subsequently, statistical analyzes were performed using the R software. The IVs that best explain Chl were the IVs $MCARI2_{RPA}$, MSR_{RPA} , and SR_{RPA} . Such IVs are highly sensitive and, are, therefore, more affected by chlorophyll variability. Both drought periods evaluated did not find a pattern in the relationships between Chl_{leaf} , Chl_{canopy} , and IVs. It was possible to use the Chl inversion methodology in the coffee crop in the rainy season.

Keywords: Unmanned Aircraft System (UAS). Canopy Chlorophyll. Coffee Crop. *Coffea arabia* L.

1 INTRODUÇÃO

A produção mundial de café para a safra 2020/21 prevista é de 7,0 milhões de sacas (60 quilos) a mais que no ano anterior, sendo o Brasil responsável pela maior parte desta produção (USDA, 2021). Neste contexto, o café representa uma importância comercial por ser uma *commodity* agrícola, além de ser fonte de renda familiar rural no país.

Entretanto, há evidências crescentes de que os produtores tem enfrentado desafios na produção do café devido às alterações climáticas ocorridas nas principais regiões produtoras de café, como no Sul de Minas Gerais, que obtiveram chuvas abaixo da média histórica (SOUZA et al., 2016) e aumento de incidência e severidade de pragas e doenças (POZZA et al., 2010 e MARIN et al., 2019). Diante destes desafios, os custos de produção aumentaram, e houve a redução da qualidade e quantidade do grão. De acordo com Chemura e Odindi (2017) a cultura cafeeira apresenta custos significativos de insumos, além disso a cultura requer avaliações intra e inter-sazonais das condições da safra e monitoramento do status da lavoura e, da produtividade para obter rentabilidade e uma produção sustentável.

Parâmetros morfológicos do cafeeiro (por exemplo altura, diâmetro, Índice de Área Foliar- LAI) (SANTOS et al. 2020a; SANTOS et al. 2020b) e parâmetros fisiológicos (por exemplo clorofila- Chl) (PUTRA; SONI, 2018; CHEMURA; ODINDI, 2017) são bons indicadores da condição da vegetação e auxiliam no monitoramento da cultura, além de ter a possibilidade de estarem relacionados com a produtividade.

Estudos recentes em Sensoriamento Remoto (SR) utilizando novas tecnologias como os *Remotely Piloted Aircraft* (RPA), têm demonstrado uma visão diferente da lavoura, representando o olho do agricultor no céu, o que facilitou e difundiu esta tecnologia no campo. Segundo Salami et al. (2014) a tecnologia RPA representa uma mudança de paradigma. Diferente das imagens de satélites e dos levantamentos aerotransportados, as imagens obtidas por RPAs apresentam alta resolução espacial (em centímetros e até milímetros) e alta resolução temporal (por exemplo, adquiridas várias vezes por dia) além de baixos custos operacionais, servindo como complemento para as tecnologias já existentes favorecendo a Agricultura de Precisão e a Cafeicultura de Precisão.

Entretanto, segundo Milas et al. (2018) a transferência de algoritmos empíricos de imagens de satélites para imagens de RPA é um desafio, principalmente a resolução espacial, já que as imagens RPA são imagens com alto detalhamento, afetando a importância dos parâmetros estruturais na obtenção do conteúdo de clorofila (Chl).

O modelo de transferência radiativa (RTM) abordado por Jacquemoud et al. (2009) é amplamente utilizado para gerar refletâncias do topo do dossel, considerando variáveis biofísicas medidas da cultura de interesse. É uma combinação do modelo de nível de folha e modelo de nível de dossel como descrito por Upreti et al. (2019). Foi utilizado em uma grande variedade de vegetação como: árvore de álamos (MERONI et al., 2004); beterraba (RICHTER et al., 2014); algodão (PALACHARLA et al., 2011); eucalipto (LE MAIRE et al., 2011); pastagem (SI et al., 2012); milho (RICHTER et al., 2014; MILAS et al., 2018), dossel florestal (WANG et al., 2018), com diferentes graus de sucesso.

No entanto, esta metodologia não foi aplicada em dados obtidos a partir de imagens de RPA na cultura do cafeeiro. O método de inversão da Chl para estimar teor de clorofila do dossel (Chl_{canopy}), utiliza o teor de clorofila da folha (Chl_{leaf}) e o LAI como descrito por Liang et al. (2016) e Milas et al. (2018). Atrelado a esta metodologia e no contexto do SR, a utilização de Índice de Vegetação (IV) que caracteriza o conteúdo de Chl_{canopy} se faz relevante uma vez que os IVs, segundo Ahmad et al. (2021), fornecem informações vitais para o monitoramento da cultura, auxiliando na tomada de decisão

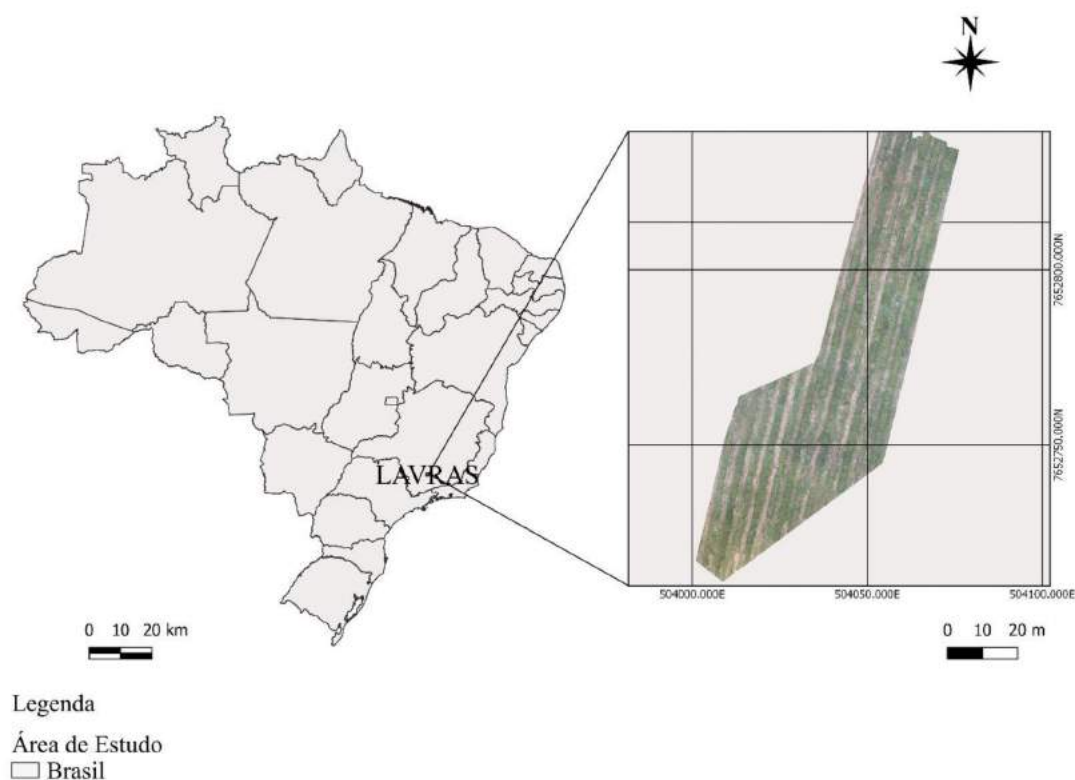
A hipótese deste estudo é de que imagens de alta resolução espacial obtidas a partir de RPA, produzem melhores resultados de estimativa de Chl do dossel de cafeeiro em relação as imagens de satélites, e que esta estimativa melhora utilizando a inversão/transformação do conteúdo de Chl_{leaf} em conteúdo de Chl_{canopy} calculado como $Chl_{leaf} \times LAI$ como os estudos de Liang et al. (2016) e Milas et al. (2018). Neste sentido, o objetivo deste trabalho foi identificar qual IVs é adequado para explicar a metodologia de inversão de Chl e avaliar as relações entre os IVs obtidos a partir de imagem RPA e os índices de Chl_{leaf} e de Chl_{canopy} em cafeeiros no período chuvoso e da seca.

2 MATERIAL E MÉTODOS

Local de estudo e coleta de dados de campo

O estudo foi realizado em uma lavoura experimental de cafeeiro (*Coffea arabica* L.) em Lavras, Minas Gerais, Brasil (21°13'36.47"S, 44°57'40.35W) (Figura 2.1). A lavoura pertence ao Setor de Cafeicultura do Departamento de Agricultura - DAG, da Universidade Federal de Lavras (UFLA) na qual possui tratamentos experimentais relacionados à otimização da água na cafeicultura cujos tratamentos são descritos por Castanheira et al. (2019) e Alecrim et al. (2020). A área da lavoura é de 0,48 ha, com plantas de cafeeiro da cultivar “Mundo Novo 379-19”, plantada em janeiro de 2016, no espaçamento 3,6 metros nas entrelinhas de plantio e 0,75 metros entre as plantas.

Figura 2.1- Localização da área de estudo.



Fonte: Da autora (2021).


Utilizou-se 90 parcelas experimentais. Cada parcela experimental foi composta por seis plantas, sendo consideradas como plantas úteis as quatro centrais. Entre as linhas de tratamento, utilizou-se uma linha de bordadura, de forma a evitar interferência. A área em estudo, as

parcelas amostradas e pontos de controle, foram georreferenciadas com auxílio de um sistema global de posicionamento diferencial (DGPS- *differential global positioning system*; Trimble Navigation Limited, Sunnyvale, California, USA) com precisão horizontal e vertical de 0,007m.

Coleta de dados RPA

Para coletar as informações espectrais de RPA sobre a lavoura, utilizou um quadricóptero (Matrice 100, DJI) (Figura 2.2a) como plataforma RPA, na qual possui quatro motores alimentados por uma bateria, controlada remotamente.

Figura 2.2- Equipamentos: (a) Aeronave Remotamente Pilotada (*Remotely Piloted Aircraft-RPA*) Matrice 100 utilizado para o levantamento; (b) a câmera Parrot Sequoia™ (sensores de imagem e irradiância); (c) o alvo de calibração da câmera; (d) um exemplo dos pontos de controle.



Fonte: Da autora (2021).

Trata-se de uma RPA robusta na qual foi controlada por meio de um plano de voo automatizado utilizando o aplicativo *Precision Flight* instalado em um smartphone. O plano de voo foi configurado a uma altitude de 30 metros acima do nível do solo, com sobreposição de 80 % frontal e lateral, e velocidade de 3 m/s, conforme a metodologia de Santos et al. (2020a). Sendo assim obteve-se uma resolução espacial de $0,03 \text{ m pixel}^{-1}$.

A RPA possui uma estrutura para estabilização da câmera, amortecimento, orientado perpendicularmente ao solo na qual foi a câmera multiespectral Parrot Sequoia com cinco sensores de imagem: um Visível 16 Megapixel (MP) (RGB) e quatro de 1,2 MP: verde, vermelho, borda do vermelho, Infravermelho próximo, detalhes estão descritos na Tabela 2.1 e Figura 2.2b, no entanto neste trabalho foram utilizadas as bandas: verde, vermelho, borda do vermelho e Infravermelho próximo.

Tabela 2.1- Especificações da câmera Parrot Sequoia.

Câmera	Parrot Sequoia™
Peso	107g
Dimensões	5,9 x 4,1 x 2,9 cm
Faixa Espectral	Verde (0,53-0,57 μm), Vermelho (0,64-0,68 μm), borda do vermelho (0,73-0,74 μm), Infravermelho próximo (0,77-0,81 μm)

Fonte: Da autora (2021).

Foram realizados três voos em diferentes épocas, o primeiro voo foi no dia 26 de novembro de 2019 (período chuvoso), segundo voo foi no dia 11 de agosto de 2020 e o terceiro voo foi no dia 26 de agosto de 2021 ambos no período seco. As imagens multiespectrais foram coletadas por volta de meio-dia, com céu claro e ensolarado, afim de minimizar os efeitos das nuvens e geração de sombras nas imagens. Antes de cada voo, utilizou-se um painel de calibração radiométrica, do qual foram tiradas imagens com a câmera que posteriormente foram utilizadas para calibrar as imagens capturadas sobre a área (Figura 2.2c).

As imagens foram processadas no software Pix4Dmapper Pro, versão educacional, seguindo o workflow de processamento disponível no software, na qual as fotos foram calibradas, alinhadas geometricamente para construir a nuvem de pontos, modelo 3D, modelo digital de terreno (MDT), modelo digital de superfície (MDS) e ortomosaico.

Os ortomosaicos foram georreferenciados no software Qgis versão 3.10 (Quantum GIS) na projeção cartográfica UTM no datum SIRGAS 2000, zona 23 Sul, realizando uma transformação polinomial de primeira ordem com método de reamostragem vizinho mais próximo, utilizando 6 pontos de controle (Figura 2.2d) distribuídos na área.

Os IVs são cálculos com base na combinação de bandas espectrais, eles são comumente usados como indicadores importantes para monitorar crescimento, prever rendimentos dentre outras aplicações. Neste estudo, foram calculados 21 IVs descritos na Tabela 2.2. Tais IVs foram obtidos por meio da média das plantas úteis através da ferramenta estatística zonal do QGis.

Tabela 2.2- Índices de vegetação obtidos a partir da refletância das bandas multiespectrais das imagens RPA.

Índices de Vegetação	Equação	Fonte
Canopy Chlorophyll Content Index (CCCI)	$CCCI = \frac{NDRE}{NDVI}$	Eitel et al. (2010)
CI _{green}	$CI_{green} = \left(\frac{\rho_{NIR}}{\rho_{green}} \right) - 1$	Rundquist et al. (2004)
CI _{red edge}	$CI_{red\ edge} = \left(\frac{\rho_{NIR}}{\rho_{red\ edge}} \right) - 1$	Rundquist et al. (2004)
Enhanced Vegetation Index 2-Green (EVI _{2green})	$EVI_{2green} = \frac{2.5 \times (\rho_{green} - \rho_{red})}{\rho_{green} + 2.4 \times \rho_{red} + 1}$	Putra e Soni (2017)
First modified chlorophyll absorption ratio index (MCARI ₁)	$MCARI_1 = 1.2 \left[\frac{2.5(\rho_{NIR} - \rho_{green}) - 1.3(\rho_{NIR} - \rho_{green})}{\sqrt{2(\rho_{NIR} + 1)^2 - (6\rho_{NIR} - 5\sqrt{\rho_{red}}) - 0.5}} \right]$	Haboudane et al. (2004)
Second modified chlorophyll absorption ratio index (MCARI ₂)	$MCARI_2 = \frac{1.5 \left[\frac{2.5(\rho_{NIR} - \rho_{red}) - 1.3(\rho_{NIR} - \rho_{green})}{\sqrt{2(\rho_{NIR} + 1)^2 - (6\rho_{NIR} - 5\sqrt{\rho_{red}}) - 0.5}} \right]}{GMR}$	Haboudane et al. (2004)
Green Minus Red (GMR)	$GMR = \rho_{green} - \rho_{red}$	Wang et al. (2013)
Green normalized difference vegetation index (GNDVI)	$GNDVI = \frac{\rho_{NIR} - \rho_{green}}{\rho_{NIR} + \rho_{green}}$	Gitelson et al. (1996)
Modified normalized difference vegetation index 1 (MTVI ₁)	$MTVI_1 = 1.2 \left[\frac{1.2(\rho_{NIR} - \rho_{green}) - 2.5(\rho_{red} - \rho_{green})}{\sqrt{2(\rho_{NIR} + 1)^2 - (6\rho_{NIR} - 5\sqrt{\rho_{red}}) - 0.5}} \right]$	Haboudane et al. (2004)
Modified normalized difference vegetation index 2 (MTVI ₂)	$MTVI_2 = \frac{1.5 \left[\frac{1(\rho_{NIR} - \rho_{green}) - 2.5(\rho_{red} - \rho_{green})}{\sqrt{2(\rho_{NIR} + 1)^2 - (6\rho_{NIR} - 5\sqrt{\rho_{red}}) - 0.5}} \right]}{MNGRDI}$	Haboudane et al. (2004)
Modified normalized green red difference index (MNGRDI)	$MNGRDI = \frac{\rho_{green}^2 - \rho_{red}^2}{\rho_{green}^2 + \rho_{red}^2}$	Bendig et al. (2015)
MSAVI (modified SAVI)	$MSAVI = 0.5 \left[\frac{2\rho_{NIR} + 1 - \sqrt{(2\rho_{NIR} + 1)^2 - 8(\rho_{NIR} - \rho_{red})}}{\sqrt{(\rho_{NIR}/\rho_{red}) + 1}} \right]$	Qi et al. (1994)
MSR (modified SR)	$MSR = \frac{(\rho_{NIR}/\rho_{red}) - 1}{\sqrt{(\rho_{NIR}/\rho_{red}) + 1}}$	Chen (1996)
Normalized Difference Red Edge (NDRE)	$NDRE = \frac{\rho_{NIR} - \rho_{red\ edge}}{\rho_{NIR} + \rho_{red\ edge}}$	Barnes et al. (2000)
Normalized difference vegetation index (NDVI)	$NDVI = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}}$	Rouse et al. (1973)
Normalized Green-Red Difference Index (NGRDI)	$NGRDI = \frac{\rho_{green} - \rho_{red}}{\rho_{green} + \rho_{red}}$	Tucker (1979)
Optimized Soil Adjusted Vegetation Index-Green (OSAVI _{green})	$OSAVI_{green} = \frac{1.5(\rho_{green} - \rho_{red})}{(\rho_{green} + \rho_{red}) + 0.16}$	Putra e Soni (2017)
RDVI (renormalized difference vegetation index)	$RDVI = \frac{\rho_{NIR} - \rho_{red}}{\sqrt{\rho_{NIR} + \rho_{red}}}$	Roujean e Breon (1995)
Simple Ratio (SR)	$SR = \frac{\rho_{NIR}}{\rho_{red}}$	Birth e McVey (1968)
Soil Adjusted Vegetation Index-Green (SAVI _{green})	$SAVI_{green} = \frac{(1 + 0.5) \times (\rho_{green} - \rho_{red})}{(\rho_{green} + \rho_{red}) + 0.5}$	Li et al. (2010)
TVI (triangular vegetation index)	$TVI = 0.5 \left[120(\rho_{NIR} - \rho_{green}) - 200(\rho_{red} - \rho_{green}) \right]$	Broge e Leblanc (2001)

Fonte: Da autora (2021).

Obtenção de Parâmetros Morfológicos e Fisiológicos

Determinaram-se os índices de clorofila na folha: a ($Chla_{leaf}$), b ($Chlb_{leaf}$) e total ($ChlT_{leaf}$), obtidos por meio do aparelho digital ClorofiLOG (modelo CFL 1030) e coletados no mesmo dia dos voos da RPA. O aparelho fornece os índices proporcionais à absorvância das clorofilas. As leituras foram realizadas entre as 9 e 11 horas da manhã, utilizando uma folha completamente expandida, localizada no terceiro ou quarto nó a partir do ápice do ramo plagiotrópico, no terço médio da planta. Apenas as folhas normais, e as folhas não sofridas por quaisquer pragas e doenças, foram consideradas. Em cada parcela, escolheu-se uma planta, totalizando 90 folhas analisadas.

A média da altura da planta (H) e do diâmetro de copa (D) das 4 plantas úteis de cada parcela foram medidas por meio de uma régua graduada em metros. Para o cálculo do índice de área foliar (LAI), utilizou-se a Equação (1), conforme descrita por Favarin et al. (2002):

$$LAI=0,0134+0,7276 \times D^2 \times H \quad (1)$$


Os índices de clorofila do dossel: a ($Chla_{canopy}$), b ($Chlb_{canopy}$) e total ($ChlT_{canopy}$) foram determinados a partir da Equação 2 e de acordo com os estudos de Liang et al. (2016) e Milas et al. (2018):

$$Chl_{canopy} = Chl_{leaf} \times LAI \quad (2)$$

Dados meteorológicos

Os dados meteorológicos mensais de precipitação pluviométrica total (mm), temperatura mínima (T min, em °C), temperatura máxima (Tmax, em °C) e umidade relativa (UR, em %), foram obtidas por meio da estação meteorológica do Instituto Nacional de Meteorologia (INMET), situada na Universidade Federal de Lavras (UFLA), no período de 01/11/2019 a 31/08/2021.

Figura 2.3- Representação gráfica das variáveis meteorológicas registradas, mensalmente, em Lavras - MG, no período novembro 2019 a agosto de 2021.



Fonte: Da autora (2021).

Análises estatísticas dos dados

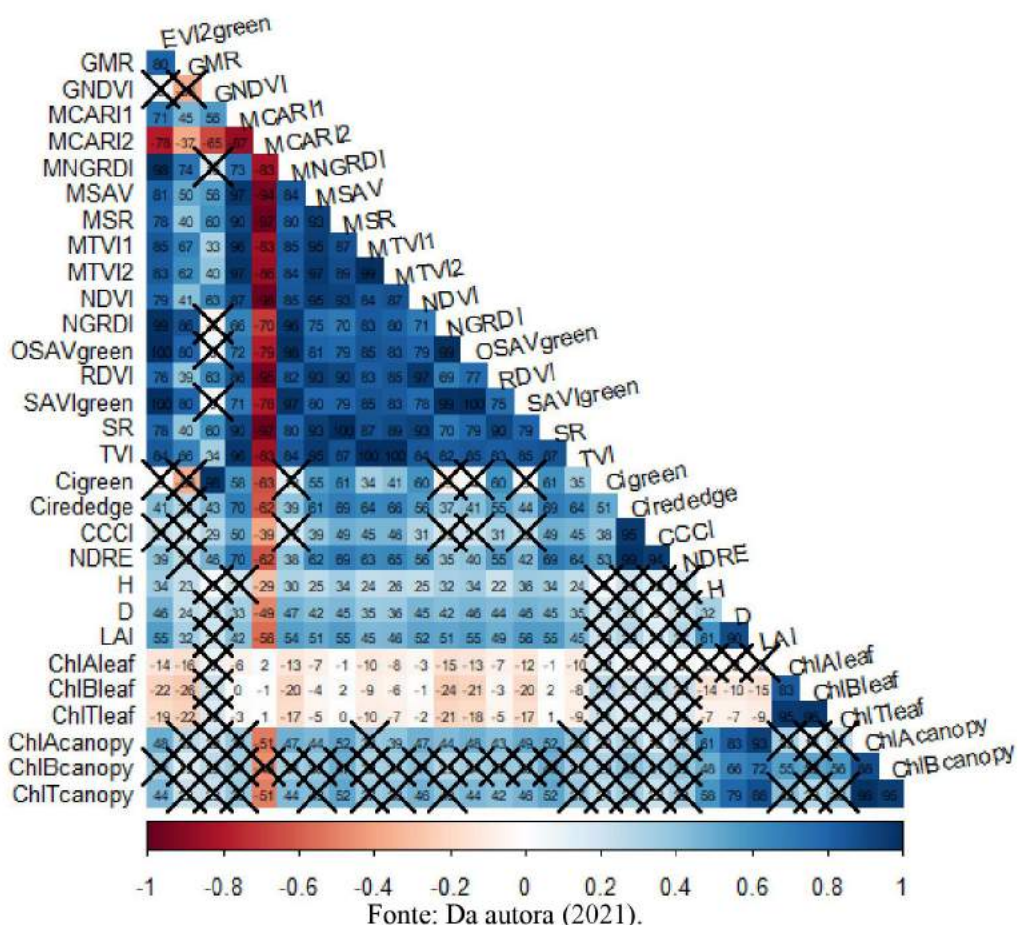
Foi realizada estatística descritiva (média, mediana, máximo, mínimo, primeiro e terceiro quartil) para dar suporte à análise exploratória dos dados. Os dados de $ChlA_{leaf}$, $ChlB_{leaf}$, $ChlT_{leaf}$, $ChlA_{canopy}$, $ChlB_{canopy}$ e $ChlT_{canopy}$ foram correlacionados com os 21 IV utilizando a correlação de Pearson (R) e nos dois períodos de estudo. Para avaliar se as estimativas foram significativas, p-valor $p < 0,05$, aplicou-se teste de t de Student, calculou-se os resíduos como a diferença entre os dados dos IV estimados pelas imagens da RPA e as medições de campo, também calculou a Média Absoluta do Erro (MAE), bem como a Raiz Quadrada do Erro Médio (RMSE). As análises estatísticas descritivas foram realizadas no software estatístico R (R Core Team, Viena, Áustria).

3 RESULTADOS E DISCUSSÃO

Período Chuvoso

Conforme ilustrado na Figura 3.1, a correlação entre H, D, LAI, Chl_{canopy} e os IVs foi positiva e moderada, sendo observado na coloração azul. Já a correlação entre os IVs e a Chl_{leaf} e entre o IV MCARI2 e os parâmetros morfológico e fisiológicos foi negativa, conforme pode-se observar na coloração vermelha. Além disso observa que a maior correlação entre Chl_{leaf} e os IVs apresentou correlações negativa e fraca ($R=-0,26$). Já a maior correlação entre a Chl_{canopy} e os IVs foi boa e positiva ($R \leq 0,52$), exceto a correlação entre o IV MCARI2 e a Chl_{canopy} e, $ChIT_{canopy}$ que foi boa, porém negativa ($R=-0,51$). A correlação entre o IV MCARI1 e a $ChIB_{leaf}$ e, entre o IV MSR e a $ChIT_{leaf}$ foi nula ou muito fraca ($R=0$).

Figura 3.1- Coeficientes de correlação e não significância do teste de t de Student (representada com x) entre os IVs e os parâmetros morfofisiológicos de cafeeiros, no período chuvoso (novembro de 2019). As correlações positivas são exibidas em azul e as correlações negativas em vermelho. Assim como as correlações fortes estão em tons intensos e as correlações fracas estão em tons claros.



Houve variações significativas ($p \leq 0,05$) entre os IVs e os parâmetros morfológicos e fisiológicos, entretanto, houveram correlações não significativas ($p > 0,05$) como pode ser observado na Figura 3.1, na qual o x representa p-valor maior que o nível de significância de 5%. A relação entre $ChlB_{canopy}$ e IV foi não significativa, bem como os IVs que são compostos pela razão do verde e do NIR (GNDVI e CIgreen) e do REG e NIR (CIrededge, CCCI e NDRE) não apresentaram relação com os parâmetros morfológicos (H, D e LAI) e fisiológicos ($ChlA_{leaf}$, $ChlB_{leaf}$, $ChlT_{leaf}$, $ChlA_{canopy}$, $ChlB_{canopy}$ e $ChlT_{canopy}$). De modo similar a relação entre os IV GMR e $ChlA_{canopy}$, $ChlB_{canopy}$ e $ChlT_{canopy}$; entre o IV MCARI1 e os parâmetros H, $ChlA_{canopy}$, $ChlB_{canopy}$ e $ChlT_{canopy}$; entre IV MSAV e a $ChlB_{canopy}$ e $ChlT_{canopy}$; entre MTVII e $ChlA_{canopy}$, $ChlB_{canopy}$ e $ChlT_{canopy}$; entre MTVI2 e a $ChlB_{canopy}$ e $ChlT_{canopy}$; entre NGRDI e a $ChlB_{canopy}$ e $ChlT_{canopy}$ e entre TVI a $ChlA_{canopy}$, $ChlB_{canopy}$ e $ChlT_{canopy}$, não apresentaram correlações significativas.

Diante dos resultados, este estudo considerou somente as análises com variações significativas ($p \leq 0,05$) e com coeficiente de correlação maiores que 0,50 positivo e/ou negativo. Logo, foram analisados as relações entre Chl_{canopy} e os IVs $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} , sendo estes IVs adequados, estatisticamente, para explicar a metodologia de inversão de Chl.


Como observado na Figura 3.2, os IV $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} não foram altamente correlacionados com a $ChlA_{leaf}$, encontrou-se valores de $R=0,02$ e $R^2=0,01$ para o IV $MCARI2_{RPA}$ e $R=-0,01$ e $R^2=-0,01$ para os IV MSR_{RPA} e SR_{RPA} . Resultados semelhantes foram encontrados por Bento (2020), na qual a autora estudou a estimativa $ChlT_{leaf}$, por meio de dados radiométricos dos índices de vegetação (IVs) obtidos a partir de RPA em uma lavoura cafeeira (*Coffea arabica L.*) recém transplantada, com cultivares Catucaí (2SL), Catucaí (IAC 62) e Bourbon (IAC J10) e idade de 5 meses no início dos trabalhos, em que os resultados não foram significativos para a variável estudada.

Embora o estudo de Bento (2020) tenha seguido a metodologia para medir o teor de clorofila da folha, estes resultados se dão devido a capacidade de medição e estimativa dos IVs obtidos a partir de imagens RPA, uma vez que as informações obtidas por meio da imagem reverbera um resultado considerando a clorofila do dossel e as medidas que foram correlacionadas representam uma medida de uma única folha em uma determinada planta. Além disso, deve-se levar em consideração a metodologia utilizado, podendo melhorar a correlação ao adotar outras metodologias de obtenção da Chl. Outra hipótese que pode melhorar é a obtenção de medidas em diferentes partes e lados da planta.

Ademais, este resultado pode ser atribuído à idade dos cafeeiros em estudo, na qual na data da coleta os cafeeiros se encontravam com 3 anos de idade. Chemura e Odindi (2017) investigaram um algoritmo para prever clorofila em plantas cafeeiras utilizando dados do Sentinel-2 em diferentes resoluções espaciais e diferentes idades de plantas. Os resultados demonstraram que os melhores resultados de modelagem ($R^2 = 0,69$, $RMSE = 6,8$) foram alcançados quando todas as bandas a 10 m resolução espacial foram usados na modelagem de Chl para todos os cafés. A precisão da predição melhorou ($R^2 = 0,77$, $RMSE = 5,9$) quando apenas cafeeiros entre 5 e 8 anos foram considerados.

Contudo, os resultados no presente estudo, melhoraram consideravelmente quando $ChlA_{leaf}$ foi multiplicada pelo LAI, utilizando a metodologia de inversão de Chl no período da chuva. O coeficiente de correlação mudou de $R=0,02$ para $R=-0,51$ e o coeficiente de determinação mudou de $R^2=-0,01$ para $R^2=0,26$ na relação entre o IV MCARI2_{RPA} e a $ChlA_{leaf}$ (Figura 3.2a). Já o coeficiente de correlação dos IVs MSR_{RPA} e a $ChlA_{leaf}$ (Figura 3.2b) e entre o IV SR_{RPA} e a $ChlA_{leaf}$ (Figura 3.2c) mudou de $R=-0,01$ para $R=0,52$, e o coeficiente de determinação foi de $R^2=-0,01$ para $R^2=0,26$ em ambas as relações, passando de uma relação nula para uma correlação significativa ($p \leq 0,05$) e diferente de zero.

Figura 3.2- Relação entre (a) MCARI2_{RPA} e medições do conteúdo de clorofila A no dossel ($ChlA_{canopy}$); (b) MSR_{RPA} e $ChlA_{canopy}$; (c) SR_{RPA} e $ChlA_{canopy}$.




Fonte: Da autora (2021).

Resultados semelhantes foram obtidos por Milas et al. (2018), no qual os autores utilizando o LAI para obter o mapeamento de clorofila usando imagens RPA na cultura do milho, alcançaram uma alta correlação do IV Normalized Difference Red Edge (NDRE) com a clorofila do dossel, ou seja, calculada a partir do produto do teor de Chl foliar e LAI. No estudo dos autores citado, o coeficiente de determinação passou de $R^2 = 0,177$ para $R^2 = 0,774$ quando os autores obtiveram a clorofila do dossel utilizando o LAI.

As bandas utilizadas neste estudo que apresentaram valores estatisticamente significativos foram as bandas NIR, Red e Green. Segundo Haboudane et al. (2004) o MSR e o SR apresentam uma melhoria nas imagens no que diz respeito à sensibilidade e à relação linear com parâmetros morfológicos da vegetação e o MCARI2 são menos sensíveis às variações do conteúdo de clorofila e linearmente relacionados ao LAI. Ressalta-se que no estudo citado de Milas et al. (2018), os autores utilizaram a banda Red Edge na cultura do milho, isso mostra a importância de estudar a metodologia em diferentes culturas, pois cada cultura apresenta seu próprio comportamento espectral.

Todavia, assim como nos resultados apresentados na Figura 3.2, a relação de regressão entre os IVs $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} e a $ChlT_{canopy}$ melhorou consideravelmente utilizando a metodologia de inversão da Chl. O coeficiente de correlação entre o IV $MCARI2_{RPA}$ e a $ChlT_{leaf}$ mudou de $R=0,01$ para $R=-0,51$ (Figura 3.3a) e o coeficiente de determinação modificou de $R^2=-0,01$ para $R^2=0,26$. Já o coeficiente de correlação entre MSR_{RPA} e a $ChlT_{leaf}$ (Figura 3.3b) foi de $R=0,00$ para $R=0,52$ e entre o IV SR_{RPA} e a $ChlT_{leaf}$ (Figura 3.3c) mudou de $R=0,01$ para $R=0,52$, e o coeficiente de determinação foi de $R^2=-0,01$ para $R^2=0,26$ em ambas as relações, passando de uma relação nula para uma correlação significativa ($p \leq 0,05$) e diferente de zero.

Figura 3.3- Relação entre (a) $MCARI2_{RPA}$ e medições do conteúdo de clorofila T na folha ($ChlT_{canopy}$); (b) MSR_{RPA} e $ChlT_{canopy}$; (c) SR_{RPA} e $ChlT_{canopy}$.



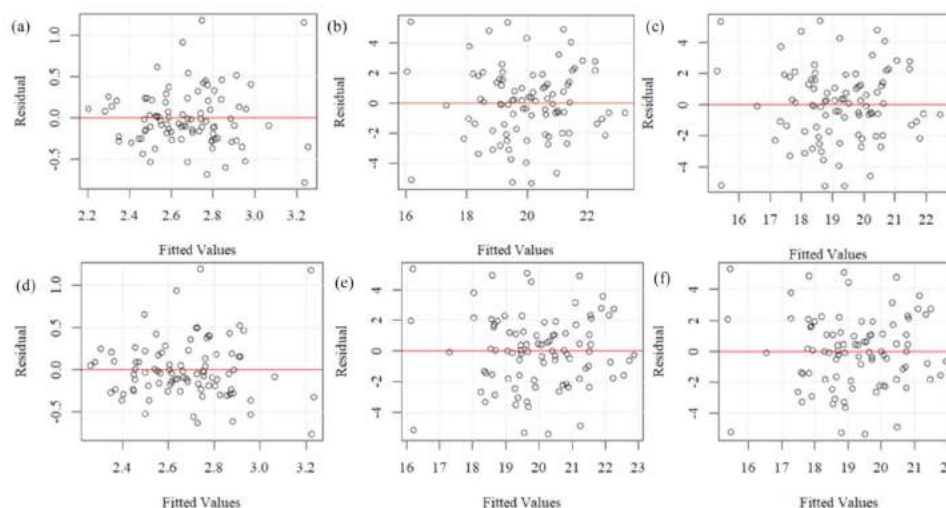
Fonte: Da autora (2021).

O valor de RMSE e MAE demonstrou bom desempenho para estimar Chl a partir do IVs estudados, além disso os IVs MSR_{RPA} e SR_{RPA} apresentaram valores de RMSE e MAE maiores quando comparado com o IV $MCARI2_{RPA}$ (Figura 3.3)

Para avaliar a eficácia do modelo da regressão, calculou-se o erro ou os resíduos para cada ponto dos dados que foram correlacionados. A Figura 3.4 ilustra a dispersão dos resíduos

que estão de acordo com os pressupostos da regressão, na qual os resíduos devem ser distribuídos aleatoriamente em torno de zero.


Figura 3.4- Resíduos dos valores estimados pelos IV_{RPA} e os parâmetros medidos em campo: (a) $MCARI2_{RPA}$ e $ChlA_{canopy}$ (b) MSR_{RPA} e $ChlA_{canopy}$ (c) SR_{RPA} e $ChlA_{canopy}$ (d) $MCARI2_{RPA}$ e $ChlT_{canopy}$ (e) MSR_{RPA} e $ChlT_{canopy}$ (f) SR_{RPA} e $ChlT_{canopy}$.



Fonte: Da autora (2021).

O IV $MCARI2_{RPA}$ (Figura 3.5a) tem uma relação inversa, na qual destaca o solo com a cor amarelo e a vegetação com a cor azul e roxo. Este índice apresentou uma correlação negativa com a Chl. Resultados diferentes foram encontrado no estudo de Haboudane et al. (2004) correlação positiva entre $MCARI2$ e Chl da cultura do milho e trigo, este resultado pode ser atribuído a variações de comportamento espectral distintos entre culturas.

Figura 3.5- Mapas dos IV da área de estudo: (a) $MCARI2_{RPA}$; (b) MSR_{RPA} ; (c) SR_{RPA} .



Fonte: Da autora (2021).

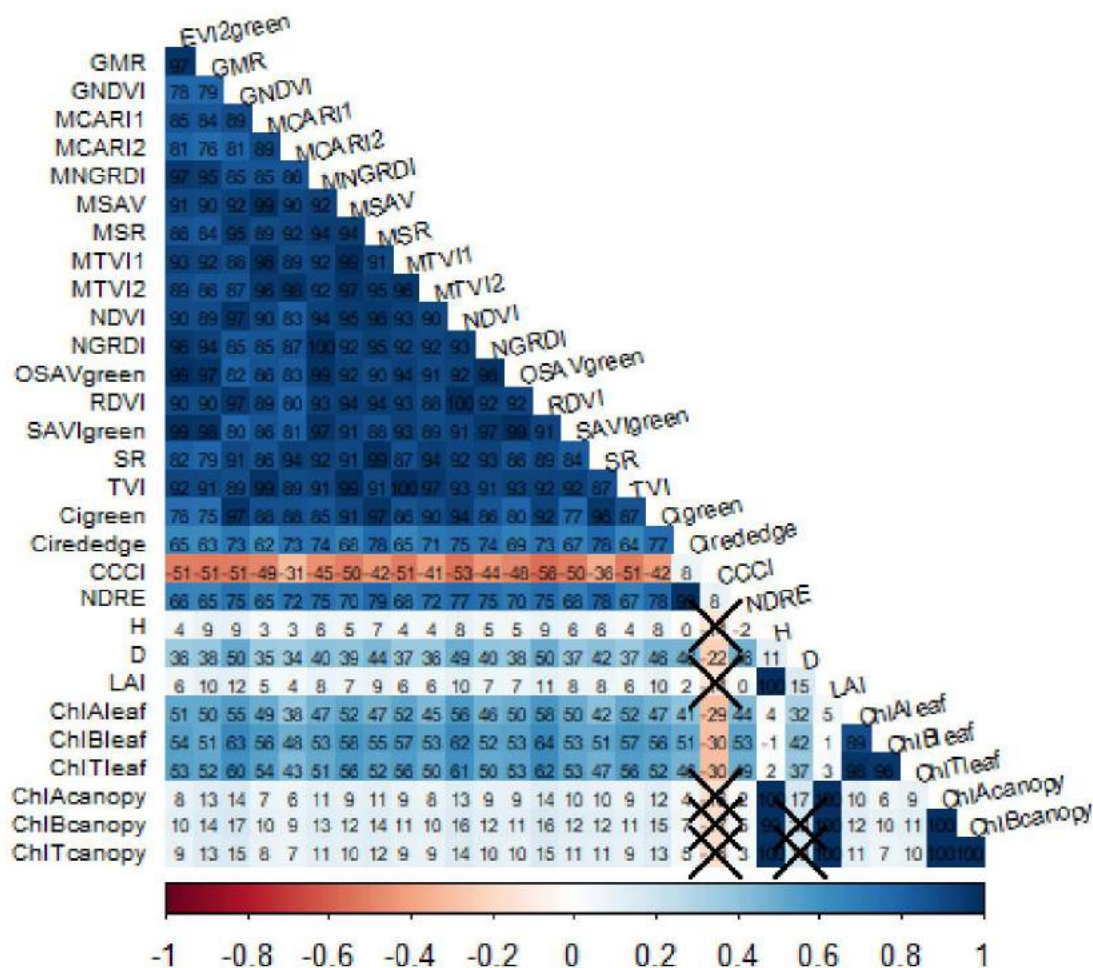
Nas Figuras 3.5b e 3.5c é possível observar uma semelhança na caracterização e variabilidade dos IV MSR_{RPA} e SR_{RPA} . Nota-se que os maiores valores de IV são apresentados na cor verde e o solo se destaca com a cor roxa, além disso, percebe-se uma variabilidade dos IV entre os tratamentos.

Segundo Haboudane et al. (2004), os IVs $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} apresentam alta sensibilidade e, por isso, são mais afetados pela variabilidade da clorofila. Segundo os mesmos autores, isso deve-se a composição das fórmulas dos IVs levar em consideração as bandas do red, green e NIR nos quais são bandas altamente correlacionadas com Chl_{leaf} e Chl_{canopy} .

Período Seco

Para o período seco do ano de 2020, a correlação entre H, LAI, Chl_{canopy} e os IVs foi positiva e fraca, sendo observado na coloração de tons claros de azul, já a correlação entre os IVs e o D e entre os IVs e a Chl_{leaf} foi positiva e moderada sendo observada na coloração de azul mais intenso, apresentada na Figura 3.6. A relação entre o D e o IV CCCI e entre a Chl_{leaf} e este mesmo índice apresentou uma correlação negativa e fraca podendo ser observado em tons claros de vermelho. A relação entre o IV CCCI e a H, LAI, Chl_{canopy} não foi significativa (Figura 3.6), na qual o x representa p-valor maior que o nível de significância de 5%.

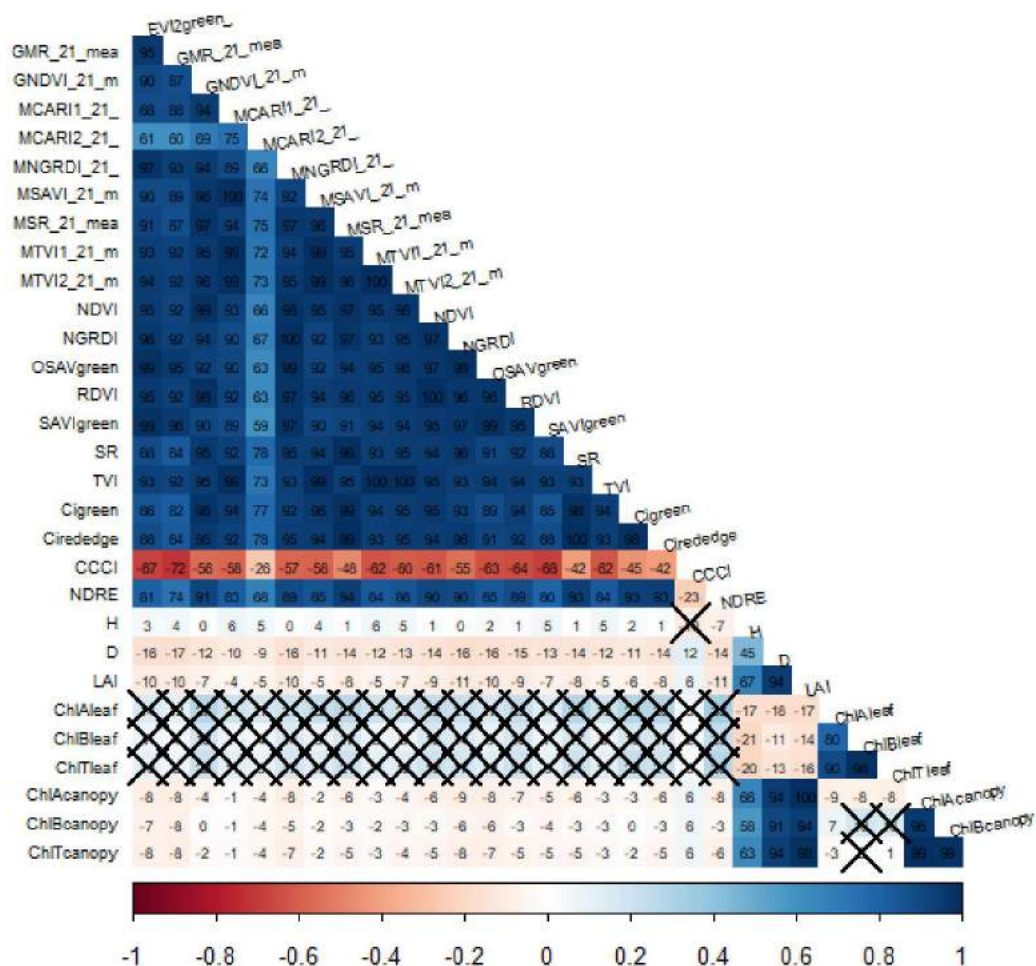
Figura 3.6- Coeficientes de correlação e não significância do teste de t de Student (representada com x) entre os IVs e os parâmetros morfofisiológicos de cafeeiros, no período seco (Agosto de 2020). As correlações positivas são exibidas em azul e as correlações negativas em vermelho, correlações fortes estão em tons intensos e as correlações fracas estão em tons claros.



Fonte: Da autora (2021).

Para o período seco do ano de 2021, a correlação entre H, D, LAI, Ch_{lcanopy} e os IVs foi negativa e fraca, sendo observado na coloração em tons claros de vermelho na Figura 3.7. Já a correlação entre os IVs e a Ch_{lleaf} e entre o IV CCCI e a H não foi significativa (Figura 3.7).

Figura 3.7- Coeficientes de correlação e não significância do teste de t de Student (representada com x) entre os IVs e os parâmetros morfofisiológicos de cafeeiros, no período seco (Agosto de 2021). As correlações positivas são exibidas em azul e as correlações negativas em vermelho. Assim como as correlações fortes estão em tons intensos e as correlações fracas estão em tons claros.



Fonte: Da autora (2021).

Para ambos os períodos da seca estudados, não encontrou-se um padrão nas relações de Chl_{leaf} , Chl_{canopy} e os IVs. No período seco de 2020, a correlação entre Chl_{leaf} e os IVs foi maior que a correlação entre Chl_{canopy} e os IVs. No período seco de 2021, a correlação entre Chl_{leaf} e os IVs não foi significativa e a correlação entre Chl_{canopy} e os IVs foi negativa e fraca. Estes resultados foram o inverso do encontrado para o período chuvoso de 2019, e pode ser atribuído às variações climáticas (Figura 2.3) principalmente com a precipitação e temperatura, na qual no período seco a lavoura se encontrava em déficit hídrico devido à baixa na precipitação.

Alguns estudos avaliando plantas em situação de deficiência hídrica observaram que os teores de clorofila aumentaram com a diminuição do conteúdo volumétrico de água no solo

(PEREIRA et al., 2011; YIN et al., 2016). Já os estudos realizados por Alonso Zuñiga et al. (2019) observaram que plantas de café cultivadas no inverno e crescendo sob estresse hídrico não apresentaram mudanças quanto ao teor de clorofila.

Embora a metodologia de inversão da Chl não seja nova, o estudo explora o impacto da alta resolução espacial de imagens RPA para obter mapeamento da Chl de cafés utilizando IV. Diante disso, na agricultura e principalmente na cafeicultura de precisão, estas aplicações são válidas, uma vez que ocorrem mudanças fenológicas rápidas, sendo possível acompanhá-las com esta tecnologia.

Diante dos resultados encontrados na época da seca, e por se tratar de um tema incipiente na cafeicultura quanto a resultados efetivos sobre a relação entre a Chl_{leaf} , Chl_{canopy} e os IVs, discute-se a necessidade de estudos para avaliar estas relações entre a clorofila e IVs.

Recomenda-se aplicar esta metodologia em diferentes cultivares, diferentes níveis de deficiência hídrica além de avaliar outros IVs que possam surtir resultados melhores. Vale ressaltar que a metodologia estudada apresenta especificidades da estrutura do dossel, da época de coleta de dados, da iluminação referente à data de aquisição dos dados, do sensor utilizado, da calibração e do processamento das imagens. Desta maneira, ao utilizar esta abordagem para aplicar IVs de maneira generalizada para determinada cultura, recomenda-se um banco de imagens adquiridas abrangendo grande variação de fatores acima citado, além disso, dados de campo devem ser coletados para fazer a validação do método e validar em épocas diferentes. Outra recomendação é realizar trabalhos que estudem a correlação das bandas do visível com valores de Chl, visto que se as bandas do visível interagem com a ChlA e ChlB, pode-se utilizar RPA de baixo custo para a obtenção e estimativas desses parâmetros utilizando esta tecnologia.

4 CONCLUSÃO

Foi possível utilizar a metodologia de inversão de Chl na cultura do cafeeiro na época da chuva. As relações entre os IV $MCARI2_{RPA}$, MSR_{RPA} e SR_{RPA} foram próximas e apropriadas para estimar Chl_{canopy} no período chuvoso.

Para ambos os períodos da seca estudados, não encontrou um padrão nas relações de Chl_{leaf} , Chl_{canopy} e os IVs. Diante do resultados encontrados na época da seca, e por se tratar de um tema incipiente na cafeicultura quanto a resultados efetivos sobre a relação entre a Chl_{leaf} , Chl_{canopy} e os IVs, discorre-se à necessidade de estudos para avaliar estas relações entre a clorofila e IVs.

Agradecimentos

À Universidade Federal de Lavras (UFLA) e ao Programa de pós-graduação em engenharia agrícola (PPGEA) pelo apoio ao estudo. Ao Consórcio Pesquisa Café (projeto aprovado no edital nº 20/2018) - Embrapa Café pelo financiamento à pesquisa. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro. Ao Setor de Cafeicultura da UFLA, ao NESA e NECAF pelo apoio e desenvolvimento da pesquisa.

REFERÊNCIAS

- AHMAD, A.; ORDOÑEZ, J.; CARTUJO, P.; MARTOS, V. (2021). Remotely Piloted Aircraft (RPA) in Agriculture: A Pursuit of Sustainability. **Agronomy**, [S. l.], v.11, n.1, p.7, 2021.
- ALECRIM, A. O.; CASTANHEIRA, D. T.; VOLTOLINI, G. B.; NETTO, P. M.; GUIMARÃES, R. J.; GONÇALVES, A. H. Phytosociology of weeds in coffee plants with different soil management techniques. **Scientia Agraria Paranaensis**, [S. l.], v.19, n.3, p.270-279, 2020.
- ALONSO ZUÑIGA, E.; RUIZ MACHUCA, L. M.; DOS SANTOS, O. F.; CRUZ DE SOUZA, M. L.; FRANCO DE OLIVEIRA, D. P.; BROETTO, F. Comportamento fisiológico de mudas de cafeeiro arábica (cv. Obatã e catucaí) submetidas à deficiência hídrica. **Irriga**, [S. l.], v. 24, n. 4, p. 890–899, 2019.
- BARNES, E.M.; CLARKE, T.R.; RICHARDS, S.E.; COLAIZZI, P.D.; HABERLAND, J.; KOSTRZEWSKI, M.; WALLER, P.; CHOI, C.; RILEY, E.; THOMPSON, T.; LASCANO, R.J.; LI, H.; MORAN, M.S. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. **In Proceedings of the Fifth International Conference on Precision Agriculture**, Bloomington, MN, USA, p.16–19, 2000.
- BENDIG, J.; KANG, Y.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. “Combining UAV-Based Plant Height from Crop Surface Models, Visible, and near Infrared Vegetation Indices for Biomass Monitoring in Barley.” **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v.39 p.79–87, 2015.
- BENTO, N. L. **Índices de vegetação em lavouras cafeeiras por sistema de aeronave remotamente pilotada**. 65 p. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Lavras, Lavras, 2020.
- BIRTH, G. S.; MCVEY, G. R. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, [S. l.], v.60, p.640-643, 1968.
- BROGE, N. H.; LEBLANC, E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote Sensing of Environment**, [S. l.], v.76, p.156-172, 2000.
- CASTANHEIRA, D. T.; BARCELOS, T. R.; GUIMARÃES, R. J.; CARVALHO, M. A. D. F.; REZENDE, T. T.; BASTOS, I. D. S.; CRUVINEL, A. H. Agronomic techniques for mitigating the effects of water restriction on coffee crops. **Coffee Science**, Lavras, v. 14, n. 1, p. 104 - 115, 2019.
- CHEMURA, A.; MUTANGA, O.; ODINDI, J. Empirical modeling of leaf chlorophyll content in coffee (*coffea arabica*) plantations with sentinel-2 msi data: Effects of spectral settings, spatial resolution, and crop canopy cover. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v.10, n.12, p.5541-5550, 2017.

CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, [S. l.], v.22, n.3, p. 229–242, 1996.

EITEL, J. U. H.; KEEFE, R. F.; LONG, D. S.; DAVIS, A. S.; VIERLING, L. A. Active ground optical remote sensing for improved monitoring of seedling stress in nurseries. **Sensors**, [S. l.], v.10, n.4, p.2843–2850, 2010.

FAVARIN, J. L.; NETO, D. D.; GARCÍA Y GARCÍA, A.; NOVA, N. A. V.; FAVARIN, M. D. G. G. V. Equações para a estimativa do índice de área foliar do cafeeiro. **Pesquisa Agropecuária Brasileira**, [S. l.], v.37, n.6, p.769-773, 2002.

GITELSON, A. A.; MERZLYAK, M. N. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. **Journal of Plant Physiology**, [S. l.], v.148 p.494-500, 1996.

HABOUDANE, D.; MILLER, J. R.; PATTEY, E.; ZARCO-TEJADA, P. J.; STRACHAN, I. B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, [S. l.], v.90, n.3, p.337-352, 2004.

JACQUEMOUD, S.; VERHOEF, W.; BARET, F.; BACOUR, C.; ZARCO-TEJADA, P. J.; ASNER, G. P.; FRANÇOIS, C.; USTIN, S. L. PROSPECT+ SAIL models: A review of use for vegetation characterization. **Remote Sensing of Environment**, [S. l.], v.113, p.S56-S66, 2009.

LE MAIRE, G.; MARSDEN, C.; VERHOEF, W.; PONZONI, F.J.; SEEN, D.L.; BÉGUÉ, A.; STAPE, J.-L.; NOUVELLON, Y. Leaf area index estimation with MODIS reflectance time series and model inversion during full rotations of Eucalyptus plantations. **Remote Sensing of Environment**, [S. l.], v.115, p.586–599, 2011.

LI, Y.; CHEN, D.; WALKER, C. N.; ANGUS, J. F. Estimating the nitrogen status of crops using a digital camera. **Field Crops Research**, [S. l.], v.118, n.3, p.221–227, 2010.

LIANG, L.; QIN, Z.; ZHAO, S.; DI, L.; ZHANG, C.; DENG, M.; LIN, H.; ZHANG, L.; WANG, L.; LIU, Z. Estimating crop chlorophyll content with hyperspectral vegetation indices and the hybrid inversion method. **International Journal of Remote Sensing**, [S. l.], v.37, p.2923–2949, 2016.

MARIN, D. B.; ALVES, M. de C.; POZZA, E. A.; BELAN, L. L.; FREITAS, M. L. de O. Multispectral radiometric monitoring of bacterial blight of coffee. **Precision Agriculture**, [S. l.], v.20, n.5, p.959-982, 2019.

MERONI, M.; COLOMBO, R.; PANIGADA, C. Inversion of a radiative transfer model with hyperspectral observations for LAI mapping in poplar plantations. **Remote Sensing of Environment**, [S. l.], v.92, p.195–206, 2004.

MILAS, A. S.; ROMANKO, M.; REIL, P.; ABEYSINGHE, T.; MARAMBE, A. The importance of leaf area index in mapping chlorophyll content of corn under different agricultural treatments using UAV images. **International Journal of Remote Sensing**, [S. l.], v.39, n.15-16, p.5415-5431, 2018.

PALACHARLA, P.K.; DURBHA, S.S.; KING, R.L.; GOKARAJU, B.; LAWRENCE, G.W. A hyperspectral reflectance data based model inversion methodology to detect reniform nematodes in cotton. **In Proceedings of the 6th International Workshop on the Analysis of Multi-Temporal Remote Sensing Images (Multi-Temp)**, Trento, Italy, 2011.

PEREIRA, T. B.; BALIZA, D. P.; CUNHA, R. L.; GUIMARÃES, R. J.; GOMES, R. A.; PEREIRA, V. A. Teores de clorofila em cafeeiros submetidos a diferentes ambientes avaliados por dois métodos de determinação. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL. Anais...(07.: 2011: Araxá, MG).Embrapa-Café, Item 40, p.1-4, 2011

POZZA, E. A.; CARVALHO, V. L.; CHALFOUN, S. M. Sintomas de injurias causadas por doenças do cafeeiro. In R. J. Guimarães, A. N. G. Mendes, & D. P. Baliza (Eds.), **Semiologia do Cafeeiro**, [S. l.], p.67–106, 2010.

PUTRA, B. T. W.; SONI, P. Enhanced broadband greenness in assessing Chlorophyll a and b, Carotenoid, and Nitrogen in Robusta coffee plantations using a digital camera. **Precision Agriculture**, [S. l.], v.19, n.2, p.238-256, 2018.

PUTRA, B. T. W.; SONI, P. Evaluating NIR-Red and NIR-Red edge external filters with digital cameras for assessing vegetation indices under different illumination. **Infrared Physics & Technology**, [S. l.], v.81, p.148–156, 2017.

QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v.48, n.2, p.119–126, 1994.

RICHTER, K.; ATZBERGER, C.; VUOLO, F.; WEIHS, P.; D'URSO, G. Experimental assessment of the Sentinel-2 band setting for RTM-based LAI retrieval of sugar beet and maize. **Canadian Journal of Remote Sensing**, [S. l.], v.35, p.230–247, 2014.

ROUJEAN, J.-L.; BREON, F.-M. "Estimating PAR Absorbed by Vegetation from Bidirectional Reflectance Measurements." **Remote Sensing of Environment**, [S. l.], v.51 n.3, p.375–384, 1995.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **Third Earth Resources Technology Satellite-1 Symposium**, [S. l.], v.1, p.309–317, 1973.

RUNDQUIST, D.C.; GITELSON, A.A.; VIÑA, A.; ARKEBAUER, T.J.; KEYDAN, G.; LEAVITT, B. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, [S. l.], v.30, p.52-1–52-4, 2003.

SALAMI, E.; BARRADO, C.; PASTOR, E. UAV Flight Experiments Applied to the Remote Sensing of Vegetated Areas. **Remote Sensing**, [S. l.], v.6, p.11051–11081, 2014.

SANTOS, L. M.; BARBOSA, B. D. de s.; DIOTTO, A. V.; MACIEL, D. T.; XAVIER, L. A. G. Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture**, [S. l.], v.21, n.6, p.1227-1241, 2020a.

SANTOS, L. M.; BARBOSA, B. D. de S.; DIOTTO, A. V.; ANDRADE, M. T., CONTI, L.; ROSSI, G. Determining the Leaf Area Index and Percentage of Area Covered by Coffee Crops

Using UAV RGB Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v.13, p.6401-6409, 2020b.

SI, Y.; SCHLERF, M.; ZURITA-MILLA, R.; SKIDMORE, A.; WANG, T. Mapping spatio-temporal variation of grassland quantity and quality using MERIS data and the PROSAIL model. **Remote Sensing of Environment**, [S. l.], v.121, p.415–425, 2012.

SOUZA, A. J. de J.; GUIMARÃES, R. J.; COLOMBO, A.; SANT'ANA, J. A. D. V.; CASTANHEIRA, D. T. Quantitative analysis of growth in coffee plants cultivated with a water-retaining polymer in an irrigated system1. **Revista Ciência Agronômica**, [S. l.], v.47, n.1, p.162-171, 2016.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Disponível em:<<http://usda.mannlib.cornell.edu/MannUsda/viewDocumentInfo.do?documentID=1801>> Acesso em: Fevereiro de 2021.

UPRETI, D.; HUANG, W.; KONG, W.; PASCUCCI, S.; PIGNATTI, S.; ZHOU, X.; YE, H.; CASA, R. A Comparison of Hybrid Machine Learning Algorithms for the Retrieval of Wheat Biophysical Variables from Sentinel-2. **Remote Sensing**, [S. l.], v.11, n.5, p.481, 2019.

WANG, Y.; WANG, D.; ZHANG, G.; WANG, J. Estimating nitrogen status of rice using the image segmentation of G-R thresholding method. **Field Crops Research**, [S. l.], v.149, p.33–39, 2013.

WANG, Z.; SKIDMORE, A. K.; DARVISHZADEH, R.; WANG, T. Mapping forest canopy nitrogen content by inversion of coupled leaf-canopy radiative transfer models from airborne hyperspectral imagery. **Agricultural and Forest Meteorology**, [S. l.], v.253, p.247-260, 2018.

YIN, C. Y.; PANG, X. Y.; PEUKE, A. D.; WANG, X.; CHEN, K.; GONG, R. G. Growth and photosynthetic responses in *Jatropha curcas*L. seedlings of different provenances to watering regimes. **Photosynthetica**, Lysolaje, [S. l.], v. 54, n. 3, p. 367-373, 2016.

**ARTIGO 3- AVALIAÇÃO DA DISTRIBUIÇÃO ESPACIAL DA
TEMPERATURA DE CAFEEIROS OBTIDA POR CAMERA TERMAL ABORDO DE
AERONAVE REMOTAMENTE PILOTADA**

(VERSÃO PRELIMINAR)

RESUMO

O café tem grande importância no mercado nacional e internacional, sendo um dos principais produtos agrícolas. Parâmetros fisiológicos são geralmente associados aos processos de crescimento e desenvolvimento das plantas, sendo úteis para indicar interrupções nestes processos. Diante disso, este estudo teve como objetivo caracterizar a temperatura obtida por meio de uma câmera termal embarcada em uma *Remotely Piloted Aircraft* (RPA) e avaliar sua relação com o potencial hídrico (PH) e condutância estomática (gs) de uma lavoura experimental de cafeeiros por meio do uso das técnicas geoestatísticas. O experimento foi realizado em uma lavoura cafeeira pertencente à Universidade Federal de Lavras, Lavras, Minas Gerais, Brasil. Utilizou-se uma RPA de asa rotativa, em modo de voo autônomo, contendo uma câmera termal embarcada, altura de 10 m e velocidade de 10 m/s. As imagens foram coletadas no dia 26 de novembro de 2019 (período chuvoso) e no dia 11 de agosto de 2020 (período seco), no horário entre 9h30 e 11h30. Dados de gs e PH amostradas foram coletados em campo. O processamento das imagens termais foi realizado no software FLIR Tools. Realizou-se a análise e espacialização da temperatura utilizando ferramentas de geoestatística e mapa de isocores por interpolação por Krigagem no software R. Posteriormente, os dados de campo foram cruzados e sobrepostos nos mapas finais de temperatura da lavoura utilizando o software QuantumGIS. Com os dados de gs, PH e os mapas de temperatura, pode-se observar que com a redução do PH, houve o fechamento estomático e a redução da gs, favorecendo o aumento da temperatura por déficit hídrica nos períodos estudados. Observou-se também a distribuição espacial da temperatura obtida por meio de câmera termal embarcada na RPA. Os mapas de distribuição da temperatura permitiram visualizar a distribuição espacial heterogênea, além de identificar áreas onde as plantas estavam expostas a condições de variações climáticas podendo indicar deficiência hídrica.

Palavras-chave: Sistemas de Aeronaves Não Tripuladas. Condutância Estomática. Cafeeiros. Potencial Hídrico. Geoestatística.

ABSTRACT

Coffee is of great importance in the national and international market, one of the leading agricultural products. Biochemical parameters are generally associated with plant growth and development processes, being useful to indicate interruptions in these processes. Therefore, this study aimed to characterize the temperature obtained using a Remotely Piloted Aircraft (RPA) and evaluate its relationship with the water potential and stomatal conductance of an experimental coffee plantation through the use of geostatistical techniques. The experiment was conducted in a coffee plantation belonging to the Federal University of Lavras, Lavras, Minas Gerais, Brazil. A rotary wing RPA was used, in autonomous flight mode, containing an onboard thermal camera, the height of 10 m and speed of 10 m/s. The images were collected on November 26, 2019 (rain period) and August 11, 2020 (dry period), between 9:30 and 11:30. Data on stomatal conductance (gs) and water potential of the plants sampled (PH) were collected in the field. The processing of thermal images was performed using FLIR Tools software. The analysis and spatialization of temperature were carried out using geostatistical tools and isocor map by Kriging interpolation in the R software. Subsequently, field data were crossed and overlaid on the final crop temperature maps using the QuantumGIS software. With the data of gs, PH and temperature maps, it can be observed that the decrease in temperature favored the increase in gs and the decrease in PH. It was also observed the spatial distribution of the temperature obtained through a thermal camera embedded in the RPA. The temperature distribution maps allowed to visualize the heterogeneous spatial distribution, and identify areas where the plants were exposed to climatic conditions that could indicate water deficit.

Keywords: Unmanned Aircraft System (UAS). Stomatal Conductance. Coffee Crop. Water Potential. Geostatistics.

1 INTRODUÇÃO

A cadeia produtiva cafeeira desempenha papel fundamental na agricultura nacional e internacional contribuindo diretamente na economia global. Sendo assim, cuidados são necessários para garantir o padrão de qualidade e quantidade da produção do grão. Segundo Voltolini et al. (2019), fatores como nutrição, relações hídricas, características do solo, dentre outros, podem interferir na produtividade e qualidade dos frutos. Em períodos de muita seca, caso não se adote irrigação, a produtividade pode ser reduzida em até 80% (DAMATTA & RAMALHO, 2006).

Para minimizar esta situação de déficit hídrico e evitar prejuízos no crescimento dos cafeeiros, medidas de otimização da água na lavoura estão sendo estudadas. Segundo Castanheira et al. (2019), o uso de coberturas de solo em lavouras cafeeiras, sejam elas vegetais como o capim braquiária ou artificiais como o filme de polietileno, tem apresentado efeito benéfico, tanto para as características do solo, quanto para as plantas. De acordo com os mesmos autores a técnicas agronômicas como fertilizantes de liberação controlada e condicionadores de solo podem mitigar as restrições hídricas em cafeeiros.

A redução das taxas transpiratórias é uma resposta marcante de plantas submetidas ao déficit hídrico (PELOSO et al., 2017). Segundo Almeida et al. (2020), a abertura estomática provoca perda de água da planta para o meio externo, com isso, em períodos quentes os estômatos permanecem fechados e a taxa fotossintética diminui. Este mecanismo de fechamento estomático causa redução da condutância estomática (gs) que contribui para a redução ou manutenção do potencial hídrico foliar (PH) (CAVATTE et al., 2012).

O Sensoriamento Remoto (SR) obtém informações sobre um objeto à distância, por meio de sensores acoplados à uma plataforma como: um satélite no nível orbital ou uma Aeronave Remotamente Pilotada do termo em inglês *Remotely Piloted Aircraft* (RPA) no nível aéreo. Perante o exposto, o monitoramento das condições hídricas utilizando SR tem-se um elevado potencial por ser de baixo custo, de forma rápida e não destrutiva (CRUSIOL et al., 2018).

Segundo Viana et al. (2018), a utilização de câmeras termais na agricultura tem uma vasta aplicabilidade, sendo possível avaliar estresse hídrico à danos em frutas, segundo os autores, o Brasil ainda carece de avanço em pesquisa que use sensores termais na agricultura, tendo capacidade de expansão e desenvolvimento.

Embarcar sensores, tais como câmeras do espectro visível, multiespectrais e/ou termais em RPAs, podem permitir avaliar as condições hídricas de cafeeiros, propiciando melhor manejo e tomada de decisões em relação às práticas agrícolas. Sendo assim, estudos com este

tipo de tecnologia devem ser explorados para que discussões sejam geradas e as lacunas preenchidas.

Diante do exposto, este estudo teve como objetivo caracterizar a temperatura obtida por meio de uma câmera termal embarcada em uma RPA e avaliar sua relação com o potencial hídrico e condutância estomática de uma lavoura experimental de cafeeiros por meio do uso das técnicas geoestatísticas.


2 MATERIAL E MÉTODOS

Local de estudo

O estudo foi realizado em uma lavoura experimental de cafeeiro (*Coffea arabica* L.) situada no Setor da cafeicultura do Departamento de Agricultura-DAG, na Universidade Federal de Lavras- UFLA, em Lavras-MG, com a cultivar “Mundo Novo 379-19”, espaçamento de 3,6 metros nas entrelinhas de plantio e 0,75 metros entre as plantas. A lavoura possui uma área de 0,48 ha e tratamentos experimentais relacionados à otimização da água na cafeicultura cujos tratamentos são descritos por Castanheira et al. (2019) e Alecrim et al. (2020).

Utilizou-se 90 parcelas experimentais (Figura 2.1). A área de estudo e as plantas centrais de cada parcela foram georreferenciadas com auxílio de um sistema global de posicionamento diferencial (DGPS- differential global positioning system; Trimble Navigation Limited, Sunnyvale, California, USA) com precisão horizontal e vertical de 0,007m.

Figura 2.1- Limite da área de estudo e localização dos pontos amostrais de cada parcela.



Fonte: Da autora (2021).

Medidas de resposta fisiológica

As características fisiológicas foram medidas no dia 26 de novembro de 2019 (período chuvoso) e no dia 11 de agosto de 2020 (período seco) e na planta central de cada parcela. Para as avaliações foram escolhidas folhas localizadas no terço médio da planta, do terceiro ou quarto par de folhas a partir do ápice do ramo plagiotrópico, completamente expandidas e isentas de pragas e doenças.

Para a avaliação da condutância estomática foliar ($gs - mmol m^{-2} s^{-1}$), utilizou-se o porômetro (SC-1, Decagon Devices). As leituras foram feitas nos dois períodos de estudo concomitante com a coletas das imagens da RPA, no período compreendido entre às 9 h e 11 h da manhã.

Para a avaliação do potencial hídrico foliar (PH-MPa), utilizou-se uma câmara de pressão tipo Scholander (modelo 1000, PMS Instrument Company), com operação de até 70 bar. As folhas coletadas no campo foram inseridas na câmara e, posteriormente, aplicou-se uma pressão até que ocorresse a exsudação pelo corte feito no pecíolo da folha. Determinou-se o potencial hídrico foliar no período antemanhã (3 h às 5 h da manhã).


Coleta de dados RPA

Para a obtenção das imagens termográficas da lavoura foi utilizado uma RPA (Matrice 100, DJI) (Figura 2.1a) classificado como plataforma de asa rotativa com quatro hélices. Equipado com câmera termal, marca FLIR, modelo DUO, tamanho de $41 \times 59 \times 30$ mm e peso de 84 g, que possui um sensor na banda do visível e outro na banda termal variando de 7,5 a 13,5 μm (Figura 2.1b). A resolução da banda termal é de 160x120 pixel, uma resolução baixa, sendo possível registrar valores de temperatura de -20 a 60 °C com exatidão de ± 5 °C. No entanto, esta câmera possui a banda do visível RGB (*Red- R, Green- G and Blue- B*) com resolução de 1920x1080 pixels, tendo assim a capacidade de produzir imagem híbrida na saída (FLIR, 2021), melhorando a identificação dos alvos e compensando a baixa resolução da banda termal.

A aquisição de imagens ocorreu no dia 26 de novembro de 2019 (período chuvoso) e no dia 11 de agosto de 2020 (período seco), no horário entre 9h30 e 11h30. Antes de cada voo foram colocadas placas de controle na cor branca e marrom em cada parcela experimental para

serem destacadas nas imagens (Figura 2.1c). As parcelas experimentais foram divididas em 3 blocos com 30 parcelas cada, sendo possível percorrer cada bloco em plano de voo a 10 m do nível do solo e velocidade de 10m/s. Os voos foram planejados com o aplicativo Precision Flight, software gratuito instalado em um android. As imagens capturadas foram armazenadas em um Cartão SD e a temperatura das parcelas foram analisadas utilizando o software FLIR Tools.

Figura 2.2- Equipamentos: (a) RPA utilizado para o levantamento, Matrice 100; (b) a câmera Termal, FLIR DUO; (c) um exemplo das placas de controle utilizado na área de estudo.




Fonte: Da autora (2021).

Dados meteorológicos

Dados meteorológicos mensais de precipitação pluviométrica total (mm), umidade relativa (UR, em %), temperatura mínima (T Mín, em °C) e temperatura máxima (T máx, em °C) foram obtidas por meio da estação meteorológica do Instituto Nacional de Meteorologia (INMET), situada na Universidade Federal de Lavras (UFLA), no período de 01/11/2019 a 31/08/2020 (Figura 2.3).

Figura 2.3- Representação gráfica das variáveis meteorológicas registradas, mensalmente, em Lavras - MG, no período novembro 2019 a agosto de 2020.



Fonte: Da autora (2021).

Análises e validação dos modelos

Com os dados das imagens obtidos em cada parcela, foi realizado um estudo da variabilidade da temperatura na área, para isso utilizou-se a geoestatística e interpolação por Krigagem. Esta análise foi realizada afim de obter mapa de temperatura para toda a área de estudo, pois a câmera não possui geotag, ou seja, informações da posição geográfica não sendo possível obter um mapa ou uma foto termográfica da área inteira.

A dependência espacial dos dados de temperatura do período seco e do período chuvoso foram analisadas por meio de ajuste de semivariograma clássico (VIEIRA et al., 1983).

O modelo foi ajustado a sentimento, sendo o melhor o Gaussiano, no qual é descrito por Oliver e Webster (2014) (Equação 1):

$$\gamma(h) = \begin{cases} 0 & \text{se } |h|=0 \\ C \left[1 - \exp\left(-\frac{|h|^2}{a^2}\right) \right] & \text{se } |h| < 0 \end{cases} \quad (1)$$

onde, h é a distância entre as amostras, C é o patamar e a o alcance prático da dependência espacial.

Segundo Mendes et al. (2019) e Ferreira et al. (2013), o modelo Gaussiano são caracterizados por uma dependência espacial com baixas variações entre os vizinhos mais próximos e maiores para os vizinhos mais distantes, devido ao fato de a temperatura apresentar tais características o modelo é justificado.

Para estimar os parâmetros do modelo utilizou-se o método da Máxima Verossimilhança (*maximum likelihood-ML*). Uma vez escolhido o modelo tem-se a distribuição da semivariância dos dados na qual utilizou para estimar os parâmetros do modelo.

Uma vez escolhido o melhor modelo e seus parâmetros estimados, deve-se verificar a adequabilidade deste modelo com a validação cruzada. De acordo com Isaaks e Srivastava (1989) a validação cruzada (VC) é uma técnica que permite estimar erros comparando os valores preditos dos amostrados. Para estas análises se baseou nos estudos de Ferraz et al. (2012), Santos et al. (2020) e Silva et al. (2021).

Após o ajuste da função do semivariograma foi realizada a interpolação dos dados por Krigagem ordinária, posteriormente gerou-se o mapa da distribuição espacial da temperatura. O grau de dependência espacial (SDD) foi avaliado de acordo com Cambardella et al. (1994). As análises geoestatísticas foram realizadas no software estatístico R (R DEVELOPMENT CORE, 2021), por meio do pacote geoR (RIBEIRO Jr.; DIGGLE, 2001). E para a confecção dos layouts dos mapas utilizou o software QGIS versão 3.10 (Quantum GIS Development Team). Dados potencial hídrico das folhas e condutância estomática foram cruzados e sobrepostos nos mapas finais de temperatura para melhor avaliação das condições hídricas dos cafeeiros.

3 RESULTADOS E DISCUSSÃO

Como maneira de melhor avaliar a temperatura da lavoura, foi utilizada a técnica de geoestatística, que fornecem informações importantes para compreender a sua variabilidade e influência na área de estudo. Sendo assim, os modelos e parâmetros dos semivariogramas experimentais ajustados para a temperatura na lavoura estão apresentados na Tabela 3.1.

Tabela 3.1- Método ML, modelo Gaussiano e parâmetros estimados de semivariogramas experimentais para temperatura na lavoura cafeeira durante o período chuvoso (novembro) e período seco (agosto).

Dia	C₀	C₁	C₀+C₁	a' (m)	SDD		ME	SDME	RE	SDRE
26/11/2019	0,64	5,66	6,29	16,44	90%	forte	-0,02	1,19	-0,01	1,00
11/08/2020	2,06	6,27	8,34	16,76	75%	moderada	0,02	1,95	0,00	1,02

C₀ – Efeito Pepita; C₁ - Contribuição; C₀ + C₁ - Patamar; a' – Alcance Prático; SDD – Grau de Dependência Espacial (C₁/C₀ + C₁)x100; ME – Erro Médio; SDME – Desvio padrão do erro médio; RE – Erro reduzido; SDRE – Desvio padrão do erro reduzido.

Fonte: Da autora (2021).

Podem-se observar na Tabela 3.1 os valores do efeito pepita (C₀) nos diferentes períodos analisados. Este valor indica a variabilidade não explicada levando em consideração a distância de amostragem utilizado (Ferraz et al. 2020). Para o período chuvoso, encontrou-se o menor valor de C₀ comparado com o período seco, isso pode ser atribuído a macro variabilidade, ou seja, a variabilidade espacial da temperatura no período seco foi superior ao estabelecido pelo espaçamento das amostras e/ou devido à alta variação de amplitude da temperatura ocorrido neste período de inverno.

Observa-se que houve um valor de alcance prático (a') próximo para ambos os períodos, sendo assim verifica-se que as amostras se distanciaram até um valor de a' na qual a distância não mais influencia, resultando em uma estabilidade do semivariograma experimental. Estudos realizados por Ferraz et al. (2012), corroboram com este comportamento do semivariograma.

Na análise dos dados, constatou-se que os valores de temperatura no período chuvoso apresentaram forte dependência espacial de acordo com a classificação de Cambardella et al. (1994), já os valores de temperatura no período seco apresentaram moderada dependência espacial de acordo com a mesma classificação.

Nota-se que em ambos os períodos de estudo, o ajuste do semivariograma experimental apresentou valores de ME e RE próximo de zero. Este resultado está de acordo com as recomendações de Ferraz et al. (2012) e indicando a qualidade e eficiência das análises (SILVA et al., 2021 e FARACO et al., 2008).

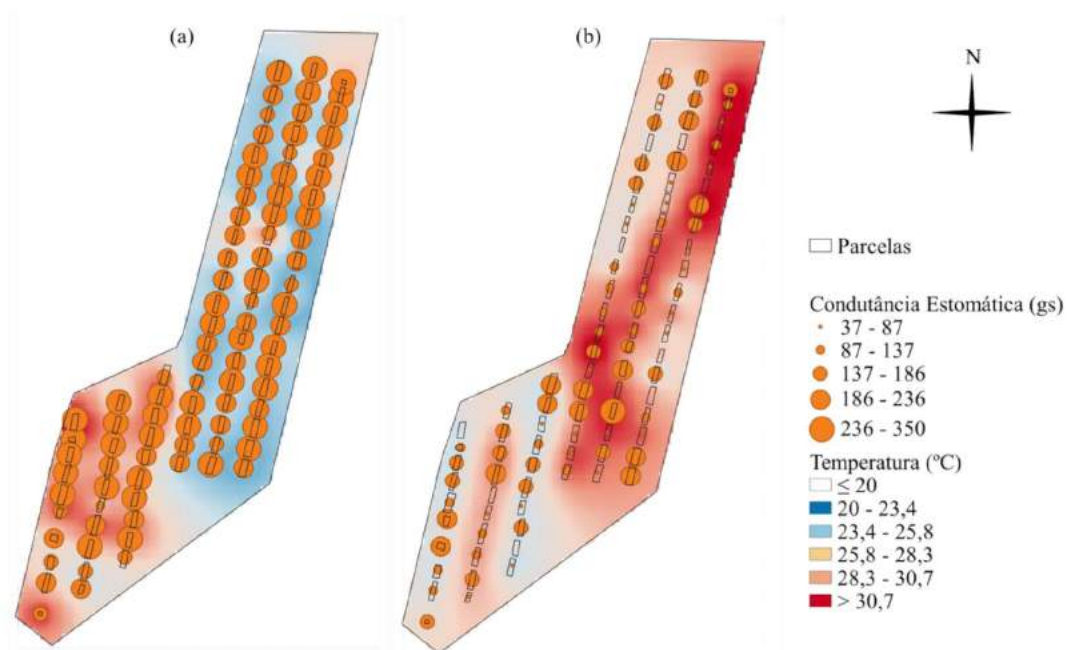
Constatou-se variabilidade espacial da temperatura no ajuste do semivariograma nas análises de geoestatística em ambos os períodos estudados. A temperatura apresentou uma distribuição não homogênea, sendo possível observar esta variabilidade na Figura 3.1. Este resultado pode ser atribuído às variações de características como a gs e PH, devido a respostas fisiológicas das plantas. Além disso, a análise da variabilidade espacial da temperatura permite ver os locais que apresentam aumento da temperatura foliar, esta observação a partir de mapas

isocores pode indicar deficiência hídrica devido a uma resposta a este aumento de temperatura ocorrer fechamento dos estômatos afim de evitar maiores perdas de água por transpiração (STEPPUHN, 2001).

No período chuvoso (Figura 3.1a), a temperatura variou de 24,5 a 32,9 °C sendo a temperatura média foi de 28,4 °C. Os maiores valores de temperatura foram observados na parte inferior esquerda, ou sudoeste da Figura 3.1a. Nos blocos a sudeste e a norte da figura apresentaram a coloração azul claro, com temperaturas mais amenas. Estudos realizados por Crusiol et al. (2018) estão em linha com as observações deste trabalho, na qual os autores ao utilizarem imagem termal acoplada a uma RPA, observaram que plantas submetidas à maior disponibilidade hídrica apresentaram as menores temperaturas do dossel.

Já no período seco (Figura 3.1b), a temperatura variou de 21 a 33,1 °C sendo a temperatura média foi de 25,6 °C. Os maiores valores de temperatura podem ser visualizados na coloração vermelha mais intensa na Figura 3.1b. Na parte inferior e a sudoeste da Figura 3.1b a temperatura foi mais amena, representada pela coloração azul claro. Segundo estudos realizados por Crusiol et al. (2018), observaram que as plantas submetidas ao déficit hídrico apresentaram as maiores temperaturas do dossel. Tais resultados corroboram com este estudo.

Figura 3.1- Distribuição espacial temperatura e condutância estomática (gs) dos cafeeiros. a) período chuvoso; b) período seco.

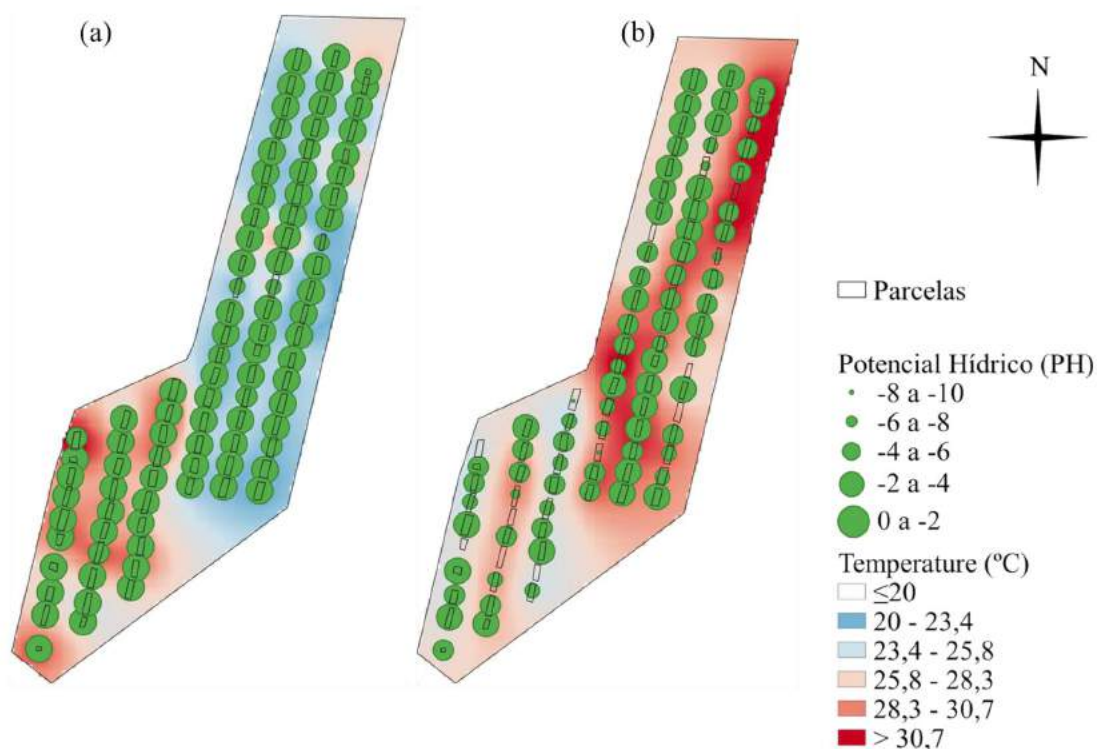


Fonte: Da autora (2021).

Ao avaliar a g_s nos dois períodos de estudo, foi possível observar que com a diminuição da disponibilidade de água (período da seca) (FIGURA 3.1b) os valores de g_s diminuíram consideravelmente na maioria das parcelas favorecendo o aumento da temperatura (Figura 3.1a e 3.1b). Esta resposta é esperada em plantas submetidas ao déficit hídrico. Tais resultados, estão de acordo com Bergonci et al. (2000), na qual os autores afirmam que durante o período de déficit de água, a g_s diminui com a diminuição do conteúdo de água no solo. Segundo Cornic (1992), plantas submetidas à deficiência hídrica apresentam decréscimo da g_s que é considerada uma das primeiras estratégias da planta para impedir a desidratação excessiva das folhas. Com a menor disponibilidade hídrica no período seco (Figura 2.3), os estômatos não abrem ou abrem menos, como mecanismo de defesa do déficit hídrico evitando a desidratação (PACHECO; LAZZARINI; ALVARENGA, 2021). Como resultado deste mecanismo de defesa das plantas ocorreu o aumento de temperatura das folhas no período da seca.

Ao avaliar os valores do PH nos dois períodos de estudo, notou-se que os valores de PH diminuíram do período chuvoso para o período da seca na maioria das parcelas (Figura 3.2a e 3.2b), favorecendo também o aumento da temperatura das folhas. O PH indica o seu estado energético na qual sua medida está relacionada com os fluxos da água no sistema solo-planta-atmosfera, e indica a diferença entre o estado energético no sistema considerado e em um estado de referência conceituado como zero (BERGONCI et al., 2000). É um parâmetro fisiológico utilizado como indicativo de estresse hídrico na cafeicultura. De acordo com Costa e Marengo (2007) o PH diminui se a planta perde água a uma taxa superior à sua capacidade de absorção e transporte, como consequência tem-se o fechamento dos estômatos e redução da fotossíntese, o que leva a um aumento de temperatura da folha. Logo este aumento de temperatura das plantas é verificado devido à redução dos valores de PH diante do período na qual o cafeeiro estava exposto, com baixa disponibilidade hídrica (Figura 2.3).

Figura 3.2- Distribuição espacial temperatura e potencial hídrico (MPa) dos cafeeiros. a) período chuvoso; b) período seco.



Fonte: Da autora (2021).

Este resultado era esperado visto que, com a redução do PH (Figura 3.2b), houve o fechamento estomático e a redução da condutância estomática (gs) (Figura 3.1b), favorecendo o aumento da temperatura por déficit hídrico (Figura 2.3). O contrário também foi válido, na qual o aumento do PH (Figura 3.2a), favoreceu o aumento da gs (Figura 3.1 a), levando à diminuição da temperatura devido a maior transpiração e disponibilidade hídrica no solo. Estes resultados atestam os resultados obtidos por Dominghetti et al. (2016), nos quais os autores observaram que com o aumento da disponibilidade hídrica no solo houve um aumento nos valores de potencial hídrico.

Frequentemente, as plantas abrem seus estômatos para diminuir a temperatura das folhas pela transpiração quando submetidas a temperaturas elevadas do ar. No entanto, são incapazes de realizar este mecanismo de abertura dos estômatos quando submetidos a condições combinadas de alta temperatura e seca (HOWARTH et al., 2018). Como resultado, a temperatura das folhas permanece alta sendo possível observar na Figuras 3.1b e 3.2b. Apesar deste resultado ter ocorrido no período do inverno, foi o período que apresentou alta variação de amplitude térmica e indisponibilidade hídrica. Assim, resultados de combinação de calor e

seca podem ser mais prejudicial para o crescimento e produtividade do cafeeiro quando comparado com estresses analisados de maneira individual (HOWARTH et al., 2018).

Sendo assim, estudos como estes tem a relevância de subsidiar os trabalhos desenvolvidos nos programas de melhoramento do cafeeiro, podendo observar e identificar genótipos que apresentam diferentes valores de temperatura, PH e gs em uma mesma condição ambiental e também em condições de estresses combinados. Além disso, tais resultados podem auxiliar o produtor a identificar, de forma clara e rápida, variações hídricas da lavoura podendo assim, adotar manejos de irrigação na cultura e remediando prejuízos no crescimento e na produtividade dos cafeeiros.

Como trabalhos futuros, recomenda-se pesquisas adicionais utilizando câmeras termais com melhor resolução espacial. Apesar da resolução da câmera utilizada neste estudo não ser comparada a um dispositivo profissional, tem a vantagem de ser menor, poder ser embarcada em RPA e com custo baixo (STOJCSICS et al., 2018). Recomenda-se também estudos destes parâmetros utilizando câmeras hiperespectrais, multiespectrais e câmeras convencionais de baixo custo, visto que as pesquisas estão avançando e tais parâmetros podem ser estimados com boa eficiência.

4 CONCLUSÃO

Foi possível observar a distribuição espacial da temperatura obtida por meio de câmera termal embarcada na RPA. Os mapas de distribuição da temperatura permitiram visualizar a distribuição espacial heterogênea, além de identificar áreas onde as plantas estavam expostas a condições de variações climáticas podendo indicar deficiência hídrica.

Com os dados de gs, PH e os mapas de temperatura, pode-se observar que com a redução do PH, houve o fechamento estomático e a redução da gs, favorecendo o aumento da temperatura por déficit hídrica. Tais resultados podem auxiliar o produtor a identificar, de forma clara e rápida, variações hídricas da lavoura podendo assim adotar manejos de irrigação na cultura.

Agradecimentos

À Universidade Federal de Lavras (UFLA) e ao Programa de pós-graduação em engenharia agrícola (PPGEA) pelo apoio ao estudo. Ao Consórcio Pesquisa Café (projeto aprovado no edital nº 20/2018) - Embrapa Café pelo financiamento à pesquisa. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro. Ao Setor de Cafeicultura da UFLA, ao NESA e NECAF pelo apoio e desenvolvimento da pesquisa.

REFERÊNCIAS

ALECRIM, A. O.; CASTANHEIRA, D. T.; VOLTOLINI, G. B.; NETTO, P. M.; GUIMARÃES, R. J.; GONÇALVES, A. H. Phytosociology of weeds in coffee plants with different soil management techniques. **Scientia Agraria Paranaensis**, [S. l.], v.19, n.3, p.270-279, 2020.

ALMEIDA, V. G.; SOUSA, C. M.; DOS SANTOS, S. G. F.; SARTI, J. K.; DA SILVA, D. P.; PEREIRA, W. Trocas gasosas de cafeeiros (*Coffea arabica*) em altas temperaturas no Cerrado goiano. **Research, Society and Development**, [S. l.], v. 9, n.11, e4779119973-e4779119973, 2020.

BERGONCI, J. I.; BERGAMASCHI, H.; ROSA, L. M. G.; SANTOS, A. O. Condutância foliar como um indicador de déficit hídrico em milho. **Revista Brasileira de Agrometeorologia**, [S. l.], v. 8, n.1, p.27-34, 2000.

CAMBARDELLA, C. A.; MOORMAN, T. B.; PARKIN, T. B.; KARLEN, D. L.; NOVAK, J. M.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of America Journal**, [S. l.], v.58, p.1501-1511, 1994.

CASTANHEIRA, D. T.; BARCELOS, T. R.; GUIMARÃES, R. J.; CARVALHO, M. A. D. F.; REZENDE, T. T.; BASTOS, I. D. S.; CRUVINEL, A. H. Agronomic techniques for mitigating the effects of water restriction on coffee crops. **Coffee Science**, Lavras, v. 14, n. 1, p. 104 - 115, 2019.

CAVATTE, P. C.; OLIVEIRA, Á. A.; MORAIS, L. E.; MARTINS, S. C.; SANGLARD, L. M.; DAMATTA, F. M. Could shading reduce the negative impacts of drought on coffee: a morphophysiological analysis. **Physiologia Plantarum**, Copenhagen, v. 144, p. 111-122, 2012.

CRUSIOL, L.; NANNI, M.; FURLANETTO, R.; SIBALDELLI, R.; MERTZ-HENNING; L. M., NEPOMUCENO, A.; FARIAS, J. NDVI e imagem termal obtidos por vant aplicados ao monitoramento da condição hídrica da cultura da soja. VII Congresso Brasileiro de Soja. 2018.

DAMATTA, F. M.; RAMALHO, J. D. C. Impact of drought and temperature stress on coffee physiology and production: a review. **Brazilian Journal of Plant Physiology**, Londrina, v. 18, n. 1, p. 55-81, 2006.

DOMINGHETTI, A. W., SOUZA, A. J. D. J., SILVEIRA, H. R. D. O., SANT'ANA, J. A. D. V., SOUZA, K. R. D. D., GUIMARÃES, R. J., & LACERDA, J. R. Tolerância ao déficit hídrico de cafeeiros produzidos por estaquia e embriogênese somática. **Coffee Science**, Lavras, v. 11, n. 1, p. 117-126, 2016.

FARACO, M.A; URIBE-OPAZO, M.A; SILVA, E.A.A; JOHANN, J.A.; BORSSOI, J.A. Seleção critérios de modelos de variabilidade espacial utilizados em mapas temáticos de atributos físicos do solo e rendimento da soja. **Revista Brasileira de Ciência do Solo**, [S. l.], v.32, p.463–476, 2008.

FERRAZ, G.A.S.; SILVA, F.M.D.; CARVALHO, L.C.; ALVES, M.D.C.; FRANCO, B.C. Variabilidade espacial e temporal do fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola**, [S. l.], v.32, p.140–150, 2012.

FERRAZ, P. F. P.; FERRAZ, G. A.; MOURA, R. S. D.; CECCHIN, D.; SILVA, D. R. D.; CADAVID, V. G. Conforto térmico em galpão cunícula em dias com e sem precipitação. **Revista Brasileira de Cunicultura**, [S. l.], v. 17, n.1, 2020.

FERREIRA, I. O.; SANTOS, G. R.; RODRIGUES, D. D. Estudo sobre a utilização adequada da krigagem na representação computacional de superfícies batimétricas. **Revista Brasileira de Cartografia**, Rio de Janeiro, n. 65, p. 831-842, 2013.

FLIR. Manual do Sensor FLIR. Disponível em: <https://www.flir.com.br/support/products/duo/#Documents>>. Acesso em 10/06/2021.

ISAAKS, E.H.; SRIVASTAVA, R.M. **An Introduction to Applied Geostatistics**; Oxford University Press: New York, NY, USA, 1989; p. 561.

MENDES, A.; DOS SANTOS, G. R.; EMILIANO, P. C.; KALEITA, A. L.; DE PAULA FERREIRA; M. Estimação do tamanho amostral na geoestatística usando um modelo de variograma gaussiano na presença de outliers. **Energia na Agricultura**; [S. l.], v. 34, n.3, p.429-440, 2019.

OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **Catena**, [S. l.], v.113, p.56-69, 2014.

PACHECO, F.; LAZZARINI, L. E.; ALVARENGA, I. Metabolismo relacionado com a fisiologia dos estômatos. **Enciclopédia Biosfera**, [S. l.], v. 18, n. 36, 2021.

PELOSO, A. D. F.; TATAGIBA, S. D.; REIS, E. F. D.; PEZZOPANE, J. E. M.; AMARAL, J. F. T. D. Limitações fotossintéticas em folhas de cafeeiro arábica promovidas pelo déficit hídrico. **Coffee Science**, Lavras, [S. l.], v. 12, n. 3, p. 389 - 399, jul./set. 2017.

R DEVELOPMENT CORE TEAM. R: A language and environment for statistical computing. RIBEIRO JR., P.J.; DIGGLE, P.J. (2001) geoR: A package for geostatistical analysis. **RNEWS**, v 1, n 2, ISSN 1609-3631.

RIBEIRO JUNIOR, P.J.; DIGGLE, P.J. GeoR: A package for geostatistical analysis. **R-News**, [S. l.], v.1, p.14-18, 2001.

SANTOS, L.M; FERRAZ, G.A.S.; BATISTA, M. L.; MARTINS, F. B.; BARBOSA, B. D. Characterization of noise emitted by a low-profile tractor and its influence on the health of agricultural workers. **Anais da Academia Brasileira de Ciências**, [S. l.], v. 92, n. 3, p.1-10, 2020.

SILVA, M. A. J. G.; FERRAZ, P. F. P.; SANTOS, L. M. D.; ROSSI, G.; BARBARI, M. Effect of the Spatial Distribution of the Temperature and Humidity Index in a New Zealand White Rabbit House on Respiratory Frequency and Ear Surface Temperature. **Animals**, [S. l.], 11(6), 1657, 2021.

STEPPUHHN, H. Pre-irrigation of a severely-saline soil with in-situ water to establish dryland forages. **Transactions of the ASAE**, St. Joseph, v. 44, n. 6, p. 1543-1551, 2001.

STOJCSICS, D.; LOVAS, I.; DOMOZI, Z.; MOLNAR, A. High Resolution 3D Thermal Imaging Using FLIR DUO R Sensor. IEEE 22nd International Conference on Intelligent Engineering Systems (INES). p. 000311-000316, 2018. doi:10.1109/ines.2018.8523914

VIANA, L. A.; ZAMBOLIM, L.; SOUSA, T. V.; TOMAZ, D. C. Potencial uso de câmera termal acoplada a vant para monitoramento de culturas/ Potential use of thermal camera coupled in uav for culture monitoring. **Revista Brasileira de Engenharia de Biosistemas**, [S. l.], v.12, n.3, p.286-298, 2018.

VIEIRA, S. R. J. L.; HATFIELD, J.; NIELSEN, D.; BIGGAR, J. Geostatistical theory and application to variability of some agronomical properties. **Hilgardia**, Oakland, v. 51, n. 1, p. 1-75,1983.

VOLTOLINI, G. B.; GUIMARÃES, R. J.; CASTANHEIRA, D. T.; DA SILVA, L. C.; RESENDE, L. S.; DE OLIVEIRA ALECRIM, A.; REGINA, S. D. S. P. Características químicas e físicas do solo e morfologia de cafeeiros em função de diferentes técnicas agronômicas. X Simpósio de Pesquisa dos Cafés do Brasil. 2019.

CONSIDERAÇÕES GERAIS

Para o primeiro artigo, obteve-se uma relação inversamente proporcional entre a produtividade com os dados de desfolha obtido pela RPA do ano subsequente. Recomenda-se realizar análises de desfolha quantificada pela RPA em um período consecutivo de quatro anos, a fim de obter dados relevantes e repetidos em um ciclo bienal do cafeeiro. Sugere-se testar a metodologia de quantificação de desfolha obtida pela RPA em terrenos diferentes, desenvolver plugins que automatizem e padronizem este processamento e tecnologias que permitam obter estas informações em tempo real.

No segundo artigo, foi possível aplicar a metodologia da inversão da clorofila somente no período chuvoso, para o período seco, discorre-se à necessidade de estudos para avaliar estas relações entre a Chl e IVs. Além disso, preconiza-se aplicar esta metodologia em diferentes cultivares, diferentes níveis de deficiência hídrica além de avaliar outros IVs que possam surtir resultados melhores. Ademais, são válidos trabalhos que estudem a correlação das bandas do visível com valores de Chl, podendo abrir leques para utilizar RPA de baixo na obtenção e estimativas desses parâmetros.

E por fim, no terceiro artigo, os resultados foram condizentes com a literatura e com potencial de auxiliar o produtor nos manejos de irrigação na cultura por meio de dados fisiológicos sobrepostos em mapas de temperatura. Como trabalhos futuros, recomenda-se pesquisas adicionais utilizando câmeras termais com melhor resolução espacial, além de estudos destes parâmetros utilizando câmeras hiperespectrais, multiespectrais e câmeras convencionais de baixo custo, visto que as pesquisas estão avançando e tais parâmetros podem ser estimados com boa eficiência.