



**STHÉFANY AIRANE DOS SANTOS**

**AVALIAÇÃO DAS CONDIÇÕES HÍDRICAS EM LAVOURA  
CAFEEIRA POR MEIO DE GEOESTATÍSTICA E  
AERONAVE REMOTAMENTE PILOTADA**

**LAVRAS-MG  
2021**

**STHÉFANY AIRANE DOS SANTOS**

**AVALIAÇÃO DAS CONDIÇÕES HÍDRICAS EM LAVOURA CAFEEIRA POR  
MEIO DE GEOESTATÍSTICA E AERONAVE REMOTAMENTE PILOTADA**

Dissertação apresentada 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 Mestre.

Prof. Dr. Gabriel Araújo e Silva Ferraz  
Orientador  
Dra. Vanessa Castro Figueiredo  
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, Sthéfany Airane dos.

Avaliação das condições hídricas em lavoura cafeeira por meio  
de geoestatística e aeronave remotamente pilotada / Sthéfany  
Airane dos Santos. - 2021.

74 p. : il.

Orientador(a): Gabriel Araújo e Silva Ferraz.

Coorientador(a): Vanessa Castro Figueiredo.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2021.

Bibliografia.

1. Agricultura de Precisão. 2. Cafeeiro. 3. Estresse Hídrico. I.  
Ferraz, Gabriel Araújo e Silva. II. Figueiredo, Vanessa Castro. III.  
Título.

**STHÉFANY AIRANE DOS SANTOS**

**AVALIAÇÃO DAS CONDIÇÕES HÍDRICAS EM LAVOURA CAFEEIRA POR  
MEIO DE GEOESTATÍSTICA E AERONAVE REMOTAMENTE PILOTADA**

**EVALUATION OF WATER CONDITIONS IN COFFEE LAVING THROUGH  
GEOSTATISTICS AND REMOTELY PILOTED AIRCRAFT**

Dissertação apresentada 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 Mestre.

APROVADA em 31 de março de 2021.  
Dr. Murilo Machado de Barros, UFRRJ  
Dr. Marley Lamounier Machado, EPAMIG  
Dra. Vanessa Castro Figueiredo, EPAMIG

Prof. Dr. Gabriel Araújo e Silva Ferraz  
Orientador

Dra. Vanessa de Castro Figueiredo  
Coorientadora

**LAVRAS-MG  
2021**

*À Deus, por toda sabedoria para vencer os obstáculos e desafios até aqui, pela saúde, nosso  
bem mais precioso e pelo amor incondicional.*

*À minha família, por todo amor e carinho, não medindo esforços para que eu alcançasse  
meus maiores sonhos*

*Ao meu noivo, por ser um alicerce, de amor e apoio, por nunca deixar eu desistir.*

*Dedico*

## AGRADECIMENTOS

À Universidade Federal de Lavras, em especial ao Departamento de Engenharia e ao Programa de Pós Graduação em Engenharia Agrícola, pelo acolhimento, ensinamentos e a oportunidade.

À instituição de fomento, CNPQ, pela concessão da bolsa de estudos.

Ao professor Gabriel Araújo e Silva Ferraz, pela orientação, disponibilidade em ajudar, ensinamentos e todo conhecimento compartilhado ao longo de todos esses anos.

À pesquisadora Dra. Vanessa de Castro Figueiredo, pela coorientação, ensinamentos e amizade.

À EPAMIG, pela parceria no projeto de pesquisa, por todo apoio e suporte.

Aos Drs. Margarete Volpato e Marley Lamounier, por todo ensinamento, paciência e disposição em ajudar em todas as etapas dessa pesquisa.

Aos envolvidos da EPAMIG, Alessandro, Pepe, Dula, Vânia, Stefanya, Vinícius, Juliano e todos que de alguma forma ajudaram direta ou indiretamente nesta pesquisa.

Aos membros do NESA, Nicole, Rafael, Luana, Lucas, Brenon, Diego, Letícia, Pedro e Sabrina, que ao longo desse tempo ajudaram na construção desse projeto.

À secretária da pós graduação Helem, pela disponibilidade e atenção de sempre.

Aos membros da banca, professor Murilo Machado, Vanessa Figueiredo e Marley Lamounier, pela disponibilidade e atenção.

À todas as pessoas que ajudaram de alguma forma, para a elaboração deste trabalho.

Muito Obrigada!

## RESUMO

As Aeronaves Remotamente Pilotadas (ARP's) vem se tornando uma tecnologia importante para a Agricultura de Precisão (AP), na última década elas permitiram a aquisição de imagens por sensores remotos, com alta resolução espacial e temporal, além de fornecer diferentes informações. Sendo assim, o objetivo deste trabalho foi avaliar as condições hídricas de uma lavoura cafeeira por meio da geoestatística e do uso de imagens de alta resolução para o cálculo de índices de vegetação. Este estudo foi conduzido em uma área de 1,2 ha, sob o cultivo de cafeeiros da espécie *Coffea arabica L.*, cultivar Topázio MG 1190. A área de estudo e os 30 pontos de amostragem, foram georreferenciados por meio de um GNSS RTK. A coleta de dados foi realizada em duas épocas, período seco (agosto de 2020) e período chuvoso (janeiro de 2021). Foram obtidas imagens de alta resolução utilizando uma ARP equipada com sensor multiespectral, para bandas Red, Nir, Green e Red Edge. O plano de voo foi elaborado no software eMotion e as imagens obtidas foram processadas pelo software Pix4D, o qual criou-se uma nuvem de pontos, um modelo digital de superfície e um ortomosaico das imagens. Coletou-se 30 amostras de solo indeformadas, na profundidade de 0-10 cm e 30 amostras na profundidade de 10-20 cm, que posteriormente passaram pelo processo de secagem em estufa à 105°C por 24 horas para estabelecer a densidade de solo, umidade gravimétrica e umidade volumétrica. Foram coletadas folhas às 04:30 da manhã em plantas georreferenciadas, onde foi determinado o potencial hídrico pelo uso de uma Bomba de Scholander. A espacialização e a interpolação de dados da umidade do solo e do potencial hídrico das folhas foi realizado por análise geoestatística, com ajuste de semivariogramas e criação de mapas por krigagem ordinária. Por meio das imagens obtidas pela ARP, foram calculados índices de vegetação. A partir da análise de correlação e regressão linear, verificou-se a relação dos atributos obtidos em campo e os índices de vegetação. O grau de dependência espacial obtido pelos dados de geoestatística apresentou forte dependência espacial para todos os atributos avaliados e para ambos os anos de coleta. Os índices de vegetação apresentaram uma diferença significativa quando comparados os períodos seco e chuvoso. Para a análise de correlação entre os dados de campo e os índices de vegetação, o maior valor de foi entre a banda espectral GREEN e a umidade volumétrica coletada na profundidade de 0-10 cm para ano de 2020 (51,57%). O potencial hídrico das folhas de 2021, correlacionou significativamente com uma banda espectral e seis índices de vegetação, já a regressão linear que obteve o melhor ajuste foi para o atributo potencial hídrico de 2021 com o índice NDRE. Estes resultados mostram a eficiência das ferramentas geoestatística e ARP, para avaliação das condições hídricas, e que por meio de estudos ainda mais aprofundados, podem se tornar grandes aliadas à cafeicultura.

**Palavras-chave:** Agricultura de Precisão, Cafeeiro, Estresse Hídrico

## ABSTRACT

The Remotely Piloted Aircraft (RPA's) has become an important technology for Precision Agriculture (PA), in the last decade they allowed the acquisition of images by remote sensors, with high spatial and temporal resolution, in addition to providing different information. Therefore, the objective of this work was to evaluate the water conditions of a coffee plantation through geostatistics and the use of high-resolution images for the calculation of vegetation indices. This study was conducted in an area of 1.2 ha, under the cultivation of coffee trees of the species *Coffea arabica* L., cultivar Topázio MG 1190. The study area and the 30 sampling points were georeferenced using a GNSS RTK. Data collection was carried out in two seasons, dry period (August 2020) and rainy period (January 2021). High resolution images were obtained using an RPA equipped with a multispectral sensor, for the Red, Nir, Green and Red Edge bands. The flight plan was elaborated in the eMotion software and the images obtained were processed by the Pix4D software, which created a point cloud, a digital surface model and an orthomosaic of the images. 30 undisturbed soil samples were collected, at a depth of 0-10 cm and 30 samples at a depth of 10-20 cm, which later went through the drying process in an oven at 105°C for 24 hours to establish the soil density, gravimetric moisture and volumetric humidity. Leaves were collected at 4:30 am in georeferenced plants, where water potential was determined by using a Scholander Pump. The spatialization and interpolation of data on soil moisture and leaf water potential was carried out by geostatistical analysis, with adjustment of semivariograms and creation of maps by ordinary kriging. Through the images obtained by the ARP, vegetation indices were calculated. From the correlation analysis and linear regression, it was verified the relation of the attributes obtained in the field and the vegetation indexes. The degree of spatial dependence obtained by the geostatistics data showed a strong spatial dependence for all evaluated attributes and for both years of collection. The vegetation indices showed a significant difference when comparing the dry and rainy periods. For the analysis of correlation between field data and vegetation indices, the highest value was between the GREEN spectral band and the volumetric humidity collected at a depth of 0-10 cm for the year 2020 (51.57%). The water potential of the leaves of 2021, correlated significantly with a spectral band and six vegetation indexes, whereas the linear regression that obtained the best fit was for the water potential attribute of 2021 with the NDRE index. These results show the efficiency of geostatistical tools and RPA, for the evaluation of water conditions, and that through even more in-depth studies, they can become great allies to coffee growing.

**Keywords:** Precision Agriculture, Coffee, Hydric Stress



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>10</b>
<b>2</b>	<b>OBJETIVOS</b> .....	<b>11</b>
2.1	Objetivos específicos .....	11
<b>3</b>	<b>REFERENCIAL TEÓRICO</b> .....	<b>12</b>
3.1	Cafeicultura no Brasil e cafeicultura de precisão .....	12
3.2	Geoestatística aplicada à agricultura de precisão .....	12
3.3	Atributos relacionados as condições hídricas da planta em lavoura cafeeira .....	15
3.3.1	Umidade do Solo e Potencial Hídrico das Folhas .....	15
3.4	Sensoriamento Remoto na Cafeicultura .....	16
3.5	Aeronaves Remotamente Pilotadas na Agricultura .....	18
3.6	Índices de Vegetação .....	20
<b>4</b>	<b>METODOLOGIA</b> .....	<b>22</b>
4.1	Descrição da área experimental .....	22
4.2	Grade de amostragem .....	23
4.3	Umidade do solo .....	25
4.4	Potencial hídrico das folhas .....	26
4.5	Espacialização das variáveis em estudo .....	27
4.6	Aquisição e processamento das imagens da aeronave remotamente pilotada .....	29
4.6.1	Características da Aeronave e da Câmera Multiespectral .....	29
4.6.2	Planejamento de Voo .....	30
4.6.3	Processamento das Imagens .....	31
4.7	Cálculo dos índices de vegetação .....	31
4.8	Correlação e Regressão Linear dos dados .....	33
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	<b>34</b>
5.1	Estatística Descritiva .....	34
5.2	Análise geoestatística .....	37
5.3	Índices de Vegetação .....	43
5.4	Análise de Correlação e Regressão Linear .....	54
<b>6</b>	<b>CONCLUSÃO</b> .....	<b>58</b>
	<b>REFERÊNCIAS</b> .....	<b>60</b>

## 1 INTRODUÇÃO

A cafeicultura no Brasil é um ramo importante do agronegócio, pois é uma das culturas que mais movimentam a economia do país. A primeira estimativa da safra de café para o ano de 2021 é de 43,85 a 49,58 milhões de sacas beneficiadas (CONAB, 2021).

A produtividade do cafeeiro é fortemente influenciada pelo suprimento de água. O conhecimento do status hídrico do cafeeiro é essencial ao entendimento do potencial produtivo das cultivares. Sendo o café, um produto tão valioso para a economia brasileira, o estudo do status hídrico da lavoura é de grande importância, uma vez que pequenas reduções na disponibilidade da água podem diminuir substancialmente seu desenvolvimento (SILVA, et al. 2008).

As variáveis relacionadas as condições hídricas em uma lavoura cafeeira podem apresentar uma alta heterogeneidade, a qual exige que o produtor tome decisões diferentes para uma mesma área quanto ao seu manejo. Conhecer a variabilidade espacial e temporal destes atributos, é de suma importância na quantificação das necessidades hídricas dos cafeeiros.

A AP é um conjunto de ferramentas e tecnologias aplicadas, para permitir um sistema de gerenciamento agrícola baseado na variabilidade espacial e temporal da unidade produtiva, visando o aumento de retorno econômico e à redução do impacto ao ambiente (BRASIL, 2013).

A utilização de técnicas de AP na cafeicultura (Cafeicultura de Precisão) já vem sendo adotada no Brasil, porém se encontra em um estágio inicial de desenvolvimento. Ao adotar a Cafeicultura de Precisão, o produtor almeja maximizar os resultados econômicos através do manejo adequado, e, conseqüentemente aumentar a produtividade através da correção da variabilidade espacial dos atributos do solo e da planta.

Um dos problemas-chave da AP é a necessidade de uma grade de amostragem densa, a fim de se detectar a variabilidade espacial do atributo em estudo e possibilitar a geração de mapas que representem, de maneira real, tal área. Uma contribuição para AP é o uso de sensores empregados no Sensoriamento Remoto (SR), que possibilitem avaliar a variabilidade espacial do solo e conseqüentemente reduzir as amostragens intensivas e caras.

Segundo Moriya (2015), os produtos utilizados no SR têm um potencial grande nas aplicações da AP, promovendo o desenvolvimento de novas abordagens metodológicas e aplicações que produzam informações espaciais de boa qualidade para auxiliar o produtor rural nas decisões em relação ao manejo das culturas.

Uma das vantagens do Sensoriamento Remoto é a possibilidade de extração de informações das culturas em áreas extensas com rapidez e de forma menos onerosa, ou seja, com o mínimo de dados

coletados no campo, além da sua alta resolução temporal. As ARP's têm se tornado uma ótima solução para aplicações com SR devido a sua capacidade de voos cada vez mais estáveis, equipados com câmeras de alta resolução e soluções em software para captura de imagem e facilidade em automatização de suas rotinas.

A variabilidade espacial da umidade do solo e potencial hídrico das folhas pode ser avaliadas por meio de técnicas de geoestatística, porém esta ferramenta requer um grande volume de dados para a melhor espacialização desta variabilidade.

O SR aplicado à AP, vem sendo muito utilizado como uma ferramenta para avaliar a variabilidade de atributos relacionados aos solos e as plantas. Uma alternativa para SR orbital é o uso de ARP's, por apresentar benefícios como: baixo custo, obter imagens de altíssima resolução espacial e temporal e apresentar uma flexibilidade de coleta de dados. Com o surgimento de sensores multiespectrais que podem ser acoplados à essas aeronaves, o uso dos mais diversos índices de vegetação tem se mostrado promissor para o agricultor, para avaliar diversos aspectos das culturas, desde características físicas, pragas e doenças e monitoramento da saúde da lavoura.

Sendo assim, a utilização de imagens aéreas de alta resolução, aplicadas aos índices de vegetação, podem ser uma ferramenta eficiente, para o estudo da variabilidade espacial de atributos relacionados as condições hídricas em uma lavoura cafeeira, através da avaliação das correlações entre os índices de vegetação e esses atributos.

## **2 OBJETIVOS**

Avaliar as condições hídricas em um lavoura cafeeira através do estudo da variabilidade espacial dos atributos umidade do solo e potencial hídrico das folhas e também por meio de análise de correlação entre os atributos de campo e índices de vegetação calculados a partir de imagens de alta resolução obtidas por uma Aeronave Remotamente Pilotada equipada com sensor multiespectral.

### **2.1 Objetivos específicos**

**2.1** Determinar padrões da informação espectral como indicadores das condições hídricas dos cafeeiros;

**2.2** Propor tecnologia de monitoramento das condições hídricas de cafeeiros utilizando ARP;

**2.3** Avaliar índices de vegetação que correlacionam com o estresse hídrico em lavouras de café.

### **3 REFERENCIAL TEÓRICO**

#### **3.1 Cafeicultura no Brasil e cafeicultura de precisão**

Entre as regiões produtoras de café do País, destaca-se a região Sudeste, especialmente o Estado de Minas Gerais, que é o maior produtor nacional do grão, onde a estimativa da primeira safra para 2021 será de 19,80 a 22,13 milhões sacas de café beneficiadas, podendo ocorrer uma redução de 42,8% do volume total, o que pode estar relacionado ao ciclo de bienalidade negativa (CONAB, 2021).

Apesar de o Brasil apresentar maior produção e exportação mundial de café, a produtividade pode ser afetada por diversos fatores como estresses abióticos e bióticos, deficiências nutricionais, manejo inadequado e também baixa tecnologia de produção.

Os principais fatores abióticos limitadores de produção do cafeeiro são a seca e os extremos de temperatura (GOMES, 2013). Sendo assim a obtenção de informações voltadas para o manejo racional e adequado para a umidade do solo na lavoura cafeeira torna-se imprescindível, se considerar a atividade cafeeira com grande importância socioeconômica no país.

O uso da agricultura de precisão pode ser uma alternativa para o produtor de café. Tal tecnologia foi definida por Bernardi et al. (2015) que afirma ser uma prática agrícola baseada em tecnologias de informações que buscam o tratamento da variabilidade espacial da lavoura. A AP pode trazer inúmeros benefícios à cultura do café, pois esta apresenta elevada receita por área cujo preço se baseia na qualidade dos grãos.

Ferraz et al. (2012) definem a cafeicultura de precisão como conjunto de técnicas e tecnologias que tem por objetivo auxiliar o manejo de lavouras cafeeiras, baseando-se na variabilidade espacial dos atributos do solo e da planta, buscando maximizar a rentabilidade, aumentar eficiência da adubação, pulverização e colheita, resultando na elevação da produtividade e qualidade final do produto.

A geoestatística apresenta-se como uma ferramenta utilizada na Agricultura de Precisão para analisar os fatores envolvidos nos sistemas produtivos. Por meio dela, é possível identificar se há ou não dependência espacial para os fatores analisados, possibilitando a criação de mapas temáticos que auxiliam na tomada de decisões (CARVALHO et al., 2013).

#### **3.2 Geoestatística aplicada à agricultura de precisão**

Marasca et al. (2017) afirmam que a geoestatística é uma ciência consagrada e integrante da estatística aplicada trata de problemas referentes às variáveis regionalizadas as quais têm um

comportamento espacial mostrando características intermediárias entre as variáveis verdadeiramente aleatórias e as totalmente determinísticas.

Quando uma determinada propriedade varia de um local para outro com algum grau de organização ou continuidade, através da dependência espacial, a estatística clássica deve ser substituída pela geoestatística (VIEIRA, 2000).

O conhecimento da distribuição espacial dos atributos do solo em uma determinada área é uma prática importante para o refinamento do manejo e avaliação dos efeitos da agricultura, sobre a qualidade ambiental (CAMBARDELLA et al., 1994). Também tem importância na definição da intensidade de amostragem do solo para sua caracterização, possibilitando, dessa maneira, reduzir o erro-padrão da média, maximizando a eficiência da amostragem, e reduzir os custos e a mão de obra (WEBSTER; OLIVER, 2001).

Uma preocupação de pesquisadores desde o início do século XX é a variabilidade espacial do solo, por proporcionar diferenças no desenvolvimento e na produtividade das culturas, alterando resultados de pesquisas, mesmo quando o solo foi considerado como homogêneo em parcelas experimentais (COELHO FILHO et al., 2001). Uma solução seria o conhecimento prévio da estrutura espacial das variáveis do solo.

Segundo Mantovani et al. (2006) afirmam que as características do solo e de cultivo variam no espaço (distância e profundidade) e no tempo. Já Inamasu (2014) diz que o impacto mais significativo da AP é a forma como as decisões de gestão da variabilidade espacial e temporal são tomadas no sistema de produção.

A aplicação do objetivo da geoestatística na agricultura de precisão tem por objetivo caracterizar a variabilidade espacial dos atributos do solo e das culturas e estimar as inter-relações desses atributos tanto no espaço quanto no tempo (BERNARDI et al., 2015).

As perdas causadas por manejo inapropriado que ocasionam baixa produtividade pode ser revertidas com o uso da geoestatística (FLOWERS et al., 2005). Na agricultura, a aplicação da análise geoestatística tem sido útil na caracterização e mapeamento da variação espacial de atributos de culturas (MANZIONE et al., 2001).

Na cultura do cafeeiro, o conhecimento da variabilidade espacial dos atributos, é de suma importância para a determinação de estratégias para atender as necessidades da cultura e conseqüentemente alcançar maior produtividade (SILVA et al., 2010).

De acordo com Vieira (1997) o autor explica que quando ocorre a variabilidade espacial para atributos dos solos, a amostragem simples e ao acaso não consegue detectá-la, assim escondendo a realidade do comportamento da variável.

O conceito central da geoestatística, segundo Vieira (2003), remete à determinação da magnitude da variabilidade espacial expressa por um semivariograma, o qual descreve a estrutura da continuidade espacial da variável. A sensibilidade dos semivariogramas para detectar a variabilidade espacial está diretamente ligada ao melhor ajuste dos dados experimentais e ao modelo teórico de semivariograma (ODA, 2005), condição essencial para a realização de inferências em locais não amostrados e para a correta interpretação de fenômenos que apresentam dependência espacial.

Segundo Ávila et al. (2010) a análise da dependência espacial, também denominada análise estrutural ou modelagem da continuidade espacial, é considerada etapa fundamental na utilização de procedimentos geoestatísticos, pois a eficiência do estimador (krigagem) na geração de mapas não enviesados (sem tendência) depende essencialmente desta análise.

Para o desenvolvimento de uma cafeicultura sustentável, alguns atributos do solo são importantes, pois podem atuar como indicadores de qualidade do solo. Dentre esses indicadores, encontram-se a densidade, a porosidade total, a macro porosidade, a micro porosidade, a resistência à penetração e a umidade do solo (EFFGEN et al., 2012).

O movimento da água no solo é muito heterogêneo e depende da ação de diversos fatores relacionados ao clima, solo, topografia e vegetação, resultando em uma alta variabilidade espacial e temporal (ÁVILA; MELLO; SILVA, 2010; ZUCCO et al., 2014).

Na literatura, diversas pesquisas já foram realizadas aplicando a AP na cafeicultura com a finalidade de se estudar a variabilidade espacial de atributos físicos do solo como: frações granulométricas (BURAK et al., 2016; CARVALHO et al., 2013; LIMA et al., 2012; SILVA; LIMA, 2013), densidade do solo (BURAK et al., 2016; CARVALHO et al., 2013; KAMIMURA et al., 2013; MOTA JÚNIOR et al., 2017; SANTOS et al., 2017; SILVA; LIMA, 2013), resistência do solo a penetração (ANDRADE et al., 2018; CARVALHO et al., 2013; KAMIMURA et al., 2013; MOTA JÚNIOR et al., 2017), densidade de partículas (KAMIMURA et al., 2013; SANTOS et al., 2017), porosidade total (BURAK et al., 2016; KAMIMURA et al., 2013; MOTA JR et al., 2017; SANTOS et al., 2017), macro porosidade e micro porosidade (BURAK et al., 2016; KAMIMURA et al., 2013; MOTA JÚNIOR et al., 2017; SANTOS et al., 2017).

A variabilidade espacial da umidade do solo e do potencial hídrico das folhas, podem ter uma melhor avaliação através da geoestatística. Além de considerar cada ponto amostral da área como um valor, ela associa a posição geográfica em que o ponto se encontra, possibilitando que variáveis amostradas mais próximas tenham valores mais semelhantes e sejam mais bem correlacionadas entre si do que amostras distantes do ponto (CANCIAN, 2015).

Existem poucos estudos que avaliam a variabilidade espacial de atributos relacionados as condições hídricas em lavouras cafeeiras. Algumas pesquisas relacionadas a variabilidade espacial

desses atributos físicos são encontradas, porém, são necessários mais estudos que avaliem a dependência espacial da umidade do solo e do potencial hídrico das folhas, principalmente em lavouras de café situadas no sul de Minas Gerais, uma das regiões com maior potencial produtivo dessa cultura.

### **3.3 Atributos relacionados as condições hídricas da planta em lavoura cafeeira**

A produção de café arábica, vem sendo afetada pelas condições climáticas, principalmente devido à ocorrência de períodos cada vez mais prolongados de seca e como consequência do fenômeno do aquecimento global (DaMATTA et al., 2010). Dentre todos os fatores abióticos, o déficit hídrico é o principal fator do ambiente que limita o crescimento e a produtividade das culturas agrícolas (CHAVES; FLEXAS; PINHEIRO, 2009). Na cultura do café, por exemplo, em períodos de muita seca, a produtividade pode ser reduzida em até 80%, caso não seja adotada a irrigação (DaMATTA; RAMALHO, 2006).

O déficit hídrico (DH) é um dos fatores ambientais mais limitantes para o desenvolvimento, e consequentemente, o rendimento das culturas. O conceito de estresse está intimamente relacionado ao de tolerância ao estresse, que é a aptidão da planta para enfrentar um ambiente desfavorável. O déficit hídrico também pode ser definido como todo o conteúdo de água de um tecido ou célula que está abaixo do conteúdo de água mais alto exibido no estado de maior hidratação (TAIZ; ZEIGER, 2004).

Dentre os vários atributos relacionados ao solo e a planta, e que estão ligados diretamente as condições hídricas de uma lavoura, podemos citar a umidade do solo e o potencial hídrico das folhas.

#### **3.3.1 Umidade do Solo e Potencial Hídrico das Folhas**

A umidade do solo é uma variável responsável pelo controle da troca de água e de energia entre a superfície terrestre e a atmosfera. Do ponto de vista hidrológico e ecológico, ela condiciona os processos de escoamento superficial, infiltração, armazenamento, drenagem e transpiração das plantas (ZHANG; SHAO, 2013).

O potencial hídrico das folhas é um dos fatores mais importantes que afetam o funcionamento dos estômatos. Ele indica o seu estado energético, cujos gradientes explicam os fluxos da água no sistema solo-planta-atmosfera (BERGONCI et al., 2000) de modo que, quaisquer variações no potencial hídrico das folhas podem afetar a assimilação do carbono da planta (HSIAO, 1973). Isto porque, caso a planta perde água a uma taxa superior à sua capacidade de absorção e transporte o potencial hídrico das folhas diminui, levando ao fechamento dos estômatos e redução da fotossíntese (COSTA; MARENCO, 2007).

Uma resposta marcante de plantas submetidas à deficiência hídrica é a redução das taxas transpiratórias. Este processo envolve o fechamento estomático, com consequente redução da condutância estomática (gs), que contribui para o aumento ou para a manutenção do potencial hídrico dentro de limites que permitam a manutenção do crescimento vegetal (CAVATTE et al., 2012).

Alguns autores como Barros et al. (1997); Batista et al. (2010); Silva et al. (2009); Silva et al. (2010, 2015) e Silva et al. (2019), avaliaram o potencial hídrico de cafeeiros. Porém nenhuma pesquisa sobre a variabilidade espacial do potencial hídrico das folhas em conjunto com a agricultura de precisão foi encontrada.

Diversos trabalhos foram conduzidos sobre a variabilidade espacial da umidade do solo em áreas agrícolas como: cana de açúcar (CAMPOS et al., 2013; SOUZA et al., 2004), soja (SANTOS et al., 2012; SILVA et al., 2009), milho (SAMPAIO et al., 2010), mandioca (CAMPOS et al., 2012), bananeiras (RODRIGUES et al., 2017), mamona (SIQUEIRA et al., 2008), cenoura (SOUZA et al. 2008) e palma forrageira ( CARVALHO et al., 2017). Porém, existem poucos estudos que demonstrem essa análise em áreas de cultivo de café. Burak et al. (2016), Carvalho et al. (2013) e Mota Júnior et al. (2017) avaliaram a variabilidade espacial da umidade do solo em lavouras cafeeiras.

Para que haja a conservação das condições hídricas adequadas dentro de uma lavoura, a sua mensuração deve ser realizada nos pontos que melhor representam a distribuição no tempo e no espaço (MEHL et al., 2010). A prática da agricultura de precisão apresenta diversas etapas, como a identificação da variabilidade em campo, geração de mapas, zoneamento da área, manejo por sítio específico e tomada de decisão. O sensoriamento remoto pode estar envolvido como o principal procedimento para a obtenção das informações em campo.

O conjunto de geoprocessamento, ou geotecnologias, que incluem as tecnologias para coleta, processamento, análise e disponibilização de informação com referência geográfica, tem grande potencial para gestão da produção agrícola e pecuária (BATISTELLA et al., 2011; FILIPPINI ALBA, 2014). A modelagem via sistema de informações geográficas (SIG) possibilita a fusão dessas camadas de informações, ampliando a capacidade de interpretação dos dados e auxiliando na tomada de decisão para a gestão do sistema de produção (FILIPPINI ALBA, 2014).

### **3.4 Sensoriamento Remoto na Cafeicultura**

Segundo Jensen (1949) uma forma simples e de fácil compreensão sobre a definição de Sensoriamento Remoto é, uma forma de aquisição de dados sobre um objeto sem tocá-lo diretamente.

Considerando as aplicações de Sensoriamento Remoto no levantamento de dados sobre a cafeicultura, os primeiros trabalhos realizados foram por Velloso (1974, 1976) e Velloso e Souza (1978).



Estes trabalhos não apresentaram bons resultados, devido à baixa resolução espacial do sensor utilizado (MSS/Landsat) e à heterogeneidade da cultura cafeeira.

A partir dos lançamentos dos satélites Landsat 5 (Thematic Mapper) e Landsat 7 (Enhancement Thematic Mapper Plus) de média resolução espacial, diversos trabalhos de mapeamento da cafeicultura foram desenvolvidos com imagens desses satélites (CORDERO-SANCHO; SADER 2007; MACHADO et al. (2001,2010); MARTÍNEZ-VERDUZCO et al., 2012; MOREIRA et al. (2008, 2010); SARMIENTO et al., 2014; TRABAQUINI et al., 2011).

Nos trabalhos de Cordero-Sancho e Sader, (2007); Machado et al. (2001); Martínez-Verduzco et al. (2012) e Sarmiento et al. (2014), apresentaram bons resultados, porém houve confusão entre as classes de café e áreas florestais devido essas espécies apresentarem quase a mesma resposta espectral. Outro problema identificado no trabalho de Machado et al. (2010) é a presença de nuvens encontradas em boa parte das imagens de satélite, o que dificulta o processo de discriminação das coberturas.

As imagens da nova geração de satélites de alta resolução como Quickbird, Ikonos, RapidEye, Geoeye-1, tem se mostrado promissoras na identificação e caracterização de áreas cafeeiras como apresentado nos trabalhos de Coltri et al. (2011); Moreira et al. (2010); Ramirez e Zullo Júnior (2010) e Souza et al. (2011), pois além de possibilitarem um conhecimento mais detalhado do comportamento espectral de plantios de café, auxiliam na identificação de pequenas lavouras com diferentes características (MOREIRA et al., 2010). Trabalhos de Bausch, Halvorson e Cipra (2008); Coltri et al. (2011); Marujo et al. (2013) e Souza et al. (2011) ressaltam a importância de novas pesquisas na classificação das imagens de alta resolução.

Informações espectrais são fundamentais para obter uma acurácia mais elevada na identificação de respostas da vegetação. Melhorias no processo se fazem necessárias, pois, apesar de bons resultados, ainda são encontradas confusões nas classificações de alvos (SOUZA et al., 2016).

Os dados adquiridos por sensores orbitais ou em plataformas aéreas está passando por uma transição com o surgimento e desenvolvimento de sensores de alta resolução (BENEDIKTSSON; CHANUSSOT; MOON, 2012).

Uma alternativa para os sensores multiespectrais orbitais é o uso de Aeronaves Remotamente Pilotadas (ARP's). Este equipamento no setor agrícola, surgiu como importante ferramenta da Agricultura de Precisão na missão de reconhecimento da exploração agropecuária por meio de tomadas de imagens (VIANA et al. 2018).

A tecnologia de sensoriamento remoto através de imagens obtidas por ARP's e processadas em softwares ainda é bastante recente na agricultura e demanda mais estudos específicos e aprofundados para a geração de dados ainda mais eficientes e confiáveis e de forma rápida para auxiliar na ampliação

da produtividade e rentabilidade das atividades agrícolas (MICHELON et al., 2019). Porém com as recentes regularizações do uso de ARP's no Brasil pela ANAC, sua utilização só tende a crescer.

### 3.5 Aeronaves Remotamente Pilotadas na Agricultura

Uso desta das ARP's está crescendo em ritmo acelerado, devido ao baixo custo de operação em ambiente de monitoramento, sua alta resolução espacial e temporal, e sua alta flexibilidade na aquisição de imagem (PURI et al., 2017; REGER et al., 2018). As ARP's são uma fonte de Sensoriamento Remoto, com elas, é possível gerar imagens em condições de clima nublado, enquanto a geração de imagens por satélite é limitada nessas situações (HUUSKONEN; OKSANEN, 2018).

Avanços na Agricultura de Precisão mostram a crescente utilização de imagens de satélites, bem como a utilização dos chamados Sistemas de Aeronaves Remotamente Pilotadas (SARP), que estão se destacando como uma tecnologia emergente na AP, os quais possibilitam a obtenção de informações bem como a tomada de decisão em tempo real (COLOMINA; MOLINA, 2014).

Segundo a Associação Brasileira de Aeromodelismo (ABA), a definição para Veículo Aéreo Não Tripulado (VANT) é: “um veículo capaz de voar na atmosfera, fora do efeito de solo, que foi projetado ou modificado para não receber um piloto humano e que é operado por controle remoto ou autônomo”. Os veículos aéreos não tripulados também são conhecidos por muitos outros nomes, como: sistema de aeronaves não tripuladas, aeronaves remotamente pilotadas, micro veículo aéreo (BERETTA et al., 2018). Diante de várias terminologias que surgiram para representar estas aeronaves, a ICAO (2016) designou o termo ARP (Aeronave Remotamente Pilotada) do inglês RPA (Remotely Piloted Aircraft) como padrão.

O conceito de ARP foi utilizado pela primeira vez durante um ataque do Exército Austríaco à cidade italiana de Veneza, em 12 de julho de 1849 (HARDGRAVE, 2005), e desde então passou por diversas mudanças, sendo que nos dias atuais, devido aos avanços tecnológicos, tornou-se um equipamento multiuso e de grande valia para a segurança pública, podendo ser empregado em diversas operações militares, auxiliando no controle de distúrbios civis, efetuando o monitoramento de áreas ocupadas e pacificadas e garantindo a defesa de seus operadores (PEZZINI; TORRES, 2018).

Embora as ARP's tenham sido inventadas para fins militares, as pessoas começaram a usá-las posteriormente para fins recreativos. A principal vantagem da tecnologia ARP é a especificidade da abordagem do alvo e a coleta de informações em um nível micro (RANGO et al., 2009; XIANG, 2011) além de oferecer uma visão geral e detalhada do campo.

O desenvolvimento de tecnologias de Aeronaves Remotamente Pilotadas (ARP's) está em constante crescimento nas últimas décadas. Abrangendo áreas tanto civis quanto militares, as ARP's

auxiliam em tarefas já realizadas por outros meios e/ou realizam serviços com maior facilidade ou menor custo (SLONGO et al., 2019).

Afirmações de Herwitz et al. (2004) já relatavam que era provável que as ARP's seriam uma ferramenta de grande interesse e uso na agricultura, onde essa tecnologia ofereceria novas alternativas para essa área dentre outras aplicações, onde se necessita de imagens de alta resolução espacial e entregues em tempo quase real.

As ARP's são utilizadas para imageamento de pequenas áreas com alta taxa de revisita e altíssima resolução espacial (EISENBEISS, 2004; ESPOSITO et al., 2006; NEBIKER et al., 2008). Ainda são necessários estudos sobre segurança para a integração dessa categoria ao espaço aéreo, mas esse parece ser um caminho sem volta, pois muito já se progrediu no uso desses equipamentos (LUCIEER et al., 2012).

Na cafeicultura de precisão algumas tecnologias vêm sendo testadas. Aplicações emergentes como a captura de imagens aéreas por meio de ARP's são cada vez mais frequentes em campos de café.

Os autores Herwitz et al. (2004) conduziram um estudo no Havai em uma plantação de 1500 ha de café. O autor utilizou uma ARP movida a energia solar. As imagens coloridas foram úteis para mapeamento de focos invasivos de ervas daninhas e revelação de anomalias de irrigação e fertilização. Os autores sugerem que as ARP's de longa duração (semanas a meses) em evolução contribuem valiosamente para o monitoramento regional de recursos agrícolas.

Coletando imagens georreferenciadas da cultura do café na safra de 2002 utilizando uma ARP Johnson et al. (2004) compararam os pixels da imagem com os dados de refletância coletados em campo, criando um índice de maturação da cultura.

Oliveira et al. (2018) apresentaram uma técnica de detecção de falhas no cafeeiro, a partir de processamento em imagens RGB obtidas por ARP e operadores morfológicos, com identificação individual e comprimento total das falhas.

Santos et al. (2019) demonstraram o potencial de técnicas para melhorias nos erros geométricos das imagens ARP, com aplicabilidade em lavouras cafeeiras.

Demonstrando um método para estimar o volume da vegetação em lavouras de café, por meio de imagens capturadas por sensores acoplados à ARP, Cunha et al. (2019) não encontraram diferenças significativas com o método tradicional de levantamento.

Propondo um modelo para estimar medidas indiretas de parâmetros de altura e diâmetro de copa de cafeeiros, Gonçalves (2018) realizou análise da porcentagem de cobertura, calculou o índice de área foliar e mapeou o coeficiente de cultura ( $K_c$ ) utilizando dados detectados por ARP.

Santana et al. (2019) avaliaram a qualidade de duas técnicas de plantio em terrenos de alta declividade por meio de controle estatístico de processo (CEP) de dados obtidos remotamente por RPA no município de Bom Sucesso no Sul de Minas Gerais.

Avaliando parâmetros biofísicos e medidas de altura e diâmetro do cafeeiro por doze meses, através de imagens obtidas por meio de sensores acoplados a ARP, Santos et al. (2020) atestam que produtos fotogramétricos apresentam capacidade significativa na estimativa de altura e diâmetro de cafeeiros. Além disso, podem ser usados para análises de atributos biofísicos evitando a necessidade de coleta no solo.

Avaliando cinco lavouras de café de cultivares diferentes em Minas Gerais Martins et al. (2021) objetivaram avaliar um índice para o monitoramento da maturação do café. Para a obtenção de dados os autores utilizaram uma ARP (DJI Matrice 100) equipada com uma câmera multiespectral MicaSense RedEdge MX. Realizou-se quatro voos no ano de 2019 (abril, maio e agosto) para a aquisição de imagens. Dentre os índices calculados, avaliou-se o NDVI, NDRE e GNDVI. As amostras do valor médio de cada índice para cada ponto amostral foram realizadas com a ferramenta de estatística zonal. Como resultados, os autores obtiveram valores de NDVI para amostras de fruto verde variando de 0,014 a 0,823 e de frutos maduros variando de 0,018 a 0,821. Para o NDRE, o índice variou de 0,20 a 0,556 para frutos verdes e de 0,021 a 0,513 para frutos maduros. O índice GNDVI variou de 0,005 a 0,847 para frutos verdes e de 0,006 a 0,841 para frutos maduros.

Na agricultura, as propriedades da reflectância em cada faixa do espectro eletromagnético podem ser mais bem avaliadas através de combinações matemáticas de diferentes bandas espectrais (ATZBERGER, 2013). Padolfi et al. (2018) afirmam que essas transformações são medidas da atividade da vegetação e utilizam em especial as faixas do visível e infravermelho próximo (NIR - Near Infrared) e são denominados de índices de vegetação (IV).

Os sensores multiespectrais são capazes de captar sinais tanto do espectro visível ao olho humano como outros espectros, permitindo que esta tecnologia, quando aliada às técnicas de Sensoriamento Remoto, contribua com a geração de produtos tecnológicos e inovadores em áreas de estudo como, por exemplo, a agricultura (FACCO; PEGORARO, 2019).

### **3.6 Índices de Vegetação**

Na agricultura, as propriedades da reflectância em cada faixa do espectro eletromagnético podem ser mais bem avaliadas através de combinações matemáticas de diferentes bandas espectrais (ATZBERGER, 2013). O monitoramento da vegetação por SR pode ser realizado por meio de índices de vegetação, que são medidas radiométricas que indicam a quantidade e atividade da vegetação verde

(JENSEN, 2011). Essas transformações são medidas da atividade da vegetação e utilizam em especial as faixas do visível e do infravermelho próximo (PADOLFI et al., 2018).

De acordo com Padolfi et al. (2018) o uso da ARP's em AP tem focado na aplicação de sensores baseados na espectroscopia de reflectância, ou seja, medidas de reflexão da radiação eletromagnética (REM) após interação com diferentes superfícies em diferentes comprimentos de onda, abrangendo a região do visível (VIS – 0,4 – 0,7  $\mu\text{m}$ ), infravermelho próximo (NIR – 0,7 – 1,3  $\mu\text{m}$ ) e Infravermelho de ondas curtas (SWIR – 1,3 – 2,5  $\mu\text{m}$ ).

O cálculo dos índices de vegetação é realizado por combinações matemáticas dos valores da reflectância, sendo esses associados às características fisiográficas das plantas (PEZZOPANE et al., 2019; SHIRATSUCHI et al., 2014). Diversos índices de vegetação podem ser calculados por imagens captadas de sensores multiespectrais acoplados nas ARP's.

Índices de Vegetação têm sido propostos na literatura com o objetivo de explorar as propriedades espectrais da vegetação, especialmente nas regiões do visível e do infravermelho próximo (PONZONI; SHIMABUKURO, 2010).

Alguns autores calcularam IV's utilizando imagens obtidas por ARP em culturas como: tomates, uvas, soja, limoeiro, pastagem.

Utilizando uma câmera Tetracam ADC e sensores multiespectrais acoplada em uma ARP do tipo hexacoptero, Candiago et al. (2015) avaliaram duas culturas: tomate e uva. Através dos dados multiespectrais os autores extraíram informações como: Índices de Vegetação (VI), Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação por Diferença Normalizada Verde (GNDVI) e Índice de Vegetação Ajustado para o Solo (IVAS), onde foi possível avaliar o vigor de cada cultura.

Avaliando o uso de Sensoriamento Remoto por ARP em uma área de 3,14 ha de soja no município de Cruz Alta- RS, Michelon et al. (2019) obtiveram imagens pelo sensor acoplado a ARP. Os autores calcularam os índices NDVI e NDRE, concluíram que através do levantamento aerofotogramétrico e processados com softwares específicos, foi possível obter uma série de dados relevantes e úteis para tomadas de decisões pontuais e precisas.

Utilizando uma câmera RGB acoplada a uma ARP, Padolfi et al. (2018) avaliaram os índices NDVI e MPRI na cultura do limoeiro no município de Jaguaré-ES. Os resultados obtidos mostraram a eficácia das técnicas utilizadas no sensoriamento remoto, onde houve uma equiparação e correlação entre os índices calculados e que, em ambos os índices de vegetação é possível visualizar a densidade da vegetação e a qualidade da mesma.

Realizando um estudo em uma área de 8 ha sob o cultivo de pastagem localizada na Embrapa Pecuária Sudeste, em São Carlos, SP, Sampaio et al. (2020) objetivou realizar uma comparação de índices de vegetação obtidos por imagens de sensores acoplados a uma ARP e por imagens de satélites.

Os índices calculados foram o NDVI e MPRI para as imagens do sensor orbital e para o suborbital. Pelos resultados os autores concluíram que o sensoriamento remoto foi útil para o mapeamento da variabilidade espacial da pastagem, porém há a necessidade de calibração dos dados das imagens tomadas com ARP's para que a conversão para reflectância seja adequada, permitindo uma comparação mais efetiva.

Pesquisas que avaliam o estresse hídrico nas lavouras de café são praticamente escassas, sendo assim o uso de imagens de alta resolução obtidas por sensores acoplados às ARP's e utilizadas para o cálculo de índices de vegetação podem ser uma alternativa para o cafeicultor que busca cada vez mais suporte para o desenvolvimento de sua lavoura.

## 4 METODOLOGIA

A metodologia desta pesquisa está dividida da seguinte forma: descrição da área experimental, georreferenciamento dos pontos no terreno e grade de amostragem, obtenção de amostras para umidade do solo, potencial hídrico das folhas, espacialização das variáveis em estudo, aquisição e processamento das imagens da aeronave remotamente pilotada, cálculo dos índices de vegetação e correlação e regressão linear dos dados.

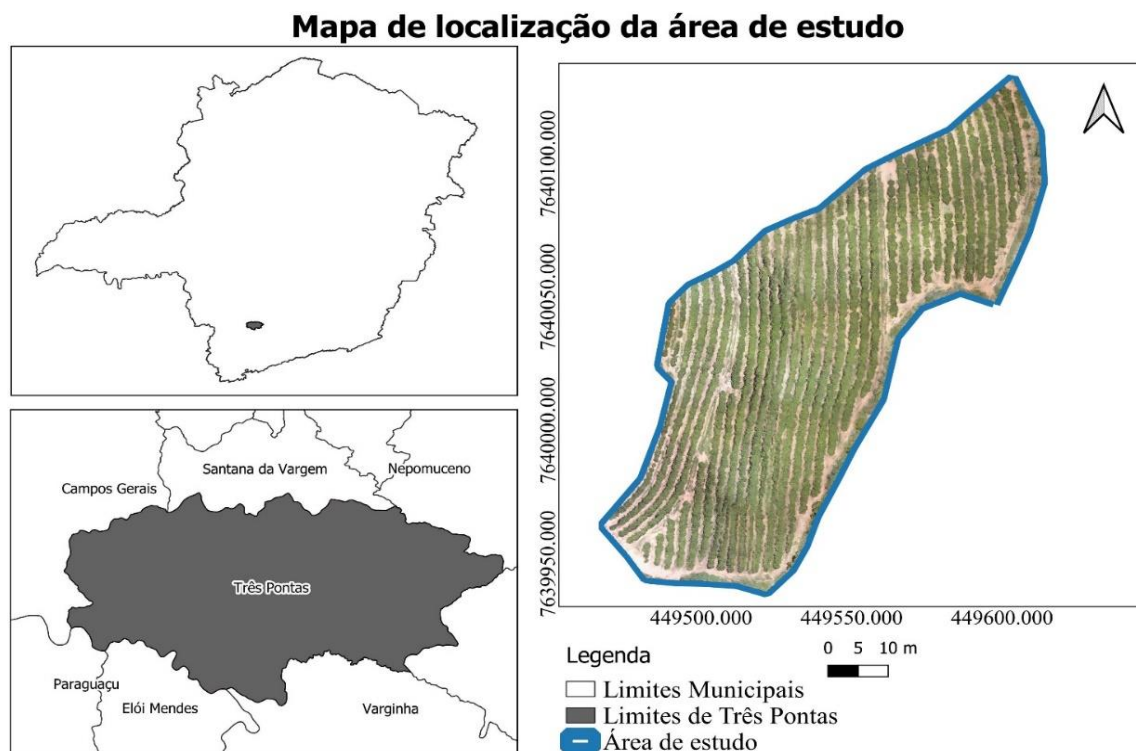
### 4.1 Descrição da área experimental

O estudo foi conduzido em uma lavoura de café do Campo Experimental da Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG), situada no município de Três Pontas, que está localizado na região sul do estado de Minas Gerais, Brasil, estando a 905 m de altitude, e com coordenadas geográficas centrais de 21° 22' 13" S de latitude 45° 30' 44" W de longitude (IBGE).

O clima do município é classificado como tropical de altitude (CW a), de acordo com a classificação de Köppen-Geiger. Conforme o Instituto Nacional de Meteorologia (INMET), a precipitação anual total em 2020 foi de 1527,2 mm, e a temperatura média anual no inverno foi de aproximadamente 17 °C, e a média anual no verão é de aproximadamente 22 °C (INMET 2020).

A área do experimento possui 1,2 ha de cultivo de cafeeiros da espécie *Coffea arabica* L., da cultivar Topázio MG 1190. Essa lavoura foi implantada no ano de 1998 com espaçamento entre linhas de 3,70 m e entre plantas de 0,70 m (Figura 1).

Figura 1- Mapa de Localização da área.




## 4.2 Grade de amostragem

Considerando que a maioria dos cafezais implantados do Sul de Minas Gerais possuem disposição das linhas de plantio em nível, para a construção da grade de amostragem para esse estudo, utilizou-se a metodologia proposta por Faria (2019), baseada na malha amostral equidistante, esse método consiste em diminuir o caminhamento dentro do talhão utilizando rotas de caminhamento.

A escolha do número de pontos dentro da grade amostral, baseou-se nos estudos elaborados por Landim (2006), onde o autor afirma que para uma análise geoestatística, exige-se que o número mínimo de pontos amostrados seja razoável, por volta de 30 a 40.

A grade amostral foi confeccionada no software QGis, versão 3.4.8, onde foram dispostos 30 pontos de amostragem (Figura 2), representando uma densidade amostral de 25 pontos por hectare. O contorno da área e o georreferenciamento dos pontos amostrais foram realizados a partir de um Global Navigation Satellite System (GNSS) topográfico RTK modelo R8 da TRIMBLE.

Figura 2- Pontos amostrais georreferenciados.



Fonte: Da autora (2021).

O trabalho de georreferenciamento desta malha amostral foi realizado no dia 11/08/2020. Segundo Ferraz et al. (2012) afirmam que a grade amostral comercialmente utilizada para se amostrar solos em cafeicultura é a de um ponto por hectare. Dessa maneira, a grade amostral utilizada nesta pesquisa apresenta-se vantajosa, uma vez que possui um número maior de pontos amostrais do que utilizado comercialmente, sem perder a capacidade de ser viável para aplicações práticas.

A grade de amostragem considerou a projeção cartográfica UTM, Zona 23 S e DATUM WGS 84. Os pontos de amostragem foram demarcados utilizando-se fitas zebradas, com aproximadamente 1,50 m de comprimento. Cada fita foi amarrada em um ramo e posicionada a uma altura aproximada de 1,50 m. Na ponta de cada fita foi fixada uma placa de identificação contendo a numeração de cada planta.

Foram realizadas duas coletas de dados em campo, uma no dia 11/08/2020 e outra no dia 27/01/2021, para avaliar o comportamento do status hídrico da lavoura no período seco e no período chuvoso, respectivamente. Na Tabela 1 observa-se os dados climatológicos para ambas as datas de coletas. Estes dados são provenientes da estação meteorológica de uma fazenda à 15 km de distância do campo experimental da EPAMIG, Três Pontas, essas informações climatológicas obtidas pela base de dados do sistema pertencente à Cooperativa Regional de Cafeicultores em Guaxupé LTDA (COOXUPÉ).



Tabela 1- Dados climatológicos referentes as datas de coletas de amostras.

Período Coleta	Temperatura Média Mensal (°C)	Data última precipitação	Quantidade da última precipitação (mm)
Seco (agosto 2020)	19,3	31/05/20	20 mm
Chuvoso (janeiro 2021)	23,9	20/01/21	115 mm

Fonte: COOXUPÉ (2020, 2021).

### 4.3 Umidade do solo

A umidade volumétrica do solo é definida como o volume de água contido em um determinado volume de amostra de solo. A mesma pode ser relacionada com a umidade gravimétrica. Segundo Klein (2008), para transformar a umidade do solo com base em massa para umidade do solo com base em volume utiliza-se uma relação matemática (Equação 1) que determina que o produto da multiplicação dos valores da umidade gravimétrica pela densidade do solo, dividido pela densidade da água, origina a umidade com base em volume, expressa em m<sup>3</sup> de água/m<sup>3</sup> de solo, cm<sup>3</sup>/cm<sup>3</sup> ou mm<sup>3</sup>/mm<sup>3</sup>.

(1)

$$Uv (\%) = \frac{(Ug \times Ds)}{Da} \times 100$$

Onde:

Uv: Umidade volumétrica (%)

Ug: Umidade gravimétrica (g/g)

Ds: Densidade do solo (g/cm<sup>3</sup>)

Da: Densidade da água (g/cm<sup>3</sup>)

No campo, utilizando um trado de amostras indeformadas foram coletados 30 pontos amostrais georreferenciados, sendo 30 amostras na profundidade de 0-10 cm e 30 amostras na profundidade de 10-20 cm. Cada amostra de solo foi armazenada individualmente em um anel, envolvidas em plástico filme e armazenadas em caixa térmica para que não houvesse perda de umidade.

Para obter a umidade volumétrica das amostras, anéis metálicos com numeração foram pesados em uma balança de precisão com resolução de 0,0001g para se obter a tara de cada anel. Utilizando um paquímetro, foram realizadas as medidas de diâmetro e altura de cada anel para que o volume de cada um fosse conhecido.

Seguindo as normas da NBR 6457/2016 as amostras contidas nos anéis foram pesadas obtendo a massa úmida, e em seguida foram acondicionadas em uma estufa a 105° C por 24 horas. Após esse período os anéis contendo as amostras de solo seco foram pesados novamente.

Com os dados de massa úmida e massa seca é possível obter os valores de umidade gravimétrica que, segundo Klein (2008), é a relação entre a quantidade de água contida num solo ou substrato e a sua massa de sólidos secos, representada pela Equação 2.

$$Ug (g/g) = \frac{\text{Massa de água (g)}}{\text{Massa de solo (g)}} \quad (2)$$

Onde:

Massa de água: é o resultado da diferença entre os valores de massa úmida e massa seca

Massa de solo: referente a massa seca

A densidade do solo é definida como sendo a relação existente entre a massa de uma amostra de solo seca a 105°C e a soma dos volumes ocupados pelas partículas e pelos poros. Nesse experimento, para obtenção da densidade do solo, foi utilizado o método do anel volumétrico que consiste no uso de um anel Kopeck, de bordas cortantes.

O Método do Anel Volumétrico consiste em cravar o anel na superfície do solo com o auxílio de um trado de amostras indeformadas, e posteriormente realizar sua remoção, e em seguida retira-se o excesso de solo, a qual será desbastada com auxílio de uma faca cortante até igualar com a superfície do anel.

Cada amostrada contida no anel foi envolvida em plástico filme e transferido para uma caixa térmica para não haver perda de umidade. Seguindo as mesmas normas do método gravimétrico, as amostras para obtenção da densidade do solo foram secas em uma estufa à 105° C durante 24 horas, e a partir desses processos a densidade do solo pode ser obtida pela Equação 3.

$$Ds (g/cm^3) = \frac{\text{Massa de solo (g)}}{\text{Volume do solo (cm}^3\text{)}} \quad (3)$$

Onde:

Massa de solo: referente a massa de solo seco;

Volume do solo: referente ao volume do anel, através das medidas de diâmetro e altura.


#### 4.4 Potencial hídrico das folhas

Para a coleta do potencial hídrico das folhas utilizou-se o método da bomba de Scholander (SCHOLANDER et al., 1965). As coletas foram realizadas por volta de 04:30 da manhã. Para cada ponto

georreferenciado coletaram-se 3 folhas do terço médio, do terceiro a quarto par de folhas, onde continham o pecíolo, e foram devidamente armazenadas para não haver perda de umidade.

Imediatamente após a coleta em cada planta georreferenciada, verificou-se o potencial hídrico das folhas através da bomba de Scholander (Figura 3). Este método consiste em colocar a folha dentro de um cilindro, de maneira que apenas o pecíolo fique para fora, atravessando um pequeno orifício revestido de borracha na tampa a qual é a prova de gás. Uma pressão é gradativamente fornecida à câmara do cilindro até que verifique o primeiro sinal de expulsão da seiva na extremidade exposta do pecíolo, quando a injeção do gás (inerte-nitrogênio) deve ser interrompida e então, fazer a leitura do manômetro. O valor expresso pelo manômetro representa o potencial de pressão do xilema em MPa (Mega Pascal), onde o potencial de soluto ou osmótico é considerado desprezível.

Figura 3- Bomba de Scholander.



Fonte: Da autora (2021).

#### 4.5 Espacialização das variáveis em estudo


Com o intuito de analisar a dependência espacial das variáveis aleatórias (atributos) em estudo, foram utilizados semivariogramas. A semivariância é classicamente estimada pela Equação (4), segundo Vieira et al. (2000):

(4)

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{Ni=(h)} [Z(x_i) - Z(x_i + h)]^2$$

Onde  $N(h)$  é o número de pares experimentais de observações  $Z(x_i)$  e  $Z(x_i + h)$ , separados por uma distância  $h$ . O semivariograma é representado pelo gráfico  $\hat{\gamma}(h)$  versus  $h$ . Do ajuste de um modelo matemático aos valores calculados de  $\hat{\gamma}(h)$  são estimados os coeficientes do modelo teórico para o semivariograma (Figura 4) denominado de efeito pepita ( $C_0$ ), patamar ( $C_0+C_1$ ) e o alcance ( $a$ ), conforme descrito por Bachmaier e Backers (2008).

Figura 4- Modelo de um semivariograma.



Fonte: FINAZZI, 2011 (Adaptado de CAMARGO, 1998).

Para este estudo utilizou-se o método dos mínimos quadrados ordinários (OLS) e os modelos esférico, exponencial e gaussiano. Estes modelos foram escolhidos de acordo com o ajuste apresentado para cada atributo estudado. Com o propósito de verificar se os ajustes para cada modelo atendem as exigências da validação cruzada, foi calculado o Erro Médio (EM) conforme Isaaks e Srivasta (1989). O EM deve apresentar o valor mais próximo possível de zero.

Com o ajuste de semivariogramas, após a identificação da variabilidade espacial, foi realizado a interpolação dos dados por meio de krigagem ordinária. Dessa forma, foi feito a estimativa da variável em locais onde a mesma não foi amostrada, permitindo visualizar por exemplo, sua distribuição no espaço na forma de mapas temáticos.

Cambardella et al. (1994) realizou-se o cálculo do grau de dependência espacial (GDE) das

variáveis. Essa classificação sugere que há forte dependência espacial quando os semivariogramas apresentam um efeito pepita igual ou inferior a 25% do patamar, moderada dependência espacial quando está entre 25% e 75%, e fraca, quando for maior que 75%.

Para a análise geostatística e para a criação dos mapas temáticos foi utilizado o software estatístico RStudio, de distribuição livre, por meio do pacote geoR (RIBEIRO JUNIOR; DIGGLE, 2001).

## 4.6 Aquisição e processamento das imagens da aeronave remotamente pilotada

### 4.6.1 Características da Aeronave e da Câmera Multiespectral

O conjunto de imagens foi adquirido com uma aeronave remotamente pilotada modelo eBee SQ, da empresa senseFly (Figura 4), esta ARP é pertencente a EPAMIG. Esta aeronave possui as seguintes características: asa fixa, envergadura de 110 cm, alcance de rádio de 3 km nominais, velocidade de cruzeiro de 40-110 km/h, resistência ao vento de até 45 km/h (12 m/s), motor elétrico, carga útil máxima de 1,1 kg (incluindo câmera e baterias) e uma autonomia de voo de até 55 minutos.

Figura 5- Aeronave Remotamente Pilotada eBee SQ.



Fonte: Da autora (2021).

A aeronave foi equipada com uma câmera da marca Parrot modelo Sequoia que possui uma câmera RGB de alta resolução com sensor de  $4608 \times 3456$  pixels, tamanho de pixel de  $1,34 \mu\text{m}$  e distância focal de 4,88 mm. A distância de amostragem do solo (GSD) é de 1,9 cm a 70 m de altura acima do nível do solo (AGL).

A Sequoia possui quatro sensores monocromáticas para as bandas espectrais: verde ( $550 \pm 40$  nm), vermelho ( $660 \pm 40$  nm), infravermelho próximo ( $790 \pm 40$  nm) e borda do vermelho ( $735 \pm 40$  nm). A resolução é de  $1280 \times 960$ , com tamanho de pixel de  $3,75 \mu\text{m}$  e distância focal igual a  $3,98$  mm; o GSD é de  $6,8$  cm na altura de voo de  $50$  m (AGL), que foi adotada para a pesquisa descrita.

Além da câmera RGB e dos sensores monocromáticos, a sequoia ainda possui um sensor de luminosidade para corrigir a influência do sol obtendo dados com correções radiométricas, esse sensor não apenas grava a iluminação atual, mas também a localização do centro da foto e dados inerciais.

#### 4.6.2 Planejamento de Voo

O planejamento de voo consiste em uma etapa primordial onde serão definidos parâmetros como: altitude de voo, área de cobertura, velocidade, sobreposição de imagens, etc, de modo que as imagens obtidas com qualidade e que possam atender os objetivos esperados. Para realizar o planejamento de voo, existem diversos softwares no mercado que podem ser utilizados em computadores, desktop, smartphones e tablets, e que posteriormente será enviado para a ARP.

O planejamento e execução do voo foi executado por meio da estação base, desenvolvida pela mesma fabricante da aeronave (senseFly), com o seguinte conjunto: o software eMotion, responsável pela programação do voo e execução do trajeto da aeronave, e uma antena transmissora, que permite o acompanhamento em tempo real do sobrevoo, bem como o envio de comandos de pouso, mudanças de direção ou tomada de imagens. A interface do programa mostra informações importantes sobre o nível de bateria, temperatura ambiente, altitude, posição, duração e velocidade do voo, velocidade do vento, resolução e sobreposição longitudinal e latitudinal da área a ser sobrevoada, altitude e link do rádio.

O plano de voo seguiu os parâmetros representados na Tabela 2.

Tabela 2- Parâmetros do planejamento de voo.

<b>Câmera</b>	Parrot Sequoia
<b>Resolução Câmera RGB</b>	16 megapixels
<b>Resolução da Câmera Multiespectral</b>	1,2 megapixels
<b>Distância Focal</b>	3,98 mm
<b>Recobrimento Vertical</b>	70%
<b>Recobrimento Horizontal</b>	70%
<b>Resolução Espacial</b>	5 cm
<b>Altitude de Voo</b>	50 m
<b>Velocidade</b>	12 m/s

Fonte: Da autora (2021).

### 4.6.3 Processamento das Imagens

O processamento das imagens foi realizado pelo *software* Pix4DMapper. O processamento digital consistiu em: fototriangulação dos blocos de imagens, obtendo os parâmetros de orientação exterior e interior das imagens; geração da nuvem de pontos, produção do MDS (Modelo Digital de Superfície) e, a geração do ortomosaico.

Para realizar a fototriangulação das imagens, utilizou-se cinco pontos de controle distribuídos uniformemente pela propriedade. Os pontos foram levantados com auxílio de um GNSS modelo R8 da Trimble, de dupla frequência no modo RTK (*Real Time Kinematic*) com precisão inferior a 1 mm em numa banda de 1 Hz.

Em seguida, realizou-se a correção radiométrica dos ortomosaicos, isto é, a conversão dos valores em ND (Número Digital) para a refletância de superfície. Esse processamento também foi realizado no *software* Pix4DMapper, com recursos da Parrot Sequoia.

Antes da realização do voo, procedeu-se à calibração radiométrica da câmera utilizando uma placa de referência. Usando os valores dessa placa, o software pode calibrar e corrigir a refletância da imagem levando em considerações as características de iluminação no momento do voo.

### 4.7 Cálculo dos índices de vegetação

Com o intuito de verificar a utilização das Aeronaves Remotamente Pilotadas para a avaliação das condições hídricas do cafeeiro, após o processamento das imagens pelo software Pix4D, essas foram salvas no formato TIF e enviadas para o software QGis, versão 3.4.8. Através das bandas NIR, RED, GREEN e RED Edge, calculou-se os seguintes índices de vegetação representados pela Tabela 3.

Tabela 3. Índices de vegetação calculados a partir das imagens de alta resolução.

Índice	Sigla	Função	Equação	Referência
Normalized Difference Vegetation Index	NDVI	Medida da vegetação verde e saudável.	$\frac{NIR - RED}{NIR + RED}$	Rouse et al. (1973)
Normalized Difference Water index	NDWI	Ressaltar as feições de água e minimizar o restante dos alvos.	$\frac{G - NIR}{G + NIR}$	McFeeters, (1996)
Enhanced Vegetation Index 2	EVI2	Melhoramento do índice EVI, sem a faixa do azul, minimizando assim as distorções causadas pela atmosfera.	$2,5 * \frac{NIR - RED}{(NIR + 2,4 * RED + 1)}$	Jiang et al., (2008)
Normalized Difference RedEdge	NDRE	Avaliar o teor de clorofila nas plantas, assim como sua captação de nitrogênio e a demanda de fertilizantes.	$\frac{NIR - RED\ Edge}{NIR + RED\ Edge}$	Barnes et al. (2000)
Chlorophyll vegetation index	CVI	Sensibilidade aumentada ao conteúdo de clorofila na cobertura decídua.	$\frac{NIR}{GREEN} * \frac{RED}{GREEN}$	Vincini et al. (2014)
Green Normalized Difference Red-Edge	GNDVI	Sensível à concentração de clorofila.	$\frac{NIR - GREEN}{NIR + GREEN}$	Gitelson et al. (1996)
Canopy chlorophyll 32ontente index	CCCI	Indicador da atividade fotossintética da cobertura vegetal, é mais frequentemente usado para avaliar o teor de umidade e a concentração de nitrogênio nas folhas das plantas.	$\frac{NDRE}{NDVI}$	Long et al. (2009)
Green Ratio of vegetation index	GVI	Minimiza os efeitos do solo de fundo quando enfatiza a vegetação verde.	$\frac{NIR}{GREEN}$	Birth and McVey, (1968)
Modified Simple Ratio	MSR	Aumento da sensibilidade aos parâmetros biofísicos da vegetação.	$\frac{\left(\frac{NIR}{RED}\right) - 1}{\left(\frac{NIR}{RED}\right) + 1}$	Chen, (1996)
Infrared Percentage Vegetation Index	IPVI	Idêntico ao NDVI, porém computacionalmente mais rápido.	$\frac{NIR}{NIR + RED}$	Crippen, (1990)
Soil Adjusted Vegetation Index	SAVI	Semelhante ao NDVI, porém suprime os efeitos dos pixels do solo, através de um fator de ajuste de fundo do dossel.	$\frac{(1 + L)(NIR - RED)}{L + NIR + RED}$	Huete, (1988)
Modified Soil Adjuted Vegetation Index 2	MSAVI	Amenizar o efeito de fundo do solo.	$\frac{[2NIR + 1 - ((2NIR + 1)^2 - 8(NIR - RED))^{0,5}]}{2}$	Qi et al. (1995)
Optimized Soil Adjusted Vegetation Index	OSAVI	Índice indicado em áreas com vegetação relativamente esparsa onde o solo é visível através do dossel.	$\frac{(NIR - RED)}{(NIR + RED + 0,16)}$	Roudeaux et al. (1996)
Green Chlorophyll Index	CIgreen	Conteúdo total de clorofila das folhas, para a banda do verde.	$\left(\frac{NIR}{GREEN}\right) - 1$	Gitelson et al. (2003)
Red-edge Chlorophyll Index	Clrededge	Conteúdo total de clorofila para a banda da borda do vermelho.	$\left(\frac{NIR}{RED\ EDGE}\right) - 1$	Gitelson et al. (2003)

Fonte: Da autora (2021).



## 4.8 Correlação e Regressão Linear dos dados

Com o intuito de identificar os índices de vegetação que possuem a melhor correlação com os atributos potencial hídrico e umidade do solo, calculados com as equações apresentadas na Tabela 3, utilizando imagens de alta resolução, foram realizadas as técnicas correlação e regressão linear dos dados. Onde a correlação resume o grau de relacionamento de duas variáveis (X e Y, por exemplo). Já a regressão tem como resultado uma equação matemática que descreve o relacionamento entre variáveis.

Para a realização da regressão linear simples, utilizou-se como variável dependente as amostras extraídas de cada índice (contendo o valor médio de reflectância de cada ponto) e as variáveis independentes foram representadas pelos dados de umidade gravimétrica e volumétrica do solo e potencial hídrico das folhas, coletados em campo.

Para a coleta das variáveis dependentes retirou-se amostras de polígonos a partir dos pontos georreferenciados. Esses polígonos foram construídos com um buffer, ou seja, cada amostra possuía um raio de 0,20 m (20 cm). Realizou-se amostragens tanto para as plantas demarcadas, quanto para o solo, através da ferramenta estatística zonal, que calcula a média do valor de refletância dos pixels dentro de um polígono. Para cada ponto georreferenciado, obteve-se 30 médias do valor de refletância para cada índice de vegetação estudado, tanto para amostras de vegetação, quanto para amostras de solo.

O valor médio de cada ponto e de cada índice calculado foi exportado para uma tabela, na qual realizou-se as operações de regressão linear pelo programa Excel, onde obteve os valores de: coeficiente de correlação de Person (R) e coeficiente de determinação, além dos teste de hipótese F, para testar significância de cada hipótese. Considerando que  $H_0: \rho = 0$ , então as hipóteses usadas nesta pesquisa foram:

$H_0: \rho = \rho_0$  hipótese nula;

$H_1: \rho \neq \rho_0$  hipótese alternativa

A correlação é calculada pelo coeficiente linear de Person (R), expresso pela Equação 5. O valor de R estará sempre no intervalo de -1 a 1.

$$R = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}} \quad (5)$$

A interpretação do coeficiente de correlação de Person pode ser descrita pela Tabela 4.

Tabela 4- Interpretação do coeficiente de correlação de Person.

Coeficiente de Correlação	Correlação
$R_{xy} = 1$	Perfeita Positiva
$0,8 \leq R_{xy} < 1$	Forte Positiva
$0,5 \leq R_{xy} < 0,8$	Moderada Positiva
$0,1 \leq R_{xy} < 0,5$	Fraca Positiva
$0 \leq R_{xy} < 0,1$	Ínfima Positiva
0	Nula
$-0,1 \leq R_{xy} < 0$	Ínfima Negativa
$-0,5 \leq R_{xy} < -0,1$	Fraca Negativa
$-0,8 \leq R_{xy} < -0,5$	Moderada Negativa
$-1 \leq R_{xy} < -0,8$	Forte Negativa
$R_{xy} = -1$	Perfeita Negativa

Fonte: RODRIGUES et al., 2012.

A relação entre essas variáveis é representada por um modelo matemático, ou seja, uma equação que associe a variável dependente com as variáveis independentes, no qual o modelo é chamado de regressão linear simples. A partir da regressão linear, obtém-se o coeficiente de determinação, que é expresso pela Equação 6.

$$R^2 = \frac{\sum(\hat{y}_i - y)^2}{\sum(y_i - \bar{y})^2} = \frac{\text{variação explicada pelo modelo}}{\text{variação total}} \quad (6)$$

O coeficiente de determinação é uma medida descritiva da proporção da variação da variável independente que pode ser explicada por variações da variável dependente, segundo o modelo de regressão especificado. Quanto mais próximo de 1 estiver o coeficiente de determinação, melhor será o grau de explicação da variação de Y em termos da variável X. É uma medida sempre positiva, e é obtida, na regressão linear simples, elevando-se o coeficiente de correlação de Person ao quadrado.

Foi utilizado o teste F de hipótese ao nível de 95% de confiança.

## 5 RESULTADOS E DISCUSSÃO

### 5.1 Estatística Descritiva

A análise descritiva dos atributos umidade gravimétrica (Ug 0-10 cm e Ug 10-20 cm), umidade volumétrica (Uv 0-10 cm e Uv 10-20 cm) coletadas em diferentes profundidades e potencial hídrico das folhas ( $\Psi_w$ , em MPa), está representada pela Tabela 5.

Tabela 5- Estatística descritiva para os dados coletados em campo Umidade Gravimétrica (Ug, em %), Umidade Volumétrica (Uv, em %) em diferentes profundidades e Potencial Hídrico das Folhas ( $\Psi_w$ , em MPa), para as coletas de agosto 2020 e janeiro de 2021.

Ano	Variável	Estatística Descritiva						
		Min	Máx	Md	Méd	Var	DP	CV
2020	Ug (0-10 cm)	12,5	20,64	17,67	17,22	3,65	1,91	0,11
	Ug (10-20 cm)	11,75	19,33	17,93	17,61	2,63	1,62	0,09
	Uv (0-10 cm)	19,52	29,54	25,52	24,83	6,00	2,45	0,09
	Uv (10-20 cm)	18,48	27,97	25,69	25,26	4,94	2,22	0,08
	$\Psi_w$ (MPa)	-3,3	-0,5	1,15	1,45	0,61	0,782	0,53
2021	Ug (0-10 cm)	18,92	31,19	23,06	23,57	7,34	2,68	0,11
	Ug (10-20 cm)	15,36	36,19	23,23	22,74	13,93	3,73	0,16
	Uv (0-10 cm)	26,24	45,45	34,39	35,02	8,08	2,84	0,07
	Uv (10-20 cm)	22,79	48,85	34,68	33,87	25,37	5,03	0,14
	$\Psi_w$ (MPa)	-0,8	-0,3	0,6	0,59	0,01	0,10	0,17

Min= valor mínimo, Máx= valor máximo, Md= mediana, Méd=média, Var= variância, DP= desvio padrão e CV= Coeficiente de variação.

Fonte: Da autora (2021).

Gomes e Garcia (2002) afirmam que a variabilidade de um atributo pode ser classificada de acordo com a magnitude do seu coeficiente de variação (CV), que segundo os autores podem ser: baixa, quando este for inferior a 10%; moderada quando está no intervalo de 10 e 20%, alta quando está entre 20 e 30%; e muito alta quando está acima de 30%. Frogbrook et al. (2002) afirmam que os primeiros indicadores de heterogeneidade de dados, são os valores elevados de CV.

Para os dados de campo do ano 2020, as variáveis Ug (10-20 cm) e Uv (0-10 cm e 10-20 cm), apresentaram um valor de CV abaixo de 10%. Já para a variável Ug (0-10 cm), o valor de CV de 11% pode ser considerado como moderado. Já para a variável Potencial Hídrico das folhas, o valor de CV foi de 53%, sendo considerado como alta heterogeneidade.

Para as variáveis coletadas no ano de 2021 apenas a Uv (0-10 cm) apresentou baixa heterogeneidade ( $CV < 10\%$ ) e as demais variáveis se concentraram no intervalo de moderada heterogeneidade ( $10\% < CV < 20\%$ ).

Os menores valores de umidade gravimétrica e volumétrica para o ano de 2020 foram encontrados nas profundidades de 10-20 cm 11,75 e 18,48% respectivamente. O mesmo fato aconteceu para o ano de 2021, os menores valores de umidade, tanto gravimétrica como volumétrica foram encontrados na profundidade de 10 a 20 cm (15,36 e 22,79%). Em relação aos valores máximos de umidade para os anos de 2020 e 2021, estes foram encontrados nas amostragens de 0-10 cm, para ambos valores de umidade gravimétrica e volumétrica.

Valores semelhantes de umidade gravimétrica em solos sob o cultivo de café aos encontrados nesta pesquisa também são referendados na literatura pelos trabalhos de Fiorese (2019) que encontrou um valor médio 17,82% e de Tanques et al. (2019) que obtiveram valores de 18,20% para a profundidade de 0-20 cm e de 20,00% para a profundidade de amostragem de 20-40 cm. Outro fato em comum entre essa pesquisa e o trabalho realizado por Tanques et al. (2017) é que os valores de umidade gravimétrica não variaram significativamente levando em consideração as profundidades de amostragem.

As médias de umidade gravimétrica apresentaram valores de 17,67% para a amostragem na profundidade de 0-10 cm e de 17,93% para a profundidade de 10-20cm para o ano de 2020. Já para o ano de 2021 os valores foram de 23,06% e 23,23% para as amostragens na profundidade de 0-10 cm e de 10-20 cm respectivamente. Já a média de valores para a umidade volumétrica foi de 24,83 % e 25,26% para as profundidades de 0-10 cm e de 10-20 cm respectivamente para o ano de 2020. Já para o ano de 2021, os valores foram de 35,02% para a profundidade de amostragem de 0-10 cm e de 33,87% para a profundidade de 0-20 cm.

Mota Júnior (2017) avaliaram a umidade volumétrica do solo em três profundidade, 0-5 cm, 5-10 cm e de 10-20 cm, os autores encontraram valores de 45,00%, 41,00% e 38,00% para as respectivas profundidades de amostragem. Observa-se que a umidade volumétrica amostrada na profundidade de 0-10 cm para essa pesquisa de 35,02% foi muito próxima à encontrada por Mota Júnior et al. (2017) de 38,00% para a profundidade de 10-20cm. Outro fato em comum foi a diminuição do valor de umidade volumétrica à medida que aumentou a profundidade de amostragem.

O potencial hídrico foliar apresentou valores médios de -1,45 MPa para o período seco e de -0,59 MPa para o período chuvoso. De acordo com as afirmações de Silva et al. (2010) valores de potencial hídrico entre -1,5MPa e -3,0MPa apresentam déficits hídricos moderado e severo, respectivamente, então para ambas as coletas (período seco e chuvoso) de potencial hídrico nenhuma encontra-se dentro do intervalo de déficit hídrico, o que corrobora com as afirmações de DaMatta et al. (2007) e Golberg et al. (1988) em que valores de potencial hídrico até -1,5 MPa parecem não afetar a fotossíntese em condições de campo.

Alguns autores apresentaram resultados semelhantes de potencial hídrico aos encontrados nessa pesquisa como os trabalhos de Batista et al. (2010) que encontraram um valor médio de potencial hídrico para a mesma cultivar deste estudo (Topázio MG 1190), de -1,17 MPa e Silva et al. (2015) que encontraram valores médios de potencial hídrico de -1,25 MPa e para o período chuvoso, o valor médio foi de -0,79 MPa, em área sob cultivo de café, valores estes que estão abaixo do intervalo de severidade mencionado por Silva et al. (2015), assim como ocorreu nesta pesquisa.

Observa-se que ao avaliar os períodos seco (agosto 2020) e o período úmido (janeiro 2021), estes apresentaram um crescimento em relação a umidade gravimétrica e volumétrica e uma diminuição do

potencial hídrico foliar, um dos fatores que interferem diretamente à essa condição, está atrelado às precipitação nestes períodos, como apresentadas na Tabela 1.

A condição moderada de severidade para o déficit hídrico em relação ao potencial hídrico, para a coleta de 2020 pode estar relacionado à ausência de precipitação neste período, observada na Tabela 1, onde a última precipitação de 20 mm, ocorreu há 74 dias (31/05/20) anteriormente a data de coleta das amostras. Em relação aos maiores valores deste atributo avaliado no período chuvoso (janeiro 2021), observa-se que houve uma precipitação de 115 mm, sete dias anteriores a data de coleta das amostras.

Conforme observado, os dados apresentados referentes à média, valor mínimo e máximo encontrados na Tabela 2 mostram a variação de valores desta variável. Entretanto apenas o conhecimento destas medidas não pode ser utilizado como único modo de identificar a expressão da variável em uma área. Para tanto, é feita a análise geoestatística com o objetivo de verificar a variabilidade espacial de uma variável e, caso identificada, confeccionam-se mapas temáticos que auxiliam a entender o seu comportamento no campo.

## 5.2 Análise geoestatística

Por meio dos resultados da análise geoestatística todas as variáveis apresentaram dependência espacial (Tabela 6 e Figuras 6 e 7), o que corrobora com os estudos de Serafim et al. (2013) que afirma que a grande variação da umidade do solo ocorre nas profundidades de amostragem dentro do intervalo de 0-20 cm o mesmo intervalo de amostragem utilizado nesta pesquisa e de Burak et al. (2016) que demonstram que as variáveis relacionadas com a retenção de água, apresentam uma maior continuidade e dependência espacial, o que sugere a influência do relevo na sua estrutura espacial.

Observa-se que, para todas as variáveis, o EM apresentou valores muito baixos e próximos de zero, mostrando que os ajustes tanto para o modelo esférico, como para o modelo exponencial foram bem feitos e preencheram os requisitos da validação cruzada. O maior valor de EM foi observado para a variável  $U_v$  10-20 cm (0,0661) no ano de 2021, e o menor valor está representado pela variável  $\Psi_w$  MPa (0,0004) também no ano de 2021.

Neste estudo identificou que todas as variáveis estudadas apresentaram grau de dependência espacial (GDE) forte assim como encontrados nos trabalhos de Mota Júnior et al. (2017) e Carvalho et al. (2013) que avaliando variabilidade espacial de atributos físicos do solo em áreas sob cultivo de café, encontraram GDE forte para a variável umidade de solo.

Tabela 6- Parâmetros de ajuste dos semivariogramas do modelo esférico e exponencial, pelo método dos Mínimos Quadrados Ordinários, das variáveis avaliadas.

Ano	Variável	Modelo	C <sub>0</sub>	C <sub>1</sub>	C <sub>0</sub> +C <sub>1</sub>	A	GDE	EM	
2020	Ug (0-10 cm)	Esf	0,01	3,50	3,51	70,00	0,28	Forte	-0,0029
	Ug (10-20 cm)	Esf	0,10	2,50	2,60	40,00	3,84	Forte	0,0060
	Uv (0-10 cm)	Exp	0,25	3,80	4,05	35,00	6,17	Forte	-0,0228
	Uv (10-20 cm)	Exp	0,01	4,00	4,01	50,00	0,24	Forte	0,0036
	Ψ <sub>w</sub> (MPa)	Esf	0,10	0,40	0,50	15,00	20,00	Forte	-0,0094
2021	Ug (0-10 cm)	Esf	0,00	8,00	8,00	45,00	0,00	Forte	0,0032
	Ug (10-20 cm)	Exp	0,10	15,00	15,10	40,00	0,66	Forte	0,0010
	Uv (0-10 cm)	Esf	0,01	22,00	22,01	20,00	0,04	Forte	-0,0170
	Uv (10-20 cm)	Esf	0,01	28	28,01	20,00	0,00	Forte	0,0661
	Ψ <sub>w</sub> (MPa)	Esf	0,01	15	15,01	15,00	0,06	Forte	0,0004

Ug- umidade gravimétrica (%); Uv- umidade volumétrica (%); Ψ<sub>w</sub>- potencial hídrico das folhas (MPa); C<sub>0</sub>– Efeito Pepita, C<sub>1</sub>- Contribuição; C<sub>0</sub>+ C<sub>1</sub>- Patamar; A- alcance (metros), GDE- grau de dependência espacial (%) e EM- erro médio

Fonte: Da autora (2021).

Os semivariogramas ajustaram-se preferencialmente aos modelos esférico e exponencial. A variável umidade gravimétrica amostrada na profundidade de 0-10 cm apresentou um valor de efeito pepita igual a zero, o chamado efeito pepita puro (EPP), ou seja, variação espacial aleatória.

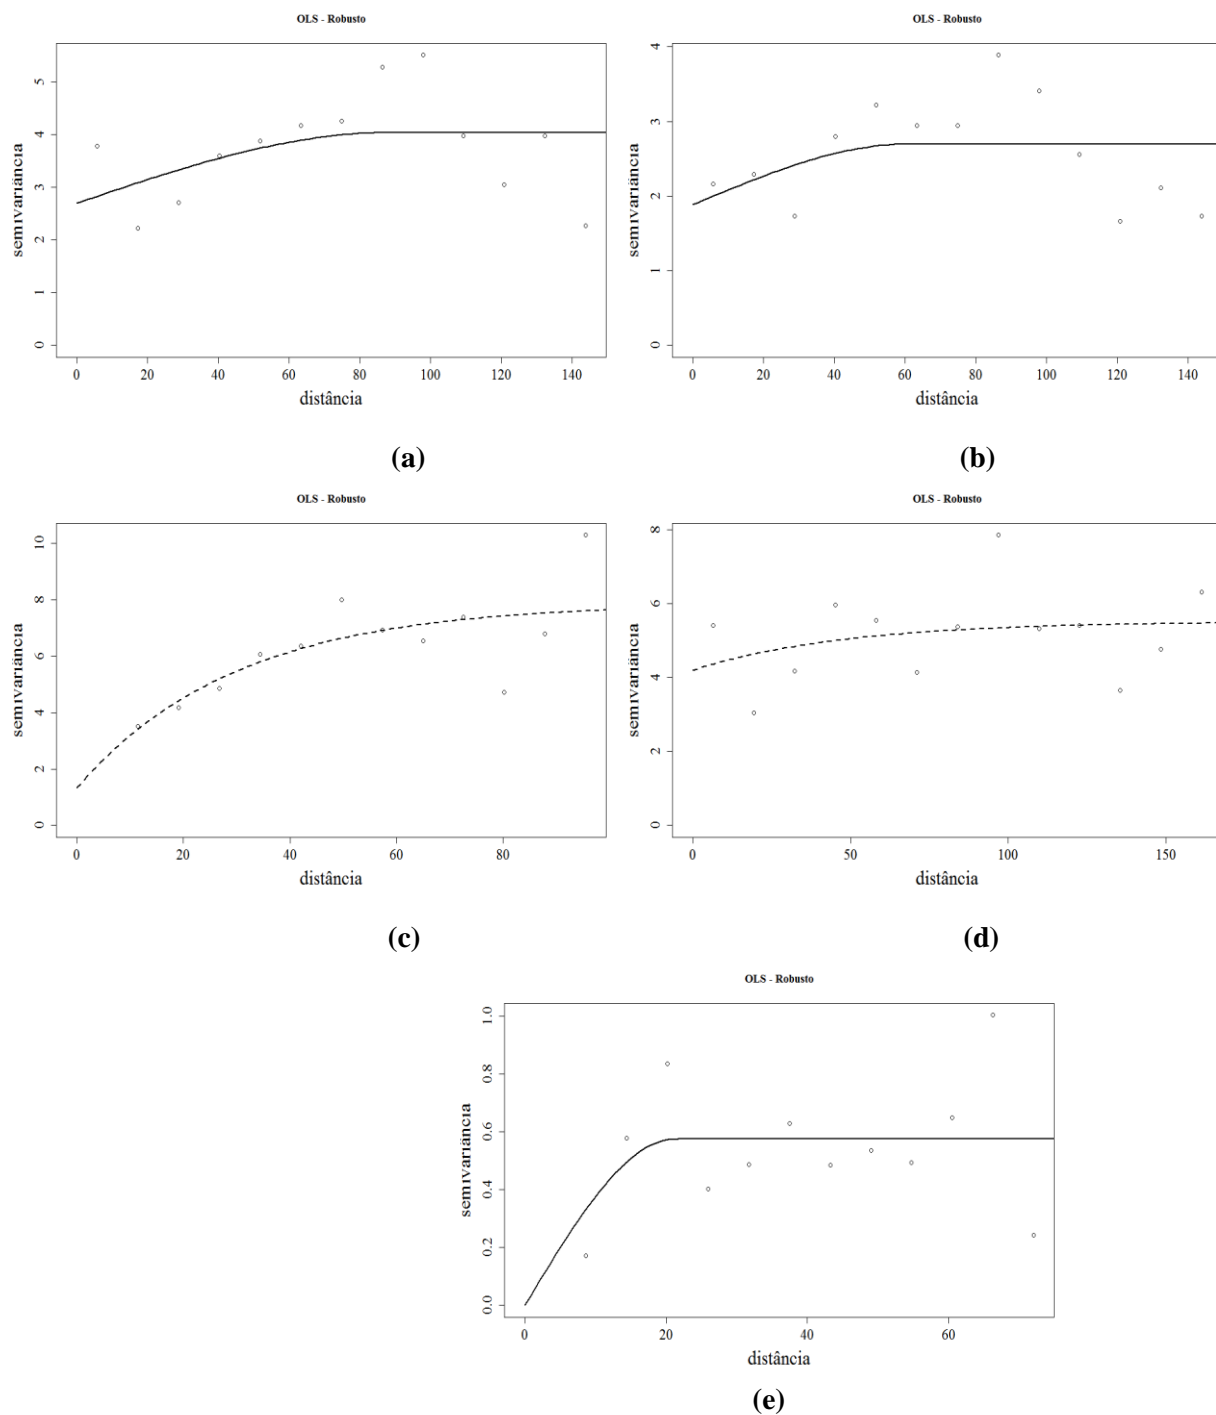
Mota Júnior et al. (2017) afirma que existe uma predominância do modelo matemático esférico predomina para trabalhos em ciência do solo, por outro lado destacam que os modelos de ajuste do semivariograma para as propriedades do solo mais frequentemente encontrados são os modelos esférico e exponencial.

A umidade gravimétrica do ano de 2020 apresentou um valor de alcance de 70,00 m quando amostrada na profundidade de 0-10 cm, e 40,00 m quando amostrada na profundidade de 10-20 cm, ou seja, uma diferença de 30 m em relação as profundidades de amostragens. Já para o ano de 2021, a amostragem de 0-10 cm apresentou um alcance de 45 m e o alcance para a amostragem de 10-20 cm foi de 40,00 m, uma variação entre as profundidades bem menor em relação ao mês de agosto de 2020.

Para a umidade volumétrica no ano de 2020, observou um aumento em relação ao alcance quando comparamos as profundidades de amostragem, sendo o alcance de 35m para a amostragem de 0-10 cm e um alcance de 50 m para a amostragem de 10-20 cm. Para o ano de 2021, o alcance permaneceu o mesmo quando se alterou as profundidades de amostragens (20 m). O potencial hídrico das folhas apresentou um alcance de 15 m tanto para a amostragem em agosto de 2020 e quanto a amostragem

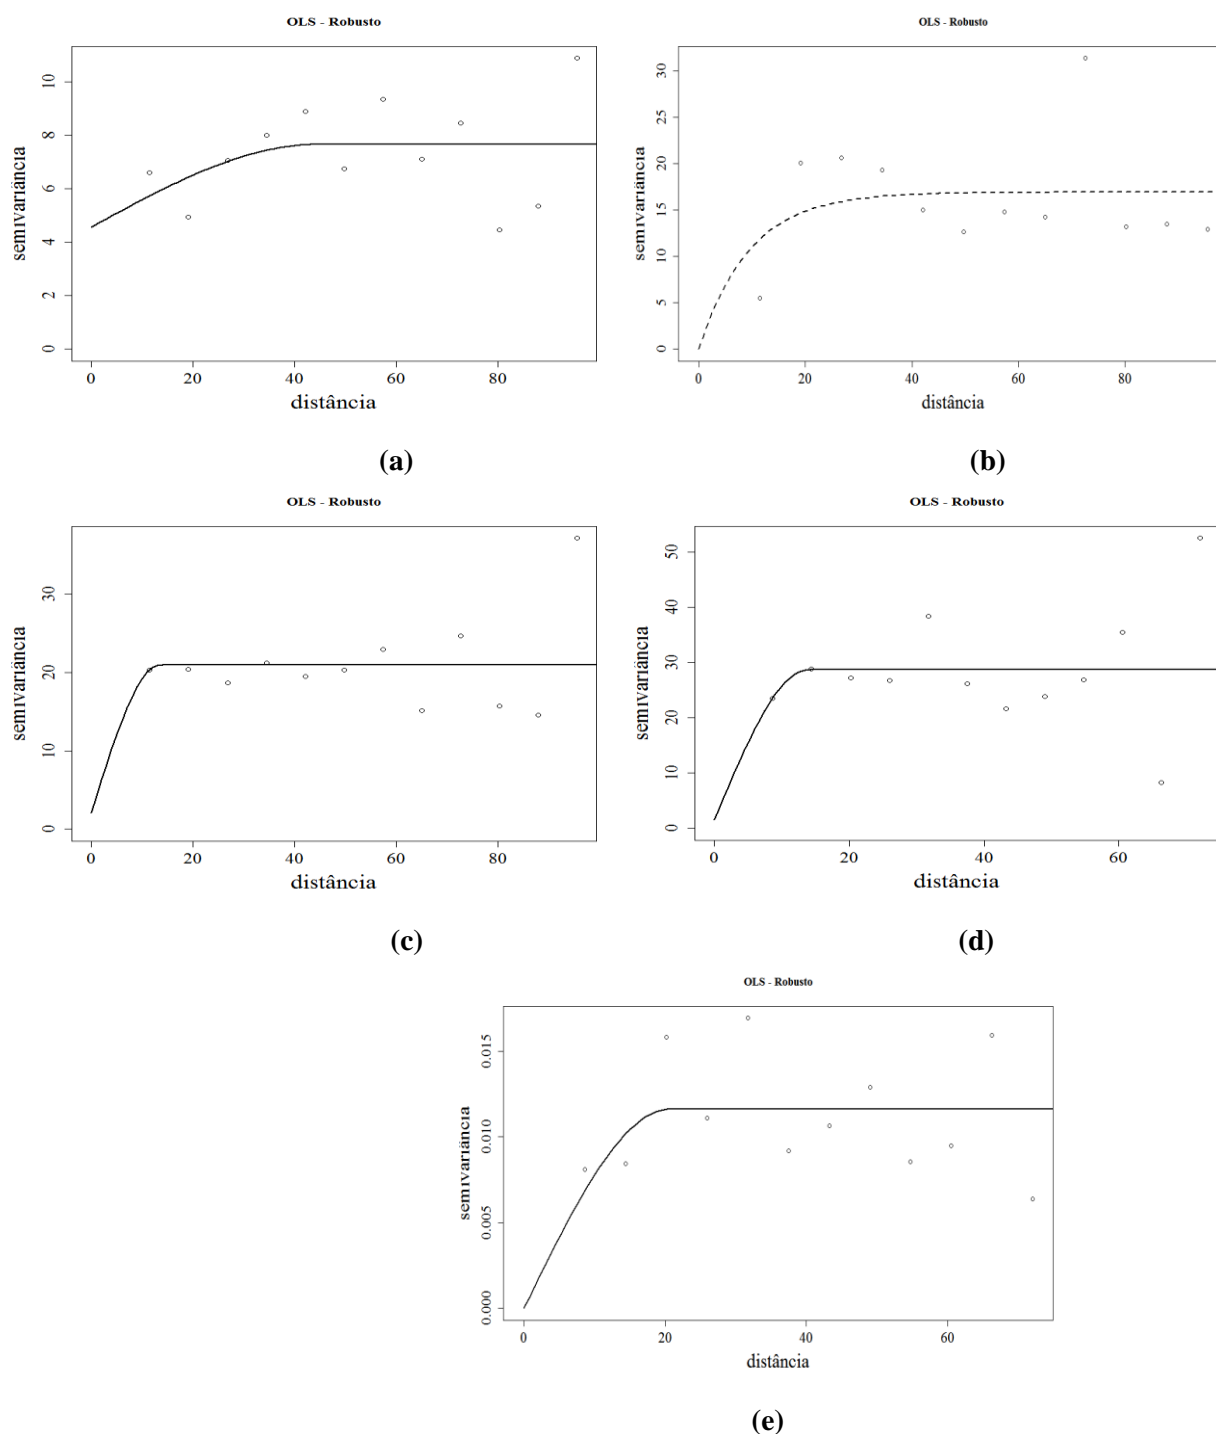
realizada em janeiro de 2021, ou seja, para ambos os períodos de amostragem o  $\Psi_w$  apresentou uma área de influência semelhante.

Figura 6- Semivariogramas ajustados pelos modelos esférico e exponencial para as variáveis (a)  $U_g$  0-10 cm, (b)  $U_g$  10-20 cm, (c)  $U_v$  0-10 cm, (d)  $U_v$  10-20 cm e (e)  $\Psi_w$ , coletados em 2020.



Fonte: Da autora (2021).

Figura 7- Semivariogramas ajustados pelos modelos esférico e exponencial para as variáveis (a) Ug 0-10 cm, (b) Ug 10-20 cm, (c) Uv 0-10 cm, (d) Uv 10-20 cm e (e)  $\Psi_w$ , coletadas em 2021.



Fonte: Da autora (2021).

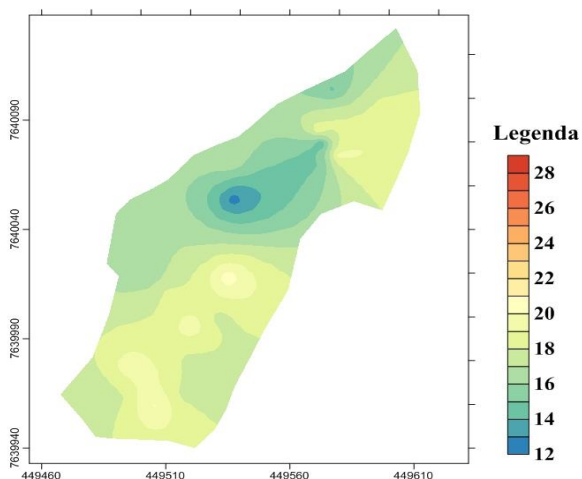
As Figuras 8, 9 e 10 representam os mapas gerados pela krigagem ordinária, observa-se que todos eles apresentam elevada amplitude em seus valores. Essa amplitude demonstra como a adoção da média de observações em campo pode ocasionar erros no manejo como abordado nos trabalhos de Carvalho et al. (2013) e Ferraz et al. (2012). Esse fato reforça a importância da AP no manejo da cafeicultura e o uso de ferramentas estatísticas que considerem relações espaciais existentes.



O mapa de krigagem da umidade gravimétrica amostrada na profundidade de 0-10 cm para o ano de 2020 (Figura 8a) variou de 12 a 20% de umidade e, visualmente, os valores que predominam dentro da área são de 16 a 20% de umidade. Para o ano de 2021, o valor de umidade gravimétrica para a profundidade de 0-10 cm (Figura 8b) variou de 20 a 28%. Já o mapa de umidade gravimétrica amostrado na profundidade de 10-20 cm (Figura 8c), variou de 12 a 18%, onde os valores predominantes de umidade se encontram no intervalo de 12 a 14%. Para o mapa de krigagem da Ug (10-20 cm) para o ano de 2021 (Figura 8d), observou uma variação de 20 a 35% de umidade, onde se predominam valores de umidade acima de 25%.


Figura 8- Mapa de krigagem para as variáveis (a) Ug 0-10 cm 2020, (b) Ug 0-10 cm 2021, (c) Ug 10-20 cm 2020 e (d) Ug 10-20 cm 2021.

### Umidade Gravimétrica 0-10 cm (2020)




(a)

### Umidade Gravimétrica 0-10cm (2021)



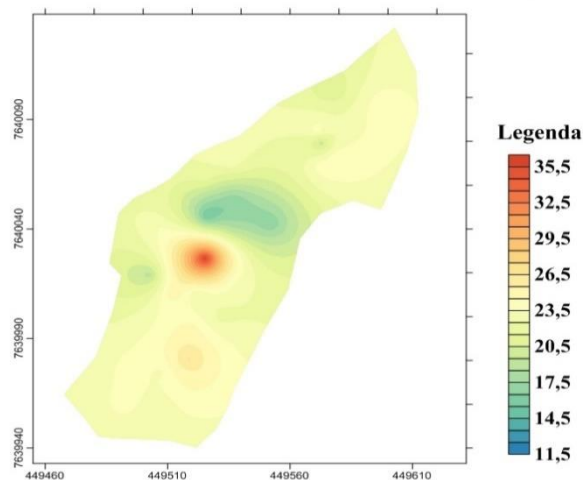
(b)

### Umidade Gravimétrica 10-20 cm (2020)



(c)

### Umidade Gravimétrica 10-20 cm (2021)




(d)

Fonte: Da autora (2021).

Os mapas de krigagem para a umidade volumétrica coletada na profundidade de 0-10 cm (Figura 9a e Figura 9b) variou nos intervalos de 20 a 28% no ano de 2020 e de 30 a 45% no ano de 2021. O que se observa pelo mapa, que os lugares de maiores e menores valores de umidade coincidem, porém de um ano para o outro houve uma tendência de crescimento. Para as amostragens de umidade volumétrica de 10-20 cm (Figura 9c), observa-se que para o ano de 2020 esse atributo variou de 20 a 26% e que os valores predominantes são menores que 20%. A umidade volumétrica (10-20 cm) para ano de 2021 (Figura 9d) variou 25 a 45%, onde os valores predominantes estão acima de 26%.


Figura 9- Mapa de krigagem para as variáveis (a) Uv 0-10 cm 2020, (b) Uv 0-10 cm 2021, (c) Uv 10-20 cm 2020 e (d) Uv 10-20 cm 2021.

### Umidade Volumétrica 0-10 cm (2020)




(a)

### Umidade Volumétrica 0-10 cm (2021)




(b)

### Umidade Volumétrica 10-20 cm (2020)



(c)

### Umidade Volumétrica 10-20 cm (2021)



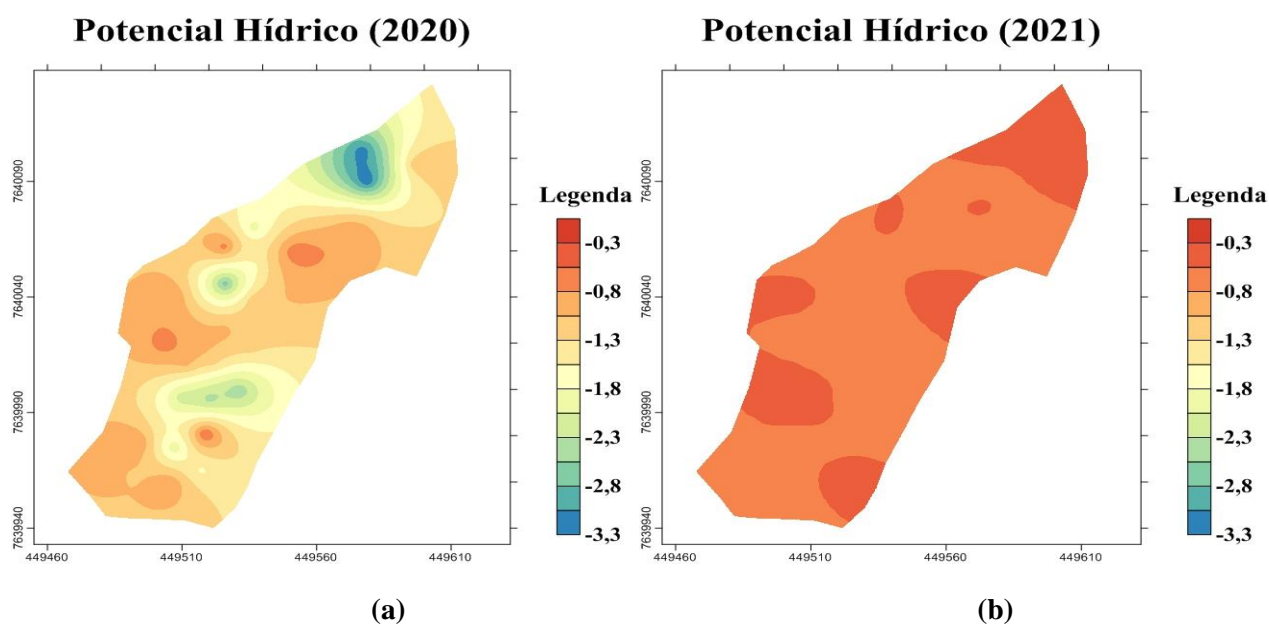
(d)

Fonte: Da autora (2021).

A medida de potencial de água na folha é importante para a determinação do estado hídrico da planta, podendo variar valores próximos de zero, quando as plantas se apresentam sem déficit, a valores bem negativos (-3 MPa a -4,5 MPa), quando as plantas apresentam déficit severo (KRAMER; BOYER, 1995).

O potencial hídrico das folhas para o ano de 2020 (Figura 10a), variou do menor valor de -3,3 MPa ao maior valor de -0,8 MPa, a predominância de potencial hídrico para esse ano está no intervalo compreendido entre -1,8 a -1,1 MPa ( tons de amarelo creme ao laranja claro), sendo parte desses valores concentrados no intervalo de moderada severidade de déficit hídrico, proposto por Silva et al. (2010), já os menores valores compreendidos dentro do intervalo -3,3 a -2,3 estão concentrado no centro-norte da área (tons de azul a verde). Para o ano de 2021, o potencial hídrico das folhas (Figura 10b) variou do menor valor (-0,7 MPa) ao maior valor (-0,1 MPa), que segundo as afirmações de Kramer e Boyer (1995), está dentro do intervalo onde as plantas não estão sofrendo déficit hídrico.

Figura 10- Mapa de krigagem para as variáveis (a)  $\Psi_w$  2020, (b)  $\Psi_w$  2021.




Fonte: Da autora (2021).

### 5.3 Índices de Vegetação


Para a determinar o potencial das imagens de alta resolução capturadas pelo sensor multiespectral acoplado à ARP, calculou diversos índices de vegetação, também foram avaliadas o valor de reflectância das bandas multiespectrais (RED, NIR, RED EDGE e GREEN) afim de averiguar as condições hídricas da lavoura cafeeira.

As Figuras 11a e 11b representam os mosaicos RGB, a partir das imagens coletadas em agosto de 2020 e janeiro de 2021. Observa-se que a lavoura apresenta características visuais bem distintas, sendo que no ano de 2020 apresenta maior presença de poeira sobre o cafeeiro, e no ano de 2021, menor presença.

Figura 11- Mosaico RGB da área de estudo (a) 2020 e (b) 2021.



(a)

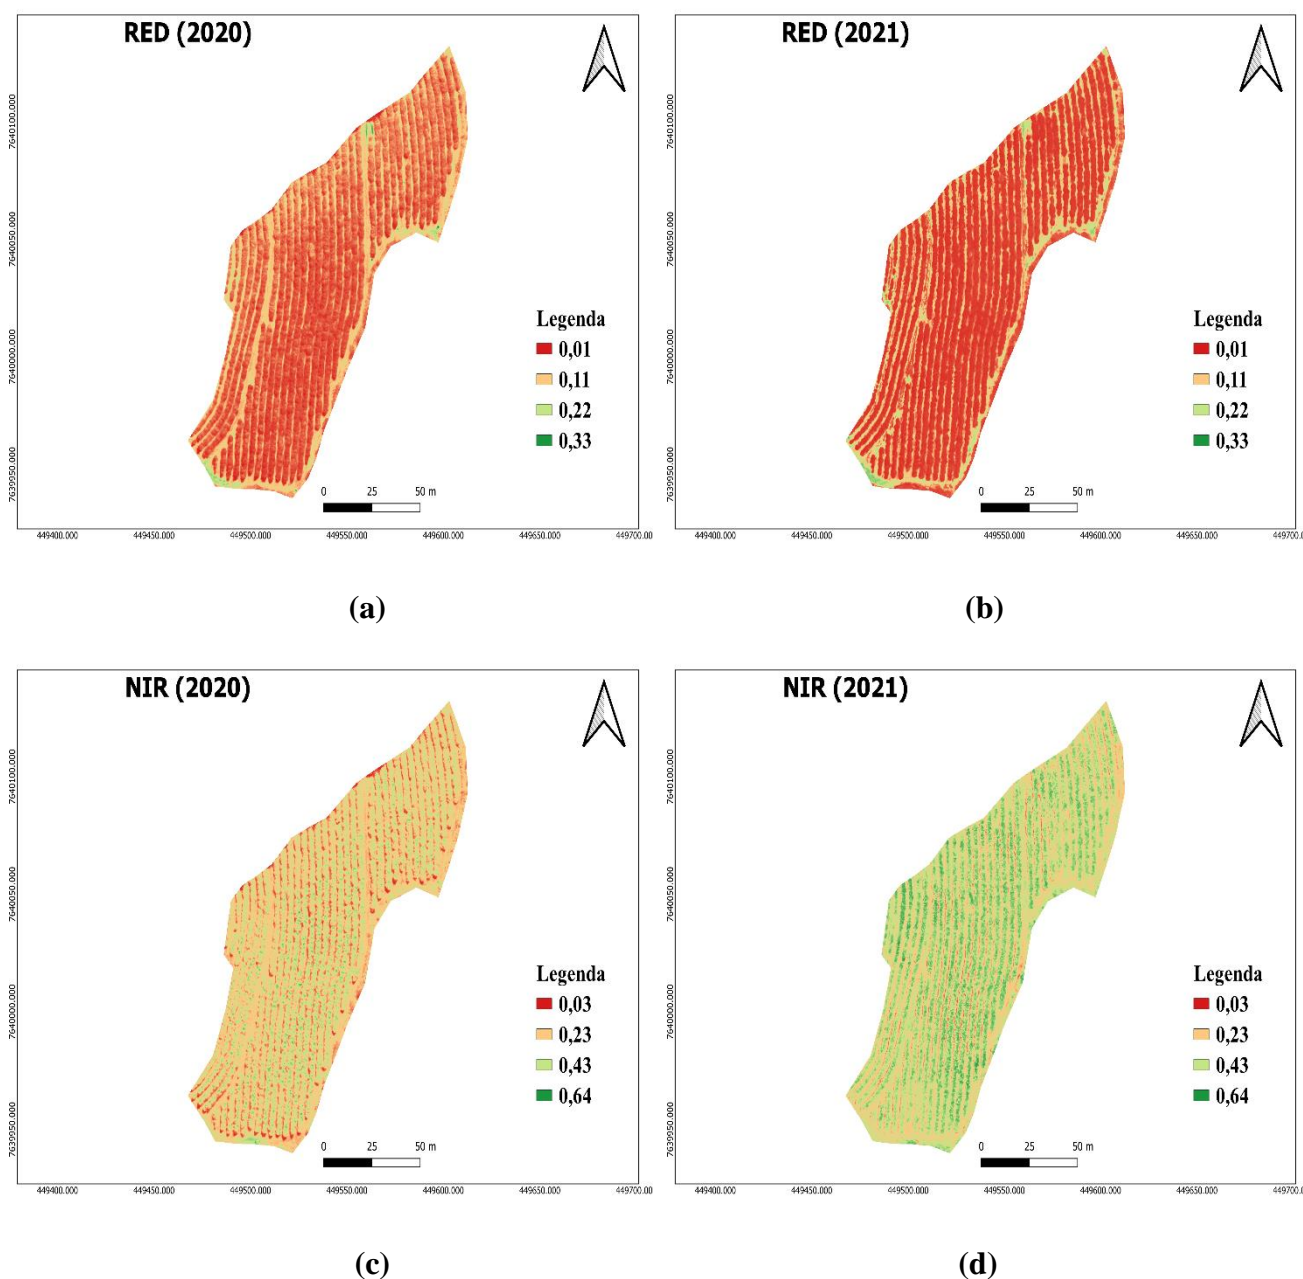


(b)

Fonte: Da autora, 2021.

As Figuras 12a e 12b representam a banda espectral do RED (vermelho), está banda variou de 0,01 a 0,33, elas não apresentaram diferenças significativas visualmente. Já as Figuras 12c e 12d, representam a banda do NIR (infravermelho próximo), enquanto para o ano de 2020 esta banda espectral teve uma maior predominância no intervalo de 0,23 a 0,43 e alguns pontos no intervalo de 0,03, para o ano de 2021 os valores predominantes ficaram na faixa de 0,43 a 0,64.

Figura 12- Bandas espectrais (a) RED 2020, (b) RED 2021, (c) NIR 2020 e (d) NIR 2021.

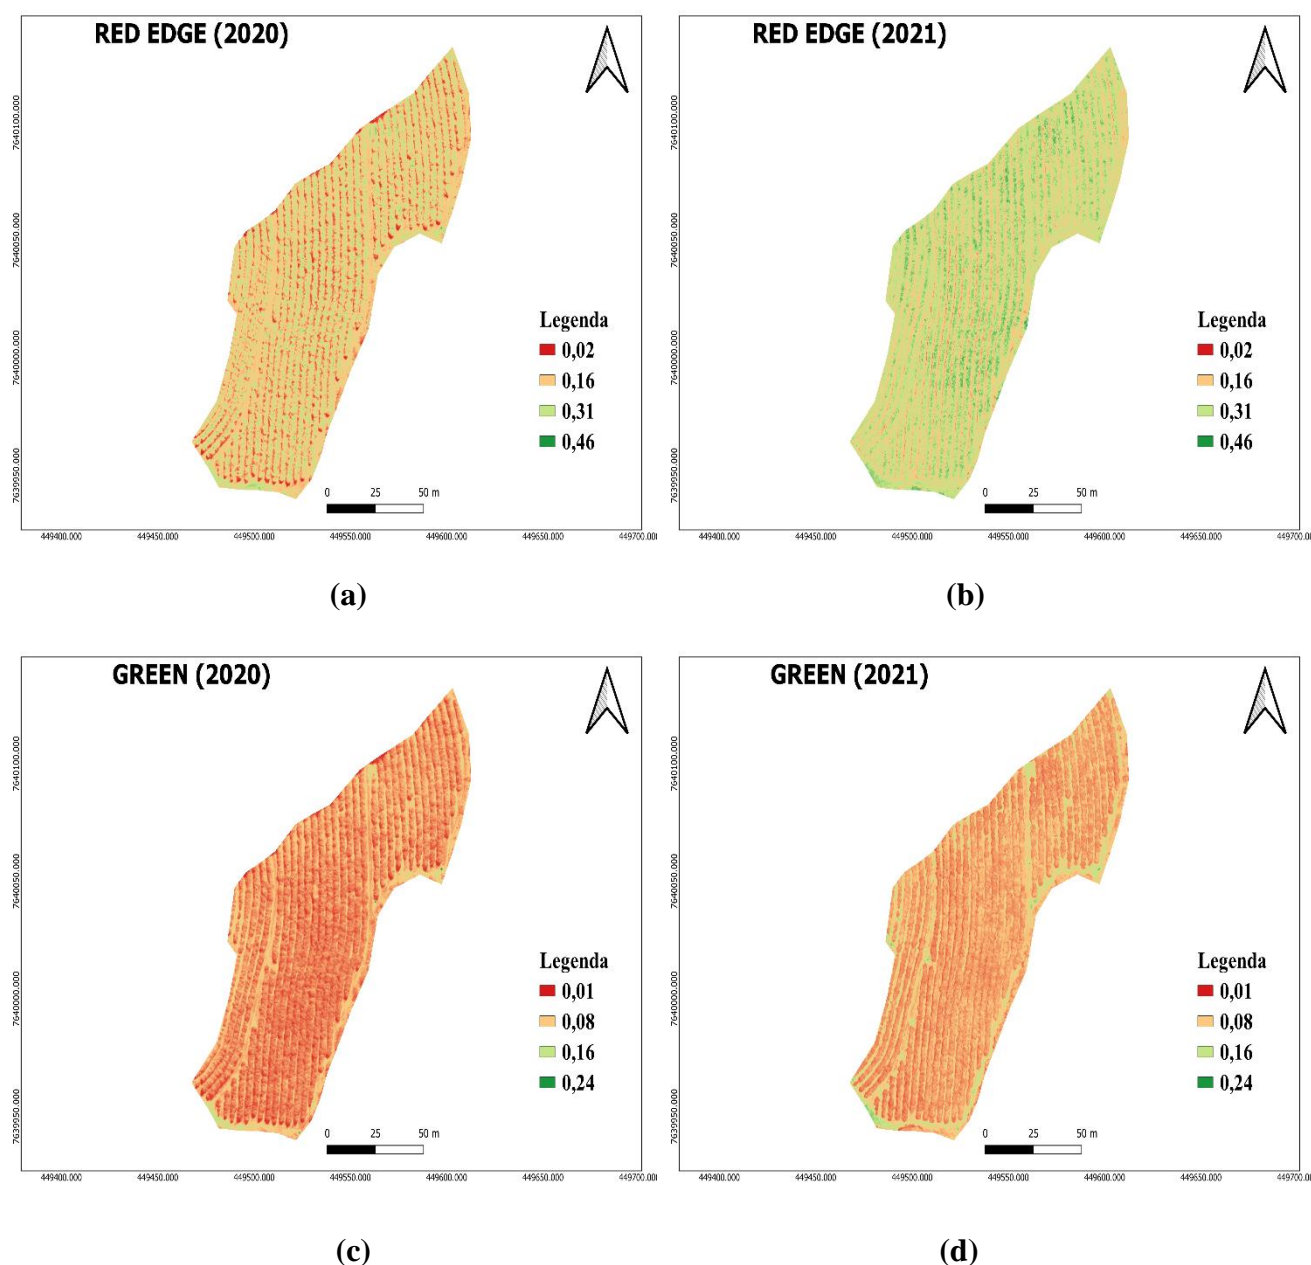


Fonte: Da autora (2021).

As Figuras 13a e 13b representam a banda multiespectral do RED EDGE (borda do vermelho), essa banda variou do menor valor de 0,02 ao maior valor de 0,46 sendo que, para o ano de 2020 ficou

predominantemente dentro do intervalo de 0,02 a 0,16, já para o ano de 2021, a banda espectral ficou dentro do intervalo de 0,31 a 0,46, visualmente essa banda apresenta características distintas para o ano de 2020 e 2021. Em relação as Figuras 13c e 13d que representam a banda espectral do GREEN (verde) observa-se quase a mesmas característica apresentadas nas Figuras 12a e 12b, porém para esta banda espectral o intervalo máximo alcançou até 0,24.

Figura 13- Bandas espectrais (a) RED EDGE 2020, (b) RED EDGE 2021, (c) GREEN 2020 e (d) GREEN 2021.

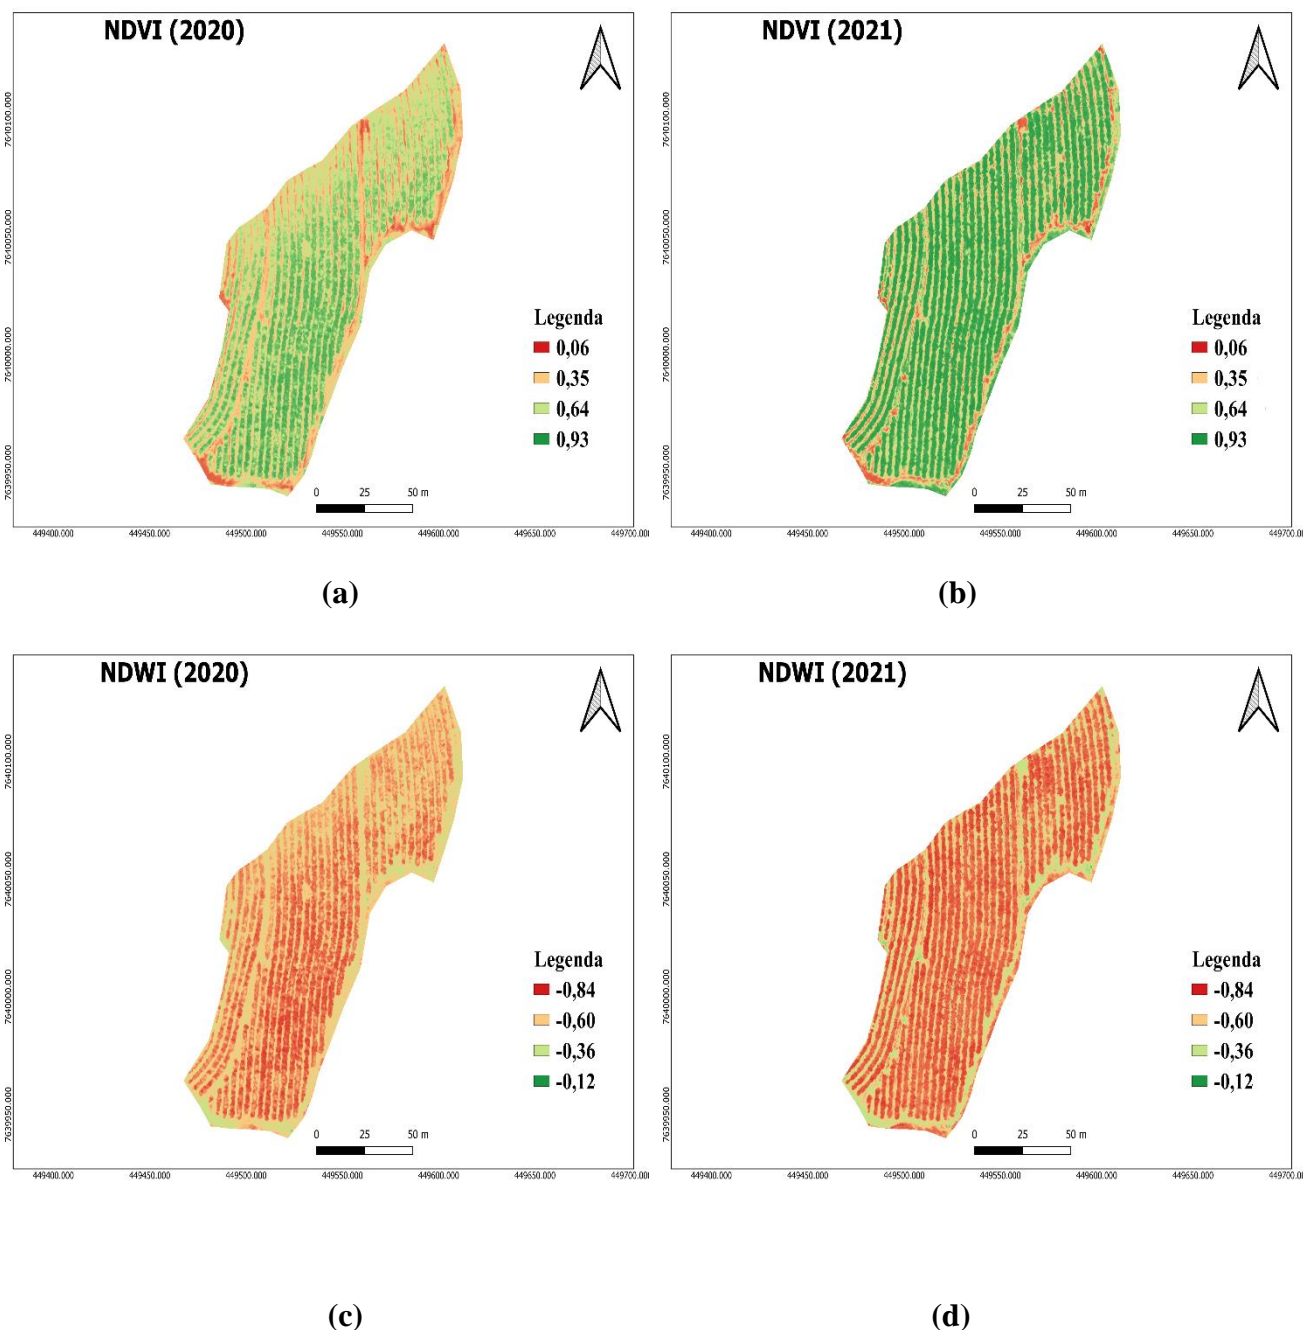


Fonte: Da autora (2021).

As Figuras 14a e 14b representam o índice de vegetação da diferença normalizada, para o ano de 2020, os valores predominantes deste índice estão dentro do intervalo de 0,64 a 0,93, e para o ano de

2021, os valores predominantes estão no intervalo em torno de 0,93 (verde escuro). O índice de vegetação NDWI é representando pelas Figuras 14c e 14d, este índice variou de -0,84 a -0,12, e visualmente não apresentou diferenças significativas.

Figura 14- Índices de vegetação (a) NDVI 2020, (b) NDVI 2021, (c) NDWI 2020 e (d) NDWI 2021.

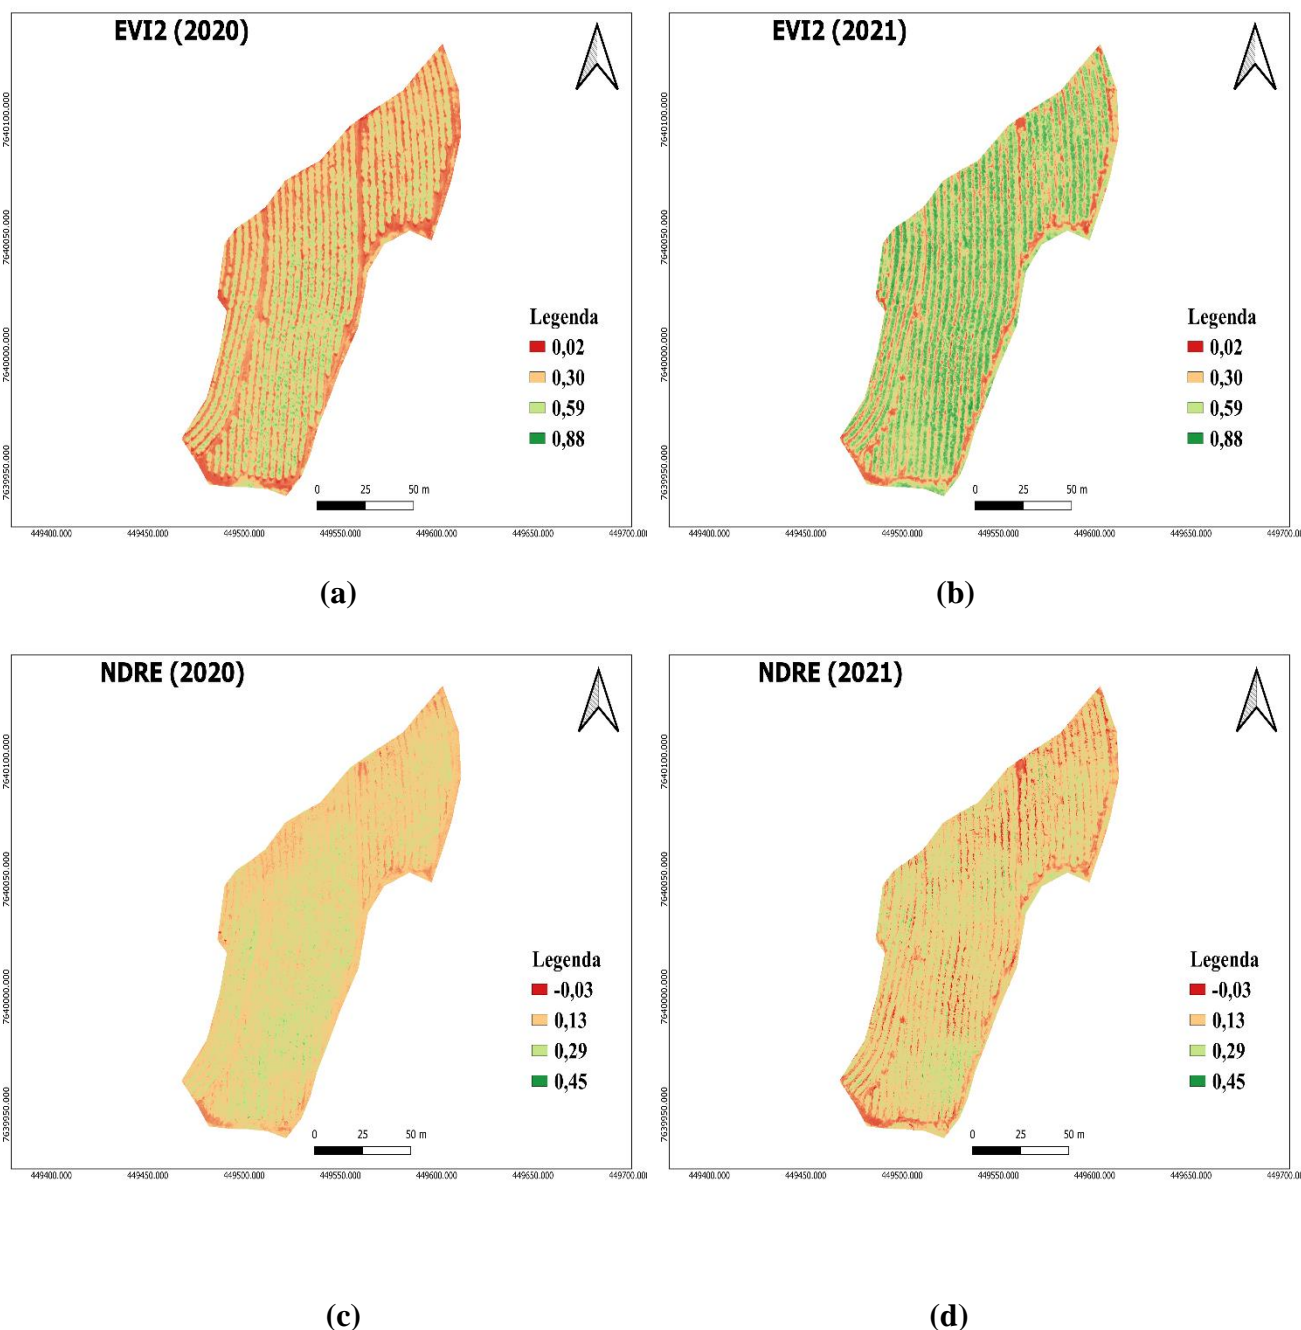


Fonte: Da autora (2021).

O índice EVI2 representado pelas Figuras 15a e 15b obteve características bem diferentes para as imagens de 2020 e 2021. Para o primeiro ano é possível ver que os valores do índice dentro da área predominam no intervalo de 0,02 a 0,59, já para o segundo ano os valores predominantes estão dentro

do intervalo de 0,59 a 0,88. O índice NDRE representando pelas Figuras 15c 15d, apresentaram características de similares, para ambos os anos, o índice variou dentro do intervalo de -0,03 a 0,29, apresentando alguns pontos para o valor de 0,45.

Figura 15- Índices de vegetação (a) EVI2 2020, (b) EVI2 2021, (c) NDRE 2020 e (d) NDRE 2021.



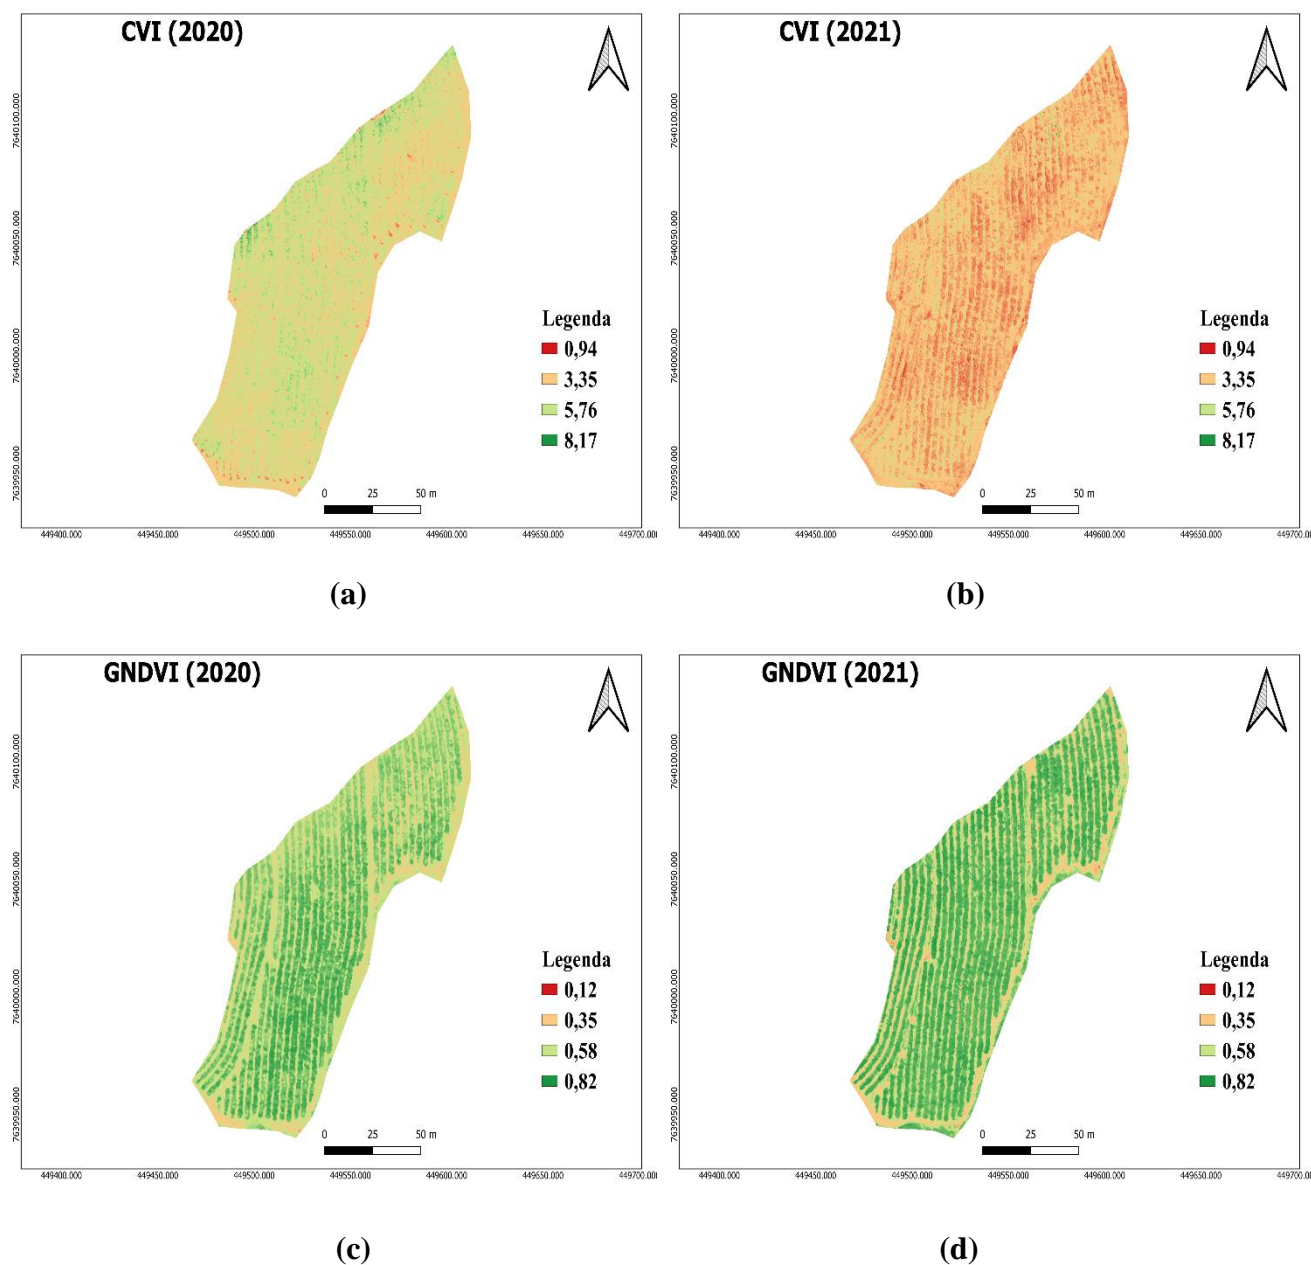
Fonte: Da autora (2021).

As Figuras 16a e 16b representam o índice CVI, para o ano de 2020 seus valores ficaram predominantemente no intervalo de 3,35 a 8,17, já para o ano de 2021 o índice apresentou um menor valor, ficando dentro do intervalo de 0,94 a 3,35. O índice GNDVI (Figuras 16c e 16d) apresentou características similares para ambos os anos, a única diferença que se observa entre 2020 e 2021, é que



para o segundo ano, a borda esquerda da área estava em torno de 0,58, em 2021 esta parte da área foi para o intervalo de 0,82.

Figura 16- Índices de vegetação (a) CVI 2020, (b) CVI 2021, (c) GNDVI 2020 e (d) GNDVI 2021.

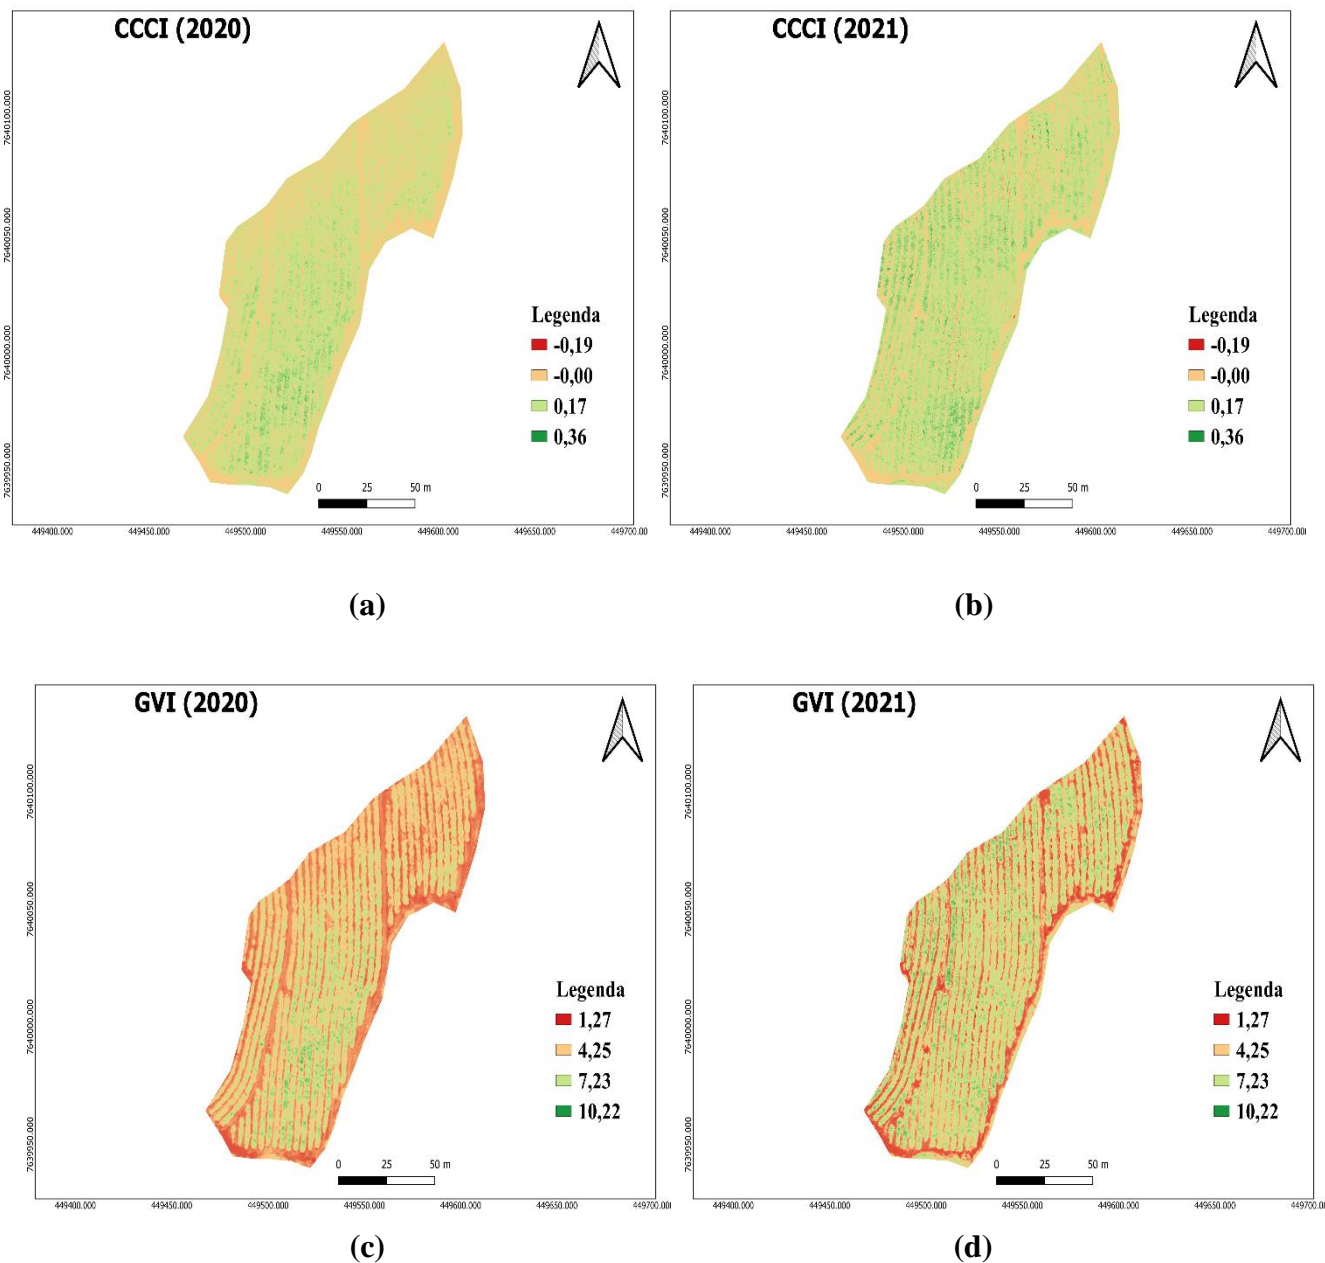


Fonte: Da autora (2021).

Uma característica observada no índice CCCI (Figuras 17a e 17b) é que para ambos os anos de coleta de imagens, estes variaram quase que na mesma proporção, apresentando características muito semelhantes, este índice variou predominantemente no intervalo de 0,00 a 0,17, sendo que em 2021, apresentou alguns pontos dentro do intervalo de 0,36. As Figuras 17c e 17d representam o índice GVI,

para os anos de 2020 e 2021. Para o primeiro ano observa-se uma grande predominância das reflectâncias na faixa de 1,27 a 4,27, já para o segundo ano, essa predominância passa para a faixa de 1,27 a 7,23.

Figura 17- Índices de vegetação (a) CCCI 2020, (b) CCCI 2021, (c) GVI 2020 e (d) GVI 2021.

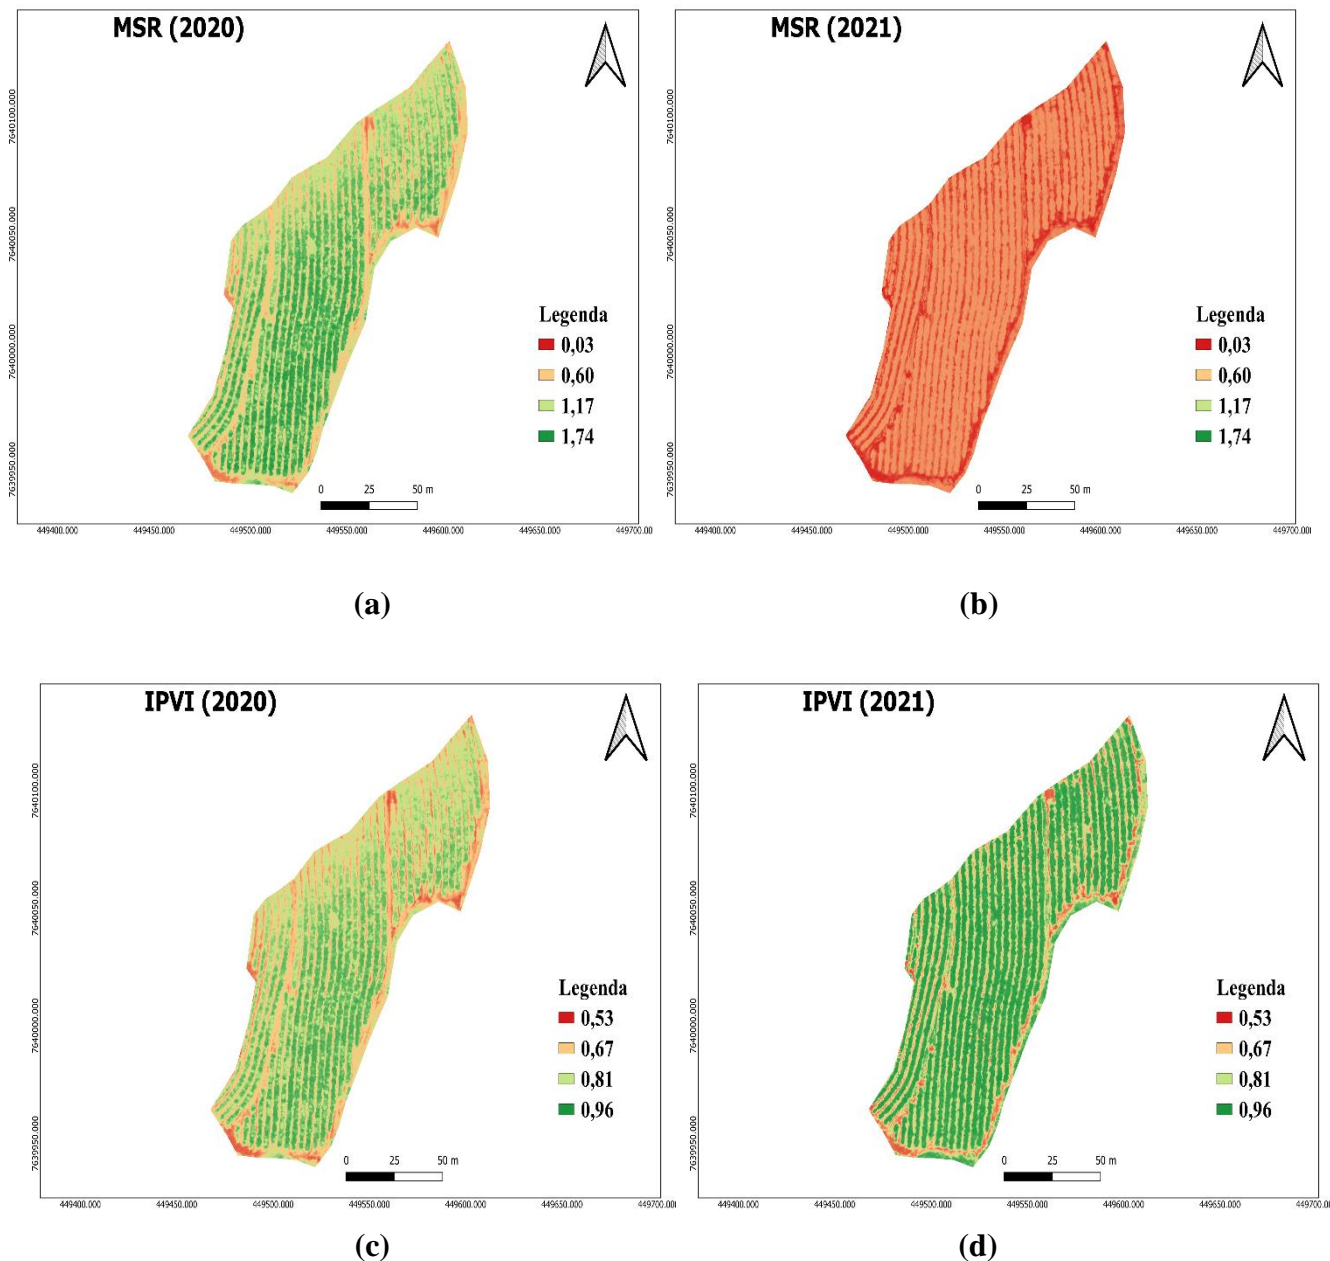


Fonte: Da autora (2021).

O índice MSR, representando pelas Figuras 18a e 18b apresentaram características bem distintas, sendo que para o ano de 2020, observa alguns pontos de 0,03 na borda na área, a ruas com valores de 0,6 (laranja) e as linhas do cafeeiro variando de 1,17 a 1,74. Já para o ano de 2021, as linhas do café ficaram no intervalo de 0,60 e as demais no intervalo de 0,03. As Figuras 18c e 18d representam o índice

IPVI, para o ano de 2020 as linhas de café predominaram na faixa de 0,81 a 0,96, já para o ano de 2021, no período chuvoso, as linhas do cafeeiro predominaram no intervalo de 0,96.

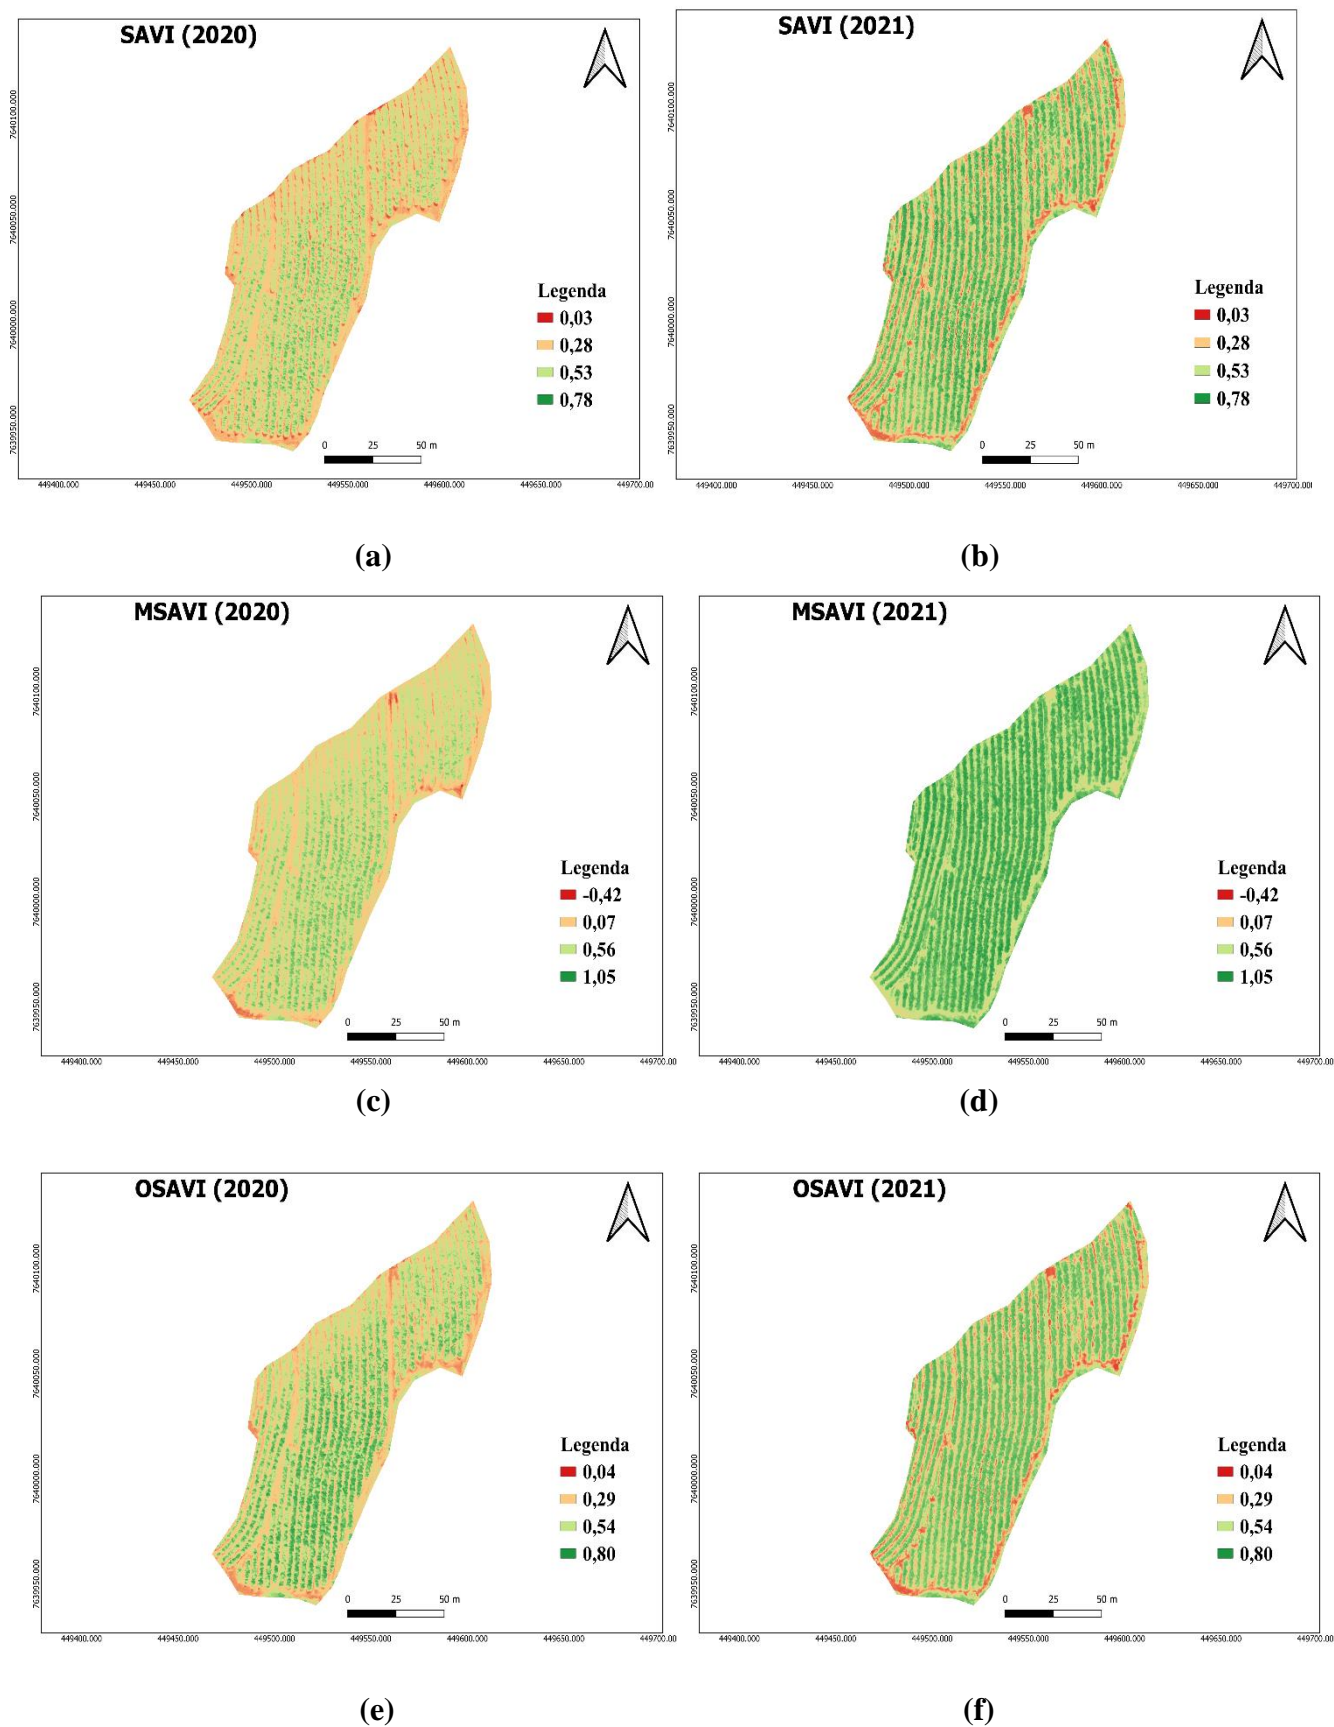
Figura 18- Índices de vegetação (a) MSR 2020, (b) MSR 2021, (c) IPVI 2020 e (d) IPVI 2021.



Fonte: Da autora (2021).

Os índices SAVI (Figuras 19a e 19b), MSAVI (Figuras 19c e 19d) e OSAVI (Figuras 19e e 19f) para os períodos de 2020 e 2021 apesar de variarem em intervalos diferentes, apresentaram características visuais muito semelhantes, para o ano de 2020 os as linhas do cafeeiro apresentaram predominantemente a mesma cor (verde claro) e para o ano de 2021 as linhas do cafeeiro apresentam o maior valor dentro do intervalo de cada índice representado pelo cor verde escuro.

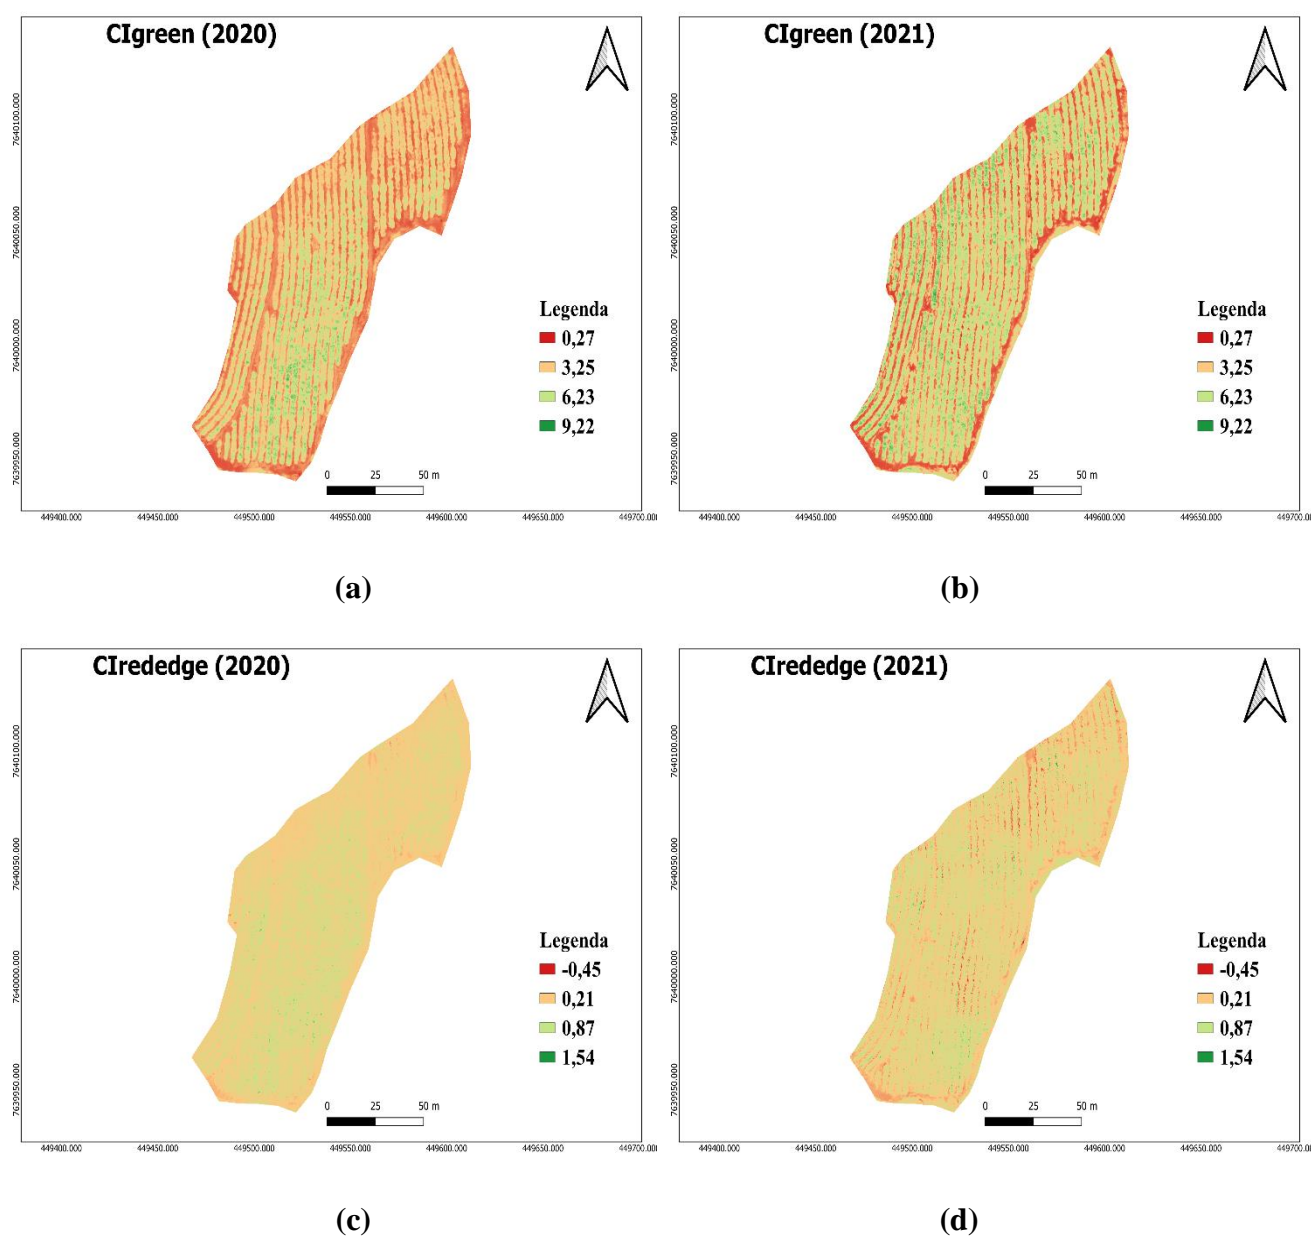
Figura 19- Índices de vegetação (a) SAVI 2020, (b) SAVI 2021, (c) MSAVI 2020 e (d) MSAVI 2021, (e) OSAVI 2020 e (f) OSAVI 2021.



Fonte: Da autora (2021).

O índice de clorofila que avalia o conteúdo total de clorofila das folhas, foi calculado para as bandas do verde CIGreen (Figuras 20a e 20b) e da borda do vermelho CIrededge (Figuras 20c e 20d). Para o CIGreen calculado para o ano de 2020, observa-se uma predominância de valores na faixa de 0,27 a 3,25, apresentando alguns pontos abaixo do centro da área no intervalo de 6,23. Para o ano de 2021 boa parte das linhas do cafeeiro apresentaram valores em torno de 6,23 e as demais áreas estão compreendidas no intervalo de 0,27 a 3,25 desde índice. Assim como alguns índices de vegetação mencionados acima, o índice CIrededge, não apresentou características visuais distintas entre os anos de 2020 e 2021 e para ambos os anos, variam predominantemente na faixa de 0,21 a 0,87.

Figura 20 - Índices de vegetação (a) CIGreen 2020, (b) CIGreen 2021, (c) CIrededge 2020 e (d) CIrededge 2021.



Fonte: Da autora (2021).

## 5.4 Análise de Correlação e Regressão Linear

As respostas morfofisiológicas das plantas em condições de estresse alteram as propriedades ópticas dos cafeeiros e os padrões de refletância das folhas e dosséis. Pesquisadores das áreas de sensoriamento remoto orbital, desenvolveram trabalhos, para avaliar o estresse hídrico na cafeicultura.

Avaliando o monitoramento agrometeorológico de áreas cafeeiras a partir de imagens do sensor MODIS, do satélite Terra, Volpato et al. (2013) observaram boa correlação entre NDVI e o déficit hídrico em áreas cafeeiras na região de Três Pontas, MG.

Identificando as variáveis do balanço hídrico e sua relação entre índices de vegetação em cafeicultura, Volpato et al. (2019) avaliaram os índices de vegetação NDVI e o EVI. Os autores afirmam que as relações entre variáveis do balanço hídrico climatológico e os índices de vegetação foram verificadas, porém com fraca correlação estatística.

Objetivando estimar o potencial hídrico da folha através da avaliação de índices de vegetação, Maciel et al. (2020) afirmam que um algoritmo quadrático que usa o Índice de Vegetação por Diferença Normalizada (NDVI) teve melhor desempenho, apresentando um coeficiente de correlação ( $R^2$ ) de 0,82.

Os autores Bacsa et al. (2019) afirmam que os setores agrícola têm utilizado amplamente as ARP's para conveniência e eficiência da detecção do estresse hídrico ( GAGO et al., 2015; NHAMO et al., 2020; ZHANG et al., 2019 e HOFFMANN et al., 2016).

Avaliando a aplicação de diferentes tipos de ARP's e diferentes sensores remotos e comparando seu desempenho com verdade de campo Gago et al. (2015) utilizaram os índices NDVI, TCARI/OSAVI e PRI, onde os resultados mostraram correlações positivas relacionadas ao estresse hídrico.

Os autores Nhamo et al. (2020) desenvolveram uma revisão para destacar o uso do NDVI na avaliação da saúde da cultura, evapotranspiração, estresse hídrico e redução dos riscos de desastres.

Pelos resultados mencionados acima, afirmam que o uso de imagens de alta resolução, com aplicação à índices de vegetação são uma ferramenta valiosa para avaliar estresse hídrico em culturas, porém nenhuma pesquisa avalia essa deficiência hídrica na cultura no café.

As Tabelas 7 e 8 representam a análise de correlação de Person entre a média de amostras coletadas da vegetação e do solo, retiradas a partir dos índices de vegetação calculados e as bandas multiespectrais (RED, NIR, RED EDGE e GREEN) em relação aos dados coletados em campo, para o ano de 2020 e 2021. Realizou-se um teste F de hipóteses para avaliar a significância da correlação a um nível de 0,05 (5%).

Tabela 7 - Análise de Correlação os índices de vegetação coletados a partir da vegetação e do solo, com as variáveis em estudo para o ano de 2020.

	Índices	Variáveis						Índices	Variáveis				
		Ug (0-10 cm)	Ug (10-20 cm)	Uv (0-10 cm)	Uv (10-20 cm)	Ψw (MPa)			Ug (0-10 cm)	Ug (10-20 cm)	Uv (0-10 cm)	Uv (10-20 cm)	Ψw (MPa)
VEGETAÇÃO	RED	0,3005 <sup>ns</sup>	0,1235 <sup>ns</sup>	0,4637 <sup>**</sup>	0,2668 <sup>ns</sup>	0,3188 <sup>ns</sup>	SOLO	RED	0,1888 <sup>ns</sup>	0,0355 <sup>ns</sup>	0,1982 <sup>ns</sup>	0,1027 <sup>ns</sup>	0,1249 <sup>ns</sup>
	NIR	0,1991 <sup>ns</sup>	0,0938 <sup>ns</sup>	0,2213 <sup>ns</sup>	0,2210 <sup>ns</sup>	0,0489 <sup>ns</sup>		NIR	0,0546 <sup>ns</sup>	0,1288 <sup>ns</sup>	0,0077 <sup>ns</sup>	0,0308 <sup>ns</sup>	0,1904 <sup>ns</sup>
	REDEDGE	0,1782 <sup>ns</sup>	0,0355 <sup>ns</sup>	0,2608 <sup>ns</sup>	0,2289 <sup>ns</sup>	0,1921 <sup>ns</sup>		REDEDGE	0,0228 <sup>ns</sup>	0,0991 <sup>ns</sup>	0,0343 <sup>ns</sup>	0,0089 <sup>ns</sup>	0,1608 <sup>ns</sup>
	GREEN	0,2840 <sup>ns</sup>	0,1093 <sup>ns</sup>	0,5157 <sup>**</sup>	0,3601 <sup>ns</sup>	0,2852 <sup>ns</sup>		GREEN	0,1514 <sup>ns</sup>	0,1663 <sup>ns</sup>	0,1773 <sup>ns</sup>	0,0992 <sup>ns</sup>	0,1083 <sup>ns</sup>
	NDVI	0,1328 <sup>ns</sup>	0,0463 <sup>ns</sup>	0,2421 <sup>ns</sup>	0,0871 <sup>ns</sup>	0,1768 <sup>ns</sup>		NDVI	0,2860 <sup>ns</sup>	0,1335 <sup>ns</sup>	0,2602 <sup>ns</sup>	0,1392 <sup>ns</sup>	0,0118 <sup>ns</sup>
	NDWI	0,0129 <sup>ns</sup>	0,0299 <sup>ns</sup>	0,1079 <sup>ns</sup>	0,0011 <sup>ns</sup>	0,0905 <sup>ns</sup>		NDWI	0,2704 <sup>ns</sup>	0,1376 <sup>ns</sup>	0,2597 <sup>ns</sup>	0,1616 <sup>ns</sup>	0,0400 <sup>ns</sup>
	EVI2	0,0627 <sup>ns</sup>	0,0375 <sup>ns</sup>	0,0177 <sup>ns</sup>	0,0950 <sup>ns</sup>	0,0663 <sup>ns</sup>		EVI2	0,3557 <sup>ns</sup>	0,2072 <sup>ns</sup>	0,3168 <sup>ns</sup>	0,1867 <sup>ns</sup>	0,0322 <sup>ns</sup>
	NDRE	0,1202 <sup>ns</sup>	0,1854 <sup>ns</sup>	0,0156 <sup>ns</sup>	0,0786 <sup>ns</sup>	0,2870 <sup>ns</sup>		NDRE	0,0481 <sup>ns</sup>	0,0233 <sup>ns</sup>	0,1085 <sup>ns</sup>	0,1087 <sup>ns</sup>	0,0276 <sup>ns</sup>
	CVI	0,4363 <sup>**</sup>	0,2487 <sup>ns</sup>	0,3791 <sup>**</sup>	0,2602 <sup>ns</sup>	0,1742 <sup>ns</sup>		CVI	0,1734 <sup>ns</sup>	0,1198 <sup>ns</sup>	0,1942 <sup>ns</sup>	0,1764 <sup>ns</sup>	0,1859 <sup>ns</sup>
	GNDVI	0,0129 <sup>ns</sup>	0,0299 <sup>ns</sup>	0,1079 <sup>ns</sup>	0,0011 <sup>ns</sup>	0,0905 <sup>ns</sup>		GNDVI	0,2704 <sup>ns</sup>	0,1376 <sup>ns</sup>	0,2597 <sup>ns</sup>	0,1616 <sup>ns</sup>	0,0400 <sup>ns</sup>
	CCCI	0,0431 <sup>ns</sup>	0,1035 <sup>ns</sup>	0,0881 <sup>ns</sup>	0,0302 <sup>ns</sup>	0,2451 <sup>ns</sup>		CCCI	0,2235 <sup>ns</sup>	0,3361 <sup>ns</sup>	0,2262 <sup>ns</sup>	0,2187 <sup>ns</sup>	0,1739 <sup>ns</sup>
	GVI	0,0409 <sup>ns</sup>	0,0287 <sup>ns</sup>	0,0833 <sup>ns</sup>	0,0129 <sup>ns</sup>	0,1113 <sup>ns</sup>		GVI	0,2837 <sup>ns</sup>	0,1429 <sup>ns</sup>	0,2819 <sup>ns</sup>	0,1384 <sup>ns</sup>	0,0992 <sup>ns</sup>
	MSR	0,1328 <sup>ns</sup>	0,0463 <sup>ns</sup>	0,2421 <sup>ns</sup>	0,0871 <sup>ns</sup>	0,1768 <sup>ns</sup>		MSR	0,2860 <sup>ns</sup>	0,1335 <sup>ns</sup>	0,2602 <sup>ns</sup>	0,1392 <sup>ns</sup>	0,0118 <sup>ns</sup>
	IPVI	0,1328 <sup>ns</sup>	0,0463 <sup>ns</sup>	0,2421 <sup>ns</sup>	0,0871 <sup>ns</sup>	0,1768 <sup>ns</sup>		IPVI	0,2860 <sup>ns</sup>	0,1335 <sup>ns</sup>	0,2602 <sup>ns</sup>	0,1392 <sup>ns</sup>	0,0118 <sup>ns</sup>
	SAVI	0,0827 <sup>ns</sup>	0,0480 <sup>ns</sup>	0,0457 <sup>ns</sup>	0,1171 <sup>ns</sup>	0,0442 <sup>ns</sup>		SAVI	0,3613 <sup>**</sup>	0,2327 <sup>ns</sup>	0,3110 <sup>ns</sup>	0,1945 <sup>ns</sup>	0,0751 <sup>ns</sup>
	MSAVI	0,0158 <sup>ns</sup>	0,0200 <sup>ns</sup>	0,0490 <sup>ns</sup>	0,0536 <sup>ns</sup>	0,1012 <sup>ns</sup>		MSAVI	0,3087 <sup>ns</sup>	0,1378 <sup>ns</sup>	0,2915 <sup>ns</sup>	0,1722 <sup>ns</sup>	0,0586 <sup>ns</sup>
	OSAVI	0,0076 <sup>ns</sup>	0,0098 <sup>ns</sup>	0,0799 <sup>ns</sup>	0,0331 <sup>ns</sup>	0,1035 <sup>ns</sup>		OSAVI	0,3312 <sup>ns</sup>	0,1773 <sup>ns</sup>	0,2972 <sup>ns</sup>	0,1704 <sup>ns</sup>	0,0128 <sup>ns</sup>
	CIgreen	0,0409 <sup>ns</sup>	0,0287 <sup>ns</sup>	0,0833 <sup>ns</sup>	0,0129 <sup>ns</sup>	0,1113 <sup>ns</sup>		CIgreen	0,2837 <sup>ns</sup>	0,1429 <sup>ns</sup>	0,2819 <sup>ns</sup>	0,1384 <sup>ns</sup>	0,0092 <sup>ns</sup>
	CIrededge	0,1360 <sup>ns</sup>	0,1941 <sup>ns</sup>	0,0005 <sup>ns</sup>	0,0908 <sup>ns</sup>	0,2906 <sup>ns</sup>		CIrededge	0,0463 <sup>ns</sup>	0,0277 <sup>ns</sup>	0,1090 <sup>ns</sup>	0,1159 <sup>ns</sup>	0,0305 <sup>ns</sup>

Ug- umidade gravimétrica, Uv- umidade volumétrica, Ψw- potencial hídrico, \*\*- significativo ao nível de 5% de probabilidade (p<0,05); ns- não significativo (p>0,05)

Tabela 8 - Análise de Correlação os índices de vegetação coletados a partir da vegetação e do solo, com as variáveis em estudo para o ano de 2021.

	Índices	Variáveis						Índices	Variáveis				
		Ug (0-10 cm)	Ug (10-20 cm)	Uv (0-10 cm)	Uv (10-20 cm)	Ψw (MPa)			Ug (0-10 cm)	Ug (10-20 cm)	Uv (0-10 cm)	Uv (10-20 cm)	Ψw (MPa)
VEGETAÇÃO	RED	0,2767 <sup>ns</sup>	0,2781 <sup>ns</sup>	0,4163 <sup>**</sup>	0,4368 <sup>**</sup>	0,3993 <sup>**</sup>	SOLO	RED	0,1078 <sup>ns</sup>	0,1649 <sup>ns</sup>	0,0228 <sup>ns</sup>	0,1931 <sup>ns</sup>	0,1998 <sup>ns</sup>
	NIR	0,0185 <sup>ns</sup>	0,0110 <sup>ns</sup>	0,1155 <sup>ns</sup>	0,1020 <sup>ns</sup>	0,1220 <sup>ns</sup>		NIR	0,1705 <sup>ns</sup>	0,1083 <sup>ns</sup>	0,0917 <sup>ns</sup>	0,0804 <sup>ns</sup>	0,3619 <sup>**</sup>
	REDEGE	0,0878 <sup>ns</sup>	0,1732 <sup>ns</sup>	0,0506 <sup>ns</sup>	0,0197 <sup>ns</sup>	0,0493 <sup>ns</sup>		REDEGE	0,1398 <sup>ns</sup>	0,0338 <sup>ns</sup>	0,0194 <sup>ns</sup>	0,1394 <sup>ns</sup>	0,1065 <sup>ns</sup>
	GREEN	0,0618 <sup>ns</sup>	0,3141 <sup>ns</sup>	0,1692 <sup>ns</sup>	0,2597 <sup>ns</sup>	0,1424 <sup>ns</sup>		GREEN	0,0495 <sup>ns</sup>	0,1238 <sup>ns</sup>	0,0212 <sup>ns</sup>	0,1173 <sup>ns</sup>	0,1405 <sup>ns</sup>
	NDVI	0,1791 <sup>ns</sup>	0,1604 <sup>ns</sup>	0,3275 <sup>ns</sup>	0,3329 <sup>ns</sup>	0,3010 <sup>ns</sup>		NDVI	0,2079 <sup>ns</sup>	0,3191 <sup>ns</sup>	0,0077 <sup>ns</sup>	0,2297 <sup>ns</sup>	0,3065 <sup>ns</sup>
	NDWI	0,0841 <sup>ns</sup>	0,2558 <sup>ns</sup>	0,2815 <sup>ns</sup>	0,3418 <sup>ns</sup>	0,2620 <sup>ns</sup>		NDWI	0,2045 <sup>ns</sup>	0,0502 <sup>ns</sup>	0,0401 <sup>ns</sup>	0,1576 <sup>ns</sup>	0,3693 <sup>**</sup>
	EVI2	0,0584 <sup>ns</sup>	0,0330 <sup>ns</sup>	0,1738 <sup>ns</sup>	0,1652 <sup>ns</sup>	0,1663 <sup>ns</sup>		EVI2	0,1832 <sup>ns</sup>	0,0521 <sup>ns</sup>	0,0336 <sup>ns</sup>	0,1966 <sup>ns</sup>	0,3555 <sup>ns</sup>
	NDRE	0,0853 <sup>ns</sup>	0,2312 <sup>ns</sup>	0,1809 <sup>ns</sup>	0,2458 <sup>ns</sup>	0,3263 <sup>ns</sup>		NDRE	0,1097 <sup>ns</sup>	0,2296 <sup>ns</sup>	0,1771 <sup>ns</sup>	0,0646 <sup>ns</sup>	0,4707 <sup>**</sup>
	CVI	0,0277 <sup>ns</sup>	0,2798 <sup>ns</sup>	0,1283 <sup>ns</sup>	0,2195 <sup>ns</sup>	0,0865 <sup>ns</sup>		CVI	0,0740 <sup>ns</sup>	0,2674 <sup>ns</sup>	0,1383 <sup>ns</sup>	0,2664 <sup>ns</sup>	0,3240 <sup>ns</sup>
	GNDVI	0,0841 <sup>ns</sup>	0,2558 <sup>ns</sup>	0,2815 <sup>ns</sup>	0,3418 <sup>ns</sup>	0,2620 <sup>ns</sup>		GNDVI	0,2045 <sup>ns</sup>	0,0502 <sup>ns</sup>	0,0401 <sup>ns</sup>	0,1576 <sup>ns</sup>	0,3693 <sup>**</sup>
	CCCI	0,0277 <sup>ns</sup>	0,0325 <sup>ns</sup>	0,1454 <sup>ns</sup>	0,2664 <sup>ns</sup>	0,3356 <sup>ns</sup>		CCCI	0,1220 <sup>ns</sup>	0,0867 <sup>ns</sup>	0,0976 <sup>ns</sup>	0,1454 <sup>ns</sup>	0,0637 <sup>ns</sup>
	GVI	0,1141 <sup>ns</sup>	0,2642 <sup>ns</sup>	0,3033 <sup>ns</sup>	0,3587 <sup>ns</sup>	0,2691 <sup>ns</sup>		GVI	0,0752 <sup>ns</sup>	0,0321 <sup>ns</sup>	0,0022 <sup>ns</sup>	0,1607 <sup>ns</sup>	0,2840 <sup>ns</sup>
	MSR	0,1791 <sup>ns</sup>	0,1604 <sup>ns</sup>	0,3275 <sup>ns</sup>	0,3329 <sup>ns</sup>	0,3010 <sup>ns</sup>		MSR	0,2079 <sup>ns</sup>	0,1391 <sup>ns</sup>	0,0077 <sup>ns</sup>	0,2297 <sup>ns</sup>	0,3065 <sup>ns</sup>
	IPVI	0,1791 <sup>ns</sup>	0,1604 <sup>ns</sup>	0,3275 <sup>ns</sup>	0,3329 <sup>ns</sup>	0,0996 <sup>ns</sup>		IPVI	0,2079 <sup>ns</sup>	0,1391 <sup>ns</sup>	0,0077 <sup>ns</sup>	0,2297 <sup>ns</sup>	0,3065 <sup>ns</sup>
	SAVI	0,0655 <sup>ns</sup>	0,0411 <sup>ns</sup>	0,1848 <sup>ns</sup>	0,1774 <sup>ns</sup>	0,1710 <sup>ns</sup>		SAVI	0,2023 <sup>ns</sup>	0,0604 <sup>ns</sup>	0,0368 <sup>ns</sup>	0,1983 <sup>ns</sup>	0,3656 <sup>**</sup>
	MSAVI	0,0542 <sup>ns</sup>	0,0301 <sup>ns</sup>	0,1696 <sup>ns</sup>	0,1613 <sup>ns</sup>	0,1576 <sup>ns</sup>		MSAVI	0,1957 <sup>ns</sup>	0,0426 <sup>ns</sup>	0,0441 <sup>ns</sup>	0,1857 <sup>ns</sup>	0,3720 <sup>**</sup>
	OSAVI	0,1002 <sup>ns</sup>	0,0778 <sup>ns</sup>	0,2321 <sup>ns</sup>	0,2287 <sup>ns</sup>	0,2090 <sup>ns</sup>		OSAVI	0,2065 <sup>ns</sup>	0,0985 <sup>ns</sup>	0,0225 <sup>ns</sup>	0,2153 <sup>ns</sup>	0,3409 <sup>ns</sup>
	CIgreen	0,1141 <sup>ns</sup>	0,2642 <sup>ns</sup>	0,3033 <sup>ns</sup>	0,3587 <sup>ns</sup>	0,2691 <sup>ns</sup>		CIgreen	0,0752 <sup>ns</sup>	0,0321 <sup>ns</sup>	0,0022 <sup>ns</sup>	0,1607 <sup>ns</sup>	0,2840 <sup>ns</sup>
CIrededge	0,0876 <sup>ns</sup>	0,2377 <sup>ns</sup>	0,1751 <sup>ns</sup>	0,2424 <sup>ns</sup>	0,3313 <sup>ns</sup>	CIrededge	0,2383 <sup>ns</sup>	0,2383 <sup>ns</sup>	0,1039 <sup>ns</sup>	0,0792 <sup>ns</sup>	0,4445 <sup>**</sup>		

Ug- umidade gravimétrica, Uv- umidade volumétrica, Ψw- potencial hídrico, \*\*- significativo ao nível de 5% de probabilidade (p<0,05); ns- não significativo (p>0,05)



No ano de 2020, para as amostras de vegetação e pelo teste F de hipóteses, foram encontradas correlações significativas para a Ug(0-10 cm) com o índice CVI (43,63%) e para Uv(0-10 cm) com os índices RED (46,37%), GREEN (51,57) e CVI (37,91%). Já para as amostras de solo, estas obtiveram significância de correlação apenas para o atributo Ug (0-10 cm) com o índice SAVI (36,13%).

Para o ano de 2021 avaliando as amostras de índices coletadas para a vegetação, observa-se que a Uv (0-10 cm) correlacionou-se significativamente com a banda espectral RED (41,63%), a Uv (10-20 cm) com o RED (43,68%) e o potencial hídrico com o RED (39,93%). As amostras de solo retiradas a partir dos índices de vegetação para o ano de 2021, obtiveram significância de correlação apenas para a variável potencial hídrico com os índices NIR (36,19%), NDWI (36,93%), NDRE (47,07%), GNDVI (36,93%), SAVI (36,56%), MSAVI (37,20%), CIrededge (44,45%).

A correlação que apresentou o maior valor, foi para o ano de 2020, entre a variável Uv (0-10 cm) e a banda espectral GREEN (51,57%) que segundo as contribuições de Rodrigues et al. (2012) apresenta-se como correlação moderada.

As amostras de vegetação para o ano de 2021 coletadas a partir da banda espectral RED, mostrou correlação significativa entre as variáveis Uv 0-10cm (46,37%), Uv 10-20cm (43,68%) e potencial hídrico (39,93%).

Observa-se também, que variável umidade volumétrica para o ano de 2021 correlacionou-se significativamente com as amostras de vegetação da banda espectral RED nas profundidades de (0-10 cm) em 2020 (46,37%) e para a profundidade de amostragem de (10-20) em 2021 (43,68%). E que a variável potencial hídrico coletado para o ano de 2021, obteve o maior número de correlação significativa, com os índices, NIR, NDWI, NDRE, GNDVI, SAVI, MSAVI, CIrededge.

Por meio dos melhores resultados de correlação foram criadas as equações de regressão linear, obtidas pela análise ANOVA (Tabela 9).

Tabela 9- Parâmetros da análise de regressão linear.

Amostra	Ano	Variável	Índice	$\beta_0$	$\beta_1$	R <sup>2</sup>
VEGETAÇÃO	2020	Ug (0-10 cm)	CVI	7,0946	-12,5529	0,1903
			RED	0,1359	-0,3114	0,2150
		Uv (0-10 cm)	GREEN	0,7681	-1,8572	0,1337
			CVI	0,1313	-1,1546	0,1305
			SAVI	7,0176	-8,4326	0,1437
		$\Psi_w$ (MPa)	RED	-0,0402	-0,0134	0,1595
		SOLO SOLO	2020	Ug (0-10 cm)	SAVI	0,1313
NIR	0,2270				0,2003	0,1310
NDWI	-0,3920				-0,2908	0,1364
2021	$\Psi_w$ (MPa)		NDRE	0,0407	0,2240	0,2215
			GNDVI	0,3920	0,2908	0,1364
			SAVI	0,1579	0,3759	0,1337
			MSAVI	0,3681	0,4095	0,1421
		CIrededge	0,0564	0,6320	0,1976	

Ug- umidade gravimétrica, Uv-umidade volumétrica,  $\Psi_w$ - potencial hídrico,  $\beta_0$  e  $\beta_1$ - coeficientes da equação de regressão e R<sup>2</sup> coeficiente de determinação.

Fonte: Da autora (2021).

Pela tabela de parâmetros de análise de regressão linear, observa-se que o maior valor de R<sup>2</sup> foi de 0,2659 (26,59%) para as amostras de solo da Ug (0-10 cm) com o índice CCCI. E o menor valor de R<sup>2</sup> foi de 0,1305 (13,05%) para as amostras de vegetação da Uv (0-10 cm) com o índice CVI.

Verifica-se que pelas análises de correlação e regressão linear, a banda espectral Green juntamente ao atributo Uv (0-10 cm) para o ano de 2020, apresentou o maior coeficiente de correlação de Person (51,57%). O melhor ajuste de regressão foi para a variável Uv (0-10cm) com a banda espectral RED (R<sup>2</sup> de 0,2250) a partir da extração de amostras da vegetação.

## 6 CONCLUSÃO

A avaliação dos dados coletados em campo, umidade gravimétrica, umidade volumétrica em diferentes profundidades e potencial hídrico foliar, para as épocas de seca (agosto de 2021) e chuva (janeiro de 2021), serviram como base para a avaliação da espacialização desses atributos, através da geoestística. Pelos ajustes de semivariogramas foi possível estimar os valores dos atributos em estudo nos locais não amostrados através da krigagem ordinária.

As variáveis em estudo, apresentaram estrutura de variabilidade espacial, através do cálculo do coeficiente de variação, que se mostrou como forte dependência espacial para todas as variáveis avaliadas, já os semivariogramas ajustaram-se para os modelos esféricos e exponencial. Os mapas

de krigagem representam a espacialização dessas variáveis, onde foi possível averiguar locais de maiores e menores intensidades de cada uma.

Já os índices de vegetação mostraram o quanto uma lavoura pode variar seus valores de reflectância quando avaliados dois períodos distintos (seca e úmido). Por meio deles é possível avaliar diversos parâmetros como, saúde das plantas, clorofila, conteúdo de água nas folhas, por essa razão, utilizou-se a análise de correlação e regressão para avaliar se a umidade do solo e potencial hídrico das folhas correlacionavam com os índices de vegetação. Por meio dessa análise observou que as bandas espectrais RED, NIR e GREEN e os índices CVI, SAVI, MSAVI, NDWI, NDRE, GNDVI e CIrededge apresentaram correlação significativas com as umidades.

Os valores de  $R^2$  apresentaram-se como baixos o que pode ser justificado pelo fato de os dados de campo sofrerem diversas interferências, como foi o caso da coleta de 2020, onde o cafeeiro possuía uma camada de poeira sobre ele, o que tem influência direta nas imagens. Apesar dessa ocorrência, os índices de vegetação e as bandas espectrais podem apresentar indícios de locais com deficiência hídrica.

O uso das ferramentas geoestatística e índices de vegetação a partir de imagens de alta resolução, mostrou-se eficiente para essa pesquisa. Porém estudos ainda mais aprimorados podem tornar essa ferramenta eficiente para o uso em lavouras cafeeiras, afim de monitorar e detectar a variabilidade das condições hídricas, auxiliando o produtor na sua tomada de decisão em relação ao manejo.

## REFERÊNCIAS

- ALVES, E. A.; QUEIROZ, D. M. de.; PINTO, F. de A. Cafeicultura de precisão. In: **Boas práticas agrícolas na produção de café**. Viçosa, MG: UFV, 2006. p. 234.
- ANDRADE, A. D.; FARIA, R. O.; ALONSO, D. J. C.; FERRAZ, G. A. S.; HERRERA, M. A. D.; SILVA, F. M. Spatial variability of soil penetration resistance in coffee growing. **Coffee Science**, v. 13, n. 3, p. 341–348, 2018.
- ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística**. São Leopoldo: UNISINOS, 2003. 165 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 6457: 2016, versão corrigida Amostras de solo — Preparação para ensaios de compactação e ensaios de caracterização. Rio de Janeiro, 2016.
- ATZBERGER, C. Advances in remote sensing of agriculture: context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013.
- ÁVILA, L. F.; MELLO, C. R. DE; SILVA, A. M. DA. Continuidade e distribuição espacial da umidade do solo em bacia hidrográfica da Serra da Mantiqueira. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 12, p. 1257–1266, 2010.
- ÁVILA, L. F.; MELLO, C. R.; SILVA, A. M. Estabilidade temporal do conteúdo de água em três condições de uso do solo, em uma bacia hidrográfica da região da serra da Mantiqueira. MG. **Revista Brasileira de Ciência do Solo**, v. 34, n. 6, p. 2001-2009, 2010.
- BACHMAIER, M. & BACKERS, M. Variogram or semivariogram? Understanding the variances in a variogram. *Precision Agriculture*, v. 9, p. 173-175, 2008.
- BACSA, C. M. et al. CORRELATION of UAV-BASED MULTISPECTRAL VEGETATION INDICES and LEAF COLOR CHART OBSERVATIONS for NITROGEN CONCENTRATION ASSESSMENT on RICE CROPS. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 42, n. 4/W19, p. 31–38, 2019.
- BARNES, E.M.; T.R. CLARKE; S.E. RICHARDS; P.D. COLAIZZI; J. HABERLAND; M. KOSTRZEWSKI; et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. In: **Proceedings of the 5th International Conference on Precision Agriculture**, 2000.
- BARROS, R. S. ; MOTA, J. W. S. ; Da MATTA, F ; MAESTRI, M. . Decline of vegetative growth in *Coffea arabica* L. in relation to leaf temperature, water potential and stomatal conductance. *Field Crops Research*, EUA, v. 54, p. 65-72, 1997.
- BATISTA, L. A. et al. Anatomia foliar e potencial hídrico na tolerância de cultivares de café ao estresse hídrico. **Revista Ciência Agronômica**, v. 41, n. 3, p. 475–481, 2010.
- BATISTELLA, M.; ANDRADE, R. G.; BOLFE, É. L.; VICTORIA, D. C.; SILVA, G. B. S. Geotecnologias e gestão territorial da bovinocultura no Brasil. **Revista Brasileira de Zootecnia**, v. 40, p. 251-260, 2011.

- BAUSCH, W. C.; HALVORSON, A. D.; CIPRA, J. Quickbird satellite and ground-based multispectral data correlations with agronomic parameters of irrigated maize grown in small plots. **Biosystems Engineering**, New York, v. 101, n. 1, p. 306-315, 2008.
- BENEDIKTSSON, J. A.; CHANUSSOT, J.; MOON, W. M. "Very high-resolution remote sensing: Challenges and opportunities", **Proceedings of the IEEE**, vol. 100, no. 6, pp. 1907-1910, 2012.
- BERETTA, F.; SHIBATA, H.; CORDOVA, R.; PERONI, R. L.; AZAMBUJA, J.; COSTA, J. F. C. L. Topographic modelling using UAVs compared with traditional survey methods in mining. **REM, Int. Eng. J.**, Ouro Preto, 71(3), p. 463-470, 2018.
- BERGONCI, J.I.; BERGAMASCHI, H.; BERLATO, M.A.; SANTOS, A.O. 2000. Potencial da água na folha como um indicador de déficit hídrico em milho. **Pesquisa Agropecuária Brasileira**, 35(8): 1531-1540.
- BERNARDI, A. C. DE C.; BETTIOL, G. M.; GREGO, C. R.; ANDRADE, R. G.; RABELLO, L. M.; INAMASU, R. Y. Ferramentas de agricultura de precisão como auxílio ao manejo da fertilidade do solo. **Cadernos de Ciência & Tecnologia**, v.32, p.211-227, 2015.
- BERNARDI, A. C. DE C.; RABELLO, L. M.; INAMASU, R. Y.; GREGO, C. R.; ANDRADE, R. G. Variabilidade espacial de parâmetros físico-químicas do solo e biofísicos de superfície em cultivo do sorgo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 6, p. 623–630, 2014.
- BERNARDI, A. C. D. C.; BETTIOL, G. M.; GREGO, C. R.; ANDRADE, R. G.; RABELLO, L. M.; INAMASU, R. Y. Ferramentas de Agricultura de Precisão como auxílio ao manejo da fertilidade do solo. **Cadernos de Ciência e Tecnologia, Brasília**, v. 32, n. 1/2, p. 211-227, ago. 2015.
- BERNI, J. A. J. et al. Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring From an Unmanned Aerial Vehicle Improved Evapotranspiration using Unmanned Aerial Vehicles View project High throughput and remote trait measurement View project Thermal and Nar. **Ieee Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, 2009.
- BREVIK, E.; FENTON, T.; LAZARI, A. Soil electrical conductivity as a function of soil water content and implications for soil mapping. **Precision Agriculture**, v.7, p.393-404, 2006.
- BIRTH, G.S.; MCVEY, G.R. Measuring the color of growing turf with a reflectance spectrophotometer. **Agron. J.** 1968, 60, 640–643, doi:10.2134/agronj1968.00021962006000060016x
- BROCCA, L.; MORBIDELLI, R.; MELONE, F.; MORAMARCO, T. Soil moisture spatial variability in experimental areas of central Italy. **Journal of Hydrology**, v.333, n.1, p.356-373, 2007.
- BURAK, D. L.; SANTOS, D. A.; PASSOS, R. R. Variabilidade espacial de atributos físicos: relação com relevo, matéria orgânica e produtividade em café conilon. **Coffee Science**, Lavras, v.11, n.4, p. 455–466, 2016.
- CAMARGO, E. Geoestatística: Fundamentos e aplicações. **Geoprocessamento em Projetos Ambientais**. INPE - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2ª Edição, 1998.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D.L.; TURCO, R.F. & KONOPKA, A.E. **Field-scale variability of soil properties in central Iowa soils.** *Soil Sci. Soc. Am. J.*, 58:1501-1511, 1994.

CAMPOS, S.; ARAÚJO JÚNIOR, A. A.; BARROS, Z. X.; CARDOSO, L. G.; PIROLI, E. L. SENSORIAMENTO REMOTO E GEOPROCESSAMENTO APLICADOS AO USO DA TERRA EM MICROBACIAS HIDROGRÁFICAS, BOTUCATU - SP. **Eng. Agríc.**, Jaboticabal, v.24, n.2, p.431-435, maio/ago. 2004.

CAMPOS, M.C.C.; OLIVEIRA, I.A.; SANTOS, L.A.C.; AQUINO, E.A. & SOARES, M.D.R. Variabilidade espacial da resistência do solo à penetração e umidade em áreas cultivadas com mandioca na região de Humaitá, AM. **R. Agriambi.**, 6:9-16, 2012.

CAMPOS, M. C. C.; DE AQUINO, R. E.; DE OLIVEIRA, I. A.; BERGAMIN, A. C. Variabilidade espacial da resistência mecânica do solo à penetração e umidade do solo em área cultivada com cana-de-açúcar na região de Humaitá, Amazonas, Brasil **Revista Brasileira de Ciências Agrárias**, vol. 8, núm. 2, 2013, pp. 305-310 Universidade Federal Rural de Pernambuco, Pernambuco, Brasil

CANCIAN, L. C. Variabilidade Espacial Da Resistência a Penetração, Granulometria E Umidade Do Solo. **Dissertação**, 2015.

CANDIAGO, S.; REMODINO, F.; GIGLIO, M. D.; DUBBINI, M.; GATTELLI, M. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applicatios from UAV Images. **Remote sensing**, 7, 4026-4047, 2015

CARVALHO, L. C. L.; SILVA, F. M.; SILVA FERRAZ, G. A.; SILVA, F. C.; STRACIERI, J. Variabilidade espacial de atributos físicos do solo e características agronômicas da cultura do café. **Coffee Science**, v. 8, n. 3, p. 265-275, 2013.

CARVALHO, A. A. DE et al. Estabilidade Temporal E Variabilidade Espacial Da Umidade De Um Argissolo Cultivado Com Palma Forrageira. **Revista Brasileira de Agricultura Irrigada**, v. 11, n. 7, p. 1998–2009, 2017.

CAVATTE, P. C.; OLIVEIRA, A. A. G.; MORAIS, L. E.; MARTINS, S. C. V.; SANGLARD, L. M. V. P.; DAMATTA, F. M. Could shading reduce the negative impacts of drought on coffee? Amorphophysiological analysis. **Physiologia plantarum**, v. 144, p. 111-122, 2012.

CHAVES, M. M.; FLEXAS, J.; PINHEIRO, C. Photosynthesis under drought and salt stress: regulation mechanisms from whole plant to cell. **Annals of Botany**, Oxford, v. 103, n. 4, p. 551-560, Feb. 2009.

CHEN, J. "Evaluation of Vegetation Indices and Modified Simple Ratio for Boreal Applications." **Canadian Journal of Remote Sensing**, 22 (1996): 229-242.

CICHOTA, R.; HURTADO, A. L. B.; LIER, Q. J. van. Spatio-temporal variability of soil water tension in a tropical soil in Brazil. **Geoderma**, v.133, n.8, p.231-243, 2006.

COELHO FILHO, M. A.; COELHO, R. D.; GONÇALVES, A. C. A. Variabilidade espacial de variáveis físico-hídricas do solo em um pomar de lima ácida Tahiti, irrigado por microaspersão. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 5, n. 2, p. 239–246, 2001.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.

COLTRI, P. P.; CORDEIRO, R. L. F.; SOUZA, T. T.; de ROMANI, L. A. S.; ZULLO JÚNIOR, J.; TRAINA JÚNIOR, C.; TRAINA, A. J. M. Classificação de áreas de café em Minas Gerais por meio do novo algoritmo QMAS em imagem espectral Geoeye-1. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.7934. p. 7934–7941, 2011.

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da Safra brasileira- café. Primeiro levantamento, janeiro 2021- safra 2020/2021: Brasília: Companhia Nacional de Abastecimento. 2021. Disponível em <https://www.conab.gov.br/info-agro/safras/cafe>. Acesso em: 08 mar. 2021.

CORDERO-SANCHO, S.; SADER, S. A. Spectral analysis and classification accuracy of coffee crops using Landsat and a topographic-environmental model. **International Journal of Remote Sensing**, Orono, v. 28, n. 7, p. 1577-1593, Apr. 2007.

COSTA, G. F. DA; MARENCO, R. A. Fotossíntese, condutância estomática e Potencial Hídrico Foliar em árvores jovens de andiroba (*Carapa guianensis*). **Acta Amazonica**, v. 37, n. 2, p. 229–234, 2007.

CRIPPEN, R. "Calculating the Vegetation Index Faster." **Remote Sensing of Environment**, 34 (1990): 71-73.

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

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, Jan./Mar. 2006.

DA MATTA, F. M. et al. Ecophysiology of coffee growth and production. **Brazilian Journal of Plant Physiology**, v. 19, n. 04, p. 485-510, 2007.

DAMATTA, F. M. ET AL. IMPACTS of climate changes on crop physiology and food quality. *Food Research International*, Kidlington, v. 43, n. 7, p. 1814-1823, Aug. 2010.

EFFGEN, T. A. M.; PASSOS, R. R.; ANDRADE, F. V.; LIMA, J. S. S.; REIS, E. F.; BORGES, E. N. Propriedades físicas do solo em função de manejos em lavouras de cafeeiro conilon. **Revista Ceres**, v. 59, n. 3, p. 414–421, 2012.

EISENBEISS, H., 2004. A mini unmanned aerial vehicle (UAV): system overview and image acquisition. **International Workshop on” Processing and visualization using highresolution imagery**, 18-20.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no Sensoriamento Remoto da cultura do feijão. **Pesquisa Agropecuária Brasileira**, v. 31, n. 6, p. 445-454, 1996.

ESPOSITO, F.; ACCARDO, D.; RUFINO, G.; MOCCIA, A. 1st: a Fully Autonomous UAV Aimed at Monitoring Environmental Risks. **Italian Journal on Composites and Nanotechnologies-Materials, Aerospace, Special Technologies**, v. 2, n. 2, p. 61-69, 2006.

FACCO, F. L. B.; PEGORARO, A. J. Utilização De Sistemas De Aeronaves Remotamente Pilotadas Na Agricultura de Precisão. **Revista Geonorte**, v. 10, n. 34, p. 129–152, 2019.

FARIA, R. O.; SILVA, F. M.; FERRAZ, G. A. S.; HERRERA, M. A. D.; ALONSO, D. J. C.; BARBOSA, B. D. S. Estimativa de custo do levantamento do mapa de produtividade em cafeicultura de precisão. **Trabalho apresentado no 43º Congresso Brasileiro de Pesquisas Cafeeiras (43.: 2017: Poços de Caldas, MG). Anais 434.**

FARIA, R. de O. Malha amostral para cafeicultura de precisão. 2019. 118 p. **Tese (Doutorado em Engenharia Agrícola)** – Universidade Federal de Lavras, Lavras, 2019.

FERN, R. R.; FOXLEY, E.A.; BRUNO, A.; MORRISON, M. L. Suitability of NDVI and OSAVI as estimators of green biomass and coverage in a semi-arid rangeland. **Ecological Indicators**, v. 94, n. June, p. 16–21, 2018.

FERRAZ, G. A. E. S.; SILVA, F. M.; CARVALHO, L. C. C.; ALVES, M. DE C.; FRANCO, B. C. Variabilidade espacial e temporal do fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola**, v. 32, n. 1, p. 140–150, 2012.

FILIPPINI ALBA, J. M. Modelagem SIG em agricultura de precisão: conceitos, revisão e aplicações. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 84-95.

FINAZZI, F. B. Comparação da eficácia da adição de pontos intermediários à grade regular amostral na elaboração de mapas para agricultura de precisão 2011. 18 p. **Estágio Supervisionado em Engenharia de Biosistemas I** –Universidade de São Paulo, Piracicaba, 2011.

FIGLIARESE, C. H. U. Análise de propriedades físicas de solo com monocultivo de café no município de Castelo (ES). **Brazilian Journal of Development**, v. 5, n. 6, p. 6850–6859, 2019.

FLOWERS, M.; WEISZ, R.; WHITE, J. G. Yield-based management zones and grid sampling strategies: Describing soil test and nutrient variability. **Agronomy Journal**,v. 97, p. 968–982, 2005.

FROGBROOK, Z. L. et al. Exploring the spatial relations between cereal yield and soil chemical properties and the implications for sampling. **Soil Use and Management**, Oxon, v. 18, n. 1, p. 1-9, Feb. 2002.

GAGO, J. et al. UAVs challenge to assess water stress for sustainable agriculture. **Agricultural Water Management**, v. 153, p. 9–19, 2015.

GITELSON, A.A.; MERZLYAK, M.N.; LICHTENTHALER, H.K. 1996. Detection of red edge position and Chlorophyll. **Journal Plant of Physiology** 148: 501-508.



- GITELSON, A.A.; GRITZ, Y.; MERZLYAK, M.N. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology** 160: 271-282.
- GOLBERG, A. D. et al. Effects and after-effects of water stress on chlorophyll fluorescence transients in *Coffea canephora* Pierre and *Coffea robusta* Capot and Aké Assi. *Café Cacao Thé*, v. 32, n. 01, p. 11-16, 1988.
- GOMES, D. **Jornal do Café**. Inovações Tecnológicas nº183, 2013.
- GOMES, F.; GARCIA, C. H. **Estatística aplicada a experimentos agrônômicos e florestais**. Piracicaba: FEALQ, 2002. 305 p.
- GONÇALVES, L. M. Estimativa de parâmetros biofísicos de lavoura cafeeira a partir de imagens obtidas por aeronave remotamente pilotada. 2018. 54 p. **Dissertação** (Mestrado em Engenharia Agrícola) –Universidade Federal de Lavras, Lavras, 2018.
- GREGO, C.R.; VIEIRA, S.R.; ANTONIO, A.M.; DELLA ROSA, S.C. Geostatistical analysis for soil moisture content under the no tillage cropping system. **Scientia Agricola**, Piracicaba, v.63, n.4, p.341-350, 2006.
- HABOUDANE, DRISS; MILLER, JOHN R.; TREMBLAY, NICOLAS; ZARCO-TEJADA, PABLO J.; DEXTRAZE, LOUISE. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v.81, p.416-426, 2002.
- HARDGRAVE, O pioneirismo com o Vant; Estados Unidos da América, 2005. Disponível em: <<http://www.ctie.monash.edu.au/hargrave/denny.html>>. Acesso em 03 de Junho de 2020.
- HATFIELD, J. L.; GITELSON, A. A.; SCHEPERS, J. S.; WALTHALL, C. L. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, v.100, p.117-131, 2008.
- HÉBRARD, O.; VOLTZ, M.; ANDRIEUX, P.; MOUSSA, R. Spatio-temporal distribution of soil surface moisture in a heterogeneously farmed Mediterranean catchment. **Journal of Hydrology**, v.329, p.110-121, 2006.
- HERWITZ, S. R. et al. 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.
- HOFFMANN, H. et al. Crop water stress maps for an entire growing season from visible and thermal UAV imagery. **Biogeosciences**, v. 13, n. 24, p. 6545–6563, 2016.  
Hoffmann et al. (2016)
- HSIAO, T.C. 1973. Plant responses to water stress. **Annual Review of Plant Physiology and Plant Molecular Biology**, 24: 519-570.
- HU, W.; SHAO, M.; HAN, F.; REICHARDT, K.; TAN, J. Watershed scale temporal stability of soil water content. **Geoderma**. v.158, p.181–198, 2010.
- HUETE, A. R. A. Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p.205-309, Aug. 1988.

HUUSKONEN, J.; OKSANEN, T. Soil sampling with drones and augmented reality in precision agriculture. **Comput. Electron. Agric.** 2018, 154, 25–35.

INAMASU, R. Y.; BERNARDI, A. C. C. Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de Precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 21-33.

INSTITUTO NACIONAL DE METEOROLOGIA DO BRASIL – INMET. Dados de Clima (2020/2021). Brasília - DF, 2021.

ISAAKS, E.H. & SRIVASTAVA, R.M. (1989). An introduction to applied geostatistics. New York: Oxford University Press, 560p.

JENSEN, J.R.; EPIPHANIO, J.C.N. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. **Parêntese**, 2011.

JENSEN, J.R. (1949). **Sensoriamento Remoto do ambiente: uma perspectiva em recursos terrestres**. EPIPHANIO, J.C.N.; FORMAGGIO, A.R.; SANTOS, A.R.; RUDORFF, B.F.T.; ALMEIDA, C.M.; GALVÃO, L.S. (Tradução). São José dos Campos: Parêntese. 2009.

JIANG, Z.; HUETE, A.R.; DIDAN, K. MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**. V.112, n.10, p.3833-3845, 2008.

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

JORGE, L. A. DE C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. **Embrapa Instrumentação-Capítulo em livro técnico-científico (ALICE)**, p. 109–134, 2014.

KAMIMURA, K. M.; SANTOS, G. R.; OLIVEIRA, M. S.; JUNIOR, M. S. D.; GUIMARÃES, P. T. G. Variabilidade espacial de atributos físicos de um Latossolo Vermelho-Amarelo, sob lavoura cafeeira. **Revista Brasileira de Ciencia do Solo**, v. 37, n. 4, p. 877–888, 2013.

KLEIN, V. A. **Física do solo**- Passo Fundo: Ed. Universidade de Passo Fundo, 2008. 212p.

KRAMER, P.K.; BOYER, J.R. (1995). Water Relations of Plants and Soil. **Academic Press: San Diego**.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. São Paulo: Editora da UNESP. 1998.

LIMA, J. S. S.; DE OLIVEIRA, R. B.; SILVA, S. A. Spatial variability of particle size fractions of an Oxisol cultivated with conilon coffee. **Revista Ceres**, v. 59, n. 6, p. 867–872, 2012.

LIMA, G. C.; SILVA, M. L. N.; SILVA, M. A.; OLIVEIRA, A. H.; AVANZI, J. C.; UMMUS, M. E. Avaliação da cobertura vegetal pelo índice de vegetação por diferença normalizada (IVDN). **Revista Ambiente & Água - An Interdisciplinary Journal of Applied Science**: v. 8, n.2, 2013.

LONG, D. S., EITEL, J. U. H., and HUGGINS, D. R. Assessing nitrogen status of dryland wheat using the canopy chlorophyll content index. **Crop Management**. Online. doi:10.1094/CM-2009-1211-01-RS

LUCIEER, A.; ROBINSON, S.; TURNER, D, STEVE HARWIN, AND KELCEY, J.. 2012. Using a Micro-UAV for ultra-high-resolution multi-sensor observations of Antarctic moss beds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XXXIX-B1, 2012

MACHADO, M.L.; ALVES, H.M.R.; VIEIRA, T.G.C.; LACERDA, M.P.C.; ANDRADE, H., FERNANDES FILHO, EI.; SCHAEFERAND, C.E.R E CEREDA, G. J. Caracterização do meio físico de agroecossistemas cafeeiros da Zona da Mata de Minas Gerais, usando técnicas de Sensoriamento Remoto, sistema de informação geográficas e fotográficas aéreas não convencionais. Trabalho apresentado no **Simpósio de Pesquisa dos Cafés do Brasil** (2: 2001: Vitória, ES). Resumos. Brasília, DF: Embrapa Café, 2001. 181p.

MACHADO, M. L.; ALVES, H. M. R.; VIEIRA, T. G. C.; FERNANDES FILHO, E. I.; COELHO, L. M. P. Mapeamento de áreas cafeieras (*Coffea arabica* L.) da Zona da Mata mineira usando Sensoriamento Remoto. **Coffee Science**, Lavras, v. 5, n. 2, p. 113-122, maio 2010.

MANTOVANI, E. C.; BERNARDO, S.; PALARETTI, L. F. **Irrigação: princípios e práticas**. Viçosa: UFV, 2006. 318 p.

MANZIONE, R. L.; RODRIGUES, J. B. T.; ZIMBACK, C. R. L. Análise espacial multivariada na avaliação de parâmetros químicos do solo. In: BALASTREIRE, L. A. **Avanços na Agricultura de Precisão no Brasil no período de 1999-2001**. Piracicaba, 2002. 347 p.

MARASCA, I.; GLADENUCCI, J; SPADIM, E. R.; BARBOSA, R. D.; LANÇAS, K. P. Geoestatística aplicada na determinação da compactação do solo no cultivo da cana-de-açúcar. *Revista de Agricultura Neotropical, Cassilândia-MS*, v. 4, n. 2, p. 49-55, abr./jun. 2017.

MARTÍNEZ-VERDUZCO, G. C.; GALEANAPIZAÑA, J. M.; CRUZ-BELLO, G. M. Coupling community mapping and supervised classification to discriminate Shade coffee from Natural vegetation. **Applied Geography**, Oxford, v. 34, p. 1-9, 2012

MARTINS, R. N. et al. A novel vegetation index for coffee ripeness monitoring using aerial imagery. **Remote Sensing**, v. 13, n. 2, p. 1–16, 2021.

MARUJO, R. F. B.; VOLPATO, M. M. L.; VIEIRA, T. G. C.; ALVES, H. M. R.; RIBEIRO, M. B. P. Classificação orientada à objeto aplicado à cultivos cafeeiros em Três Pontas, MG. In: **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 16., 2013, Foz do Iguaçu. Anais... São José dos Campos: INPE, 2013. p. 1338-1345.

MARRACCINI, P.; VINECKY, F.; ALVES, G. S. C.; RAMOS, H. J. O.; ELBERT, S.; VIEIRA, N. G.; CARNEIRO, F. A.; SUJII, P. S.; ALEKCEVETCH, J. C.; SILVA, V. A.; DaMATTA, F. M.; FERRÃO, M. A. G.; LEROY, T.; POT, D.; VIEIRA, L. G. E.; SILVA, F. R.; ANDRADE, A. C. Differentially expressed genes and proteins upon drought acclimation in tolerant and sensitive genotypes of *Coffea canephora*. **Journal of Experimental Botany**, Oxford, v. 63, p. 1-22, 2012.

MCBRATNEY, A. B.; WEBSTER, R. Choosing functions for semi-variograms of soil properties and fitting them to sampling estimates. **Journal of Soil Science**, Oxford, v. 37, n. 3, p. 617-639, June 1986.

McFEETERS, S.K. (1996). The use of the normalized difference water index (NDWI) in the delineation of open water features. *Int. J. Remote Sens.*, 17, 1425–1432.

MEDEIROS, F. A. Desenvolvimento de um veículo aéreo 2007. 102 f. **Dissertação** (Mestrado em Engenharia Agrícola- Universidade Federal de Santa Maria, Santa Maria, 2007.

MEHL, H. U.; SAGRILO, E. WOLSCHICK, D.; ARZABE, C. Produção de Biomassa e Padrão de Decomposição de Adubos Verdes Cultivados nas Entrelinhas de Acerola Orgânica. **XVIII REUNIÃO BRASILEIRA DE MANEJO E CONSERVAÇÃO DO SOLO E DA ÁGUA Novos Caminhos para Agricultura Conservacionista no Brasil**, p. 1–5, [s.d.].

MICHELON, D.; ZAMBERLAN, J. F.; OLIVEIRA NETO, D.; SAMPAIO, M. I. R. Uso do Sensoriamento Remoto com VANT's: possibilidade de aquisição de dados para agricultura. **Ciência & Tecnologia**, v. 3, n. 1, p. 23–35, 2019.

MONTIBELLER, B. et al. Identification of gaps in sugarcane plantations using UAV images. In: **XVIII Simpósio Brasileiro de Sensoriamento Remoto**, 1., Santos. Anais... Santos: INPE, 2017.

MOREIRA, M. A.; BARROS, M. A.; RUDORFF, B. F. T. Geotecnologias no mapeamento da cultura do café em escala municipal. **Sociedade e Natureza**, Uberlândia, v. 20, n. 1, p. 101-110, 2008.

MOREIRA, M. A. et al. Geotecnologias para mapear lavouras de café nos estados de Minas Gerais e São Paulo. **Revista Engenharia Agrícola**, Jaboticabal, v. 30, n. 6, p. 1123-1135, dez. 2010.

MOREIRA, N. B.; LIBARDI, P. L.; SALVADOR, M. M. S.; SOUSA, H. H. F. Análise espaço-temporal de componentes do balanço hídrico em um Latossolo. **Revista Brasileira de Ciência do Solo**, v. 38, n. 1, p. 60-72, 2014.

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.

MOTA, P. C. Jr.; CAMPOS, M. C.C.; MANTOVANELLI, B. C.; FRANCISCON, U.; CUNHA, J. M. Spatial variability of physical attributes of the soil in Amazonian black soil under coffee cultivation. **Coffee Science**, v. 12, n. 2, p. 260–271, 2017.

MOTOHKA, T.; NASAHARA, K. N.; OGUMA, H.; TSUCHIDA, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, v. 2, n. 10, p. 2369-2387, 2010.

NEBIKER, S.; ANNEN, A.; SCHERRER, M.; OESCH, D. A Light-Weight Multispectral Sensor for micro UAV – Opportunities for very high resolution airborne remote sensing. The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**. v. XXXVII, B1, 2008.

NHAMO, L. et al. Prospects of improving agricultural and water productivity through unmanned aerial vehicles. **Agriculture (Switzerland)**, v. 10, n. 7, p. 1–18, 2020.

ODA, M. L. Aplicação de métodos geoestatísticos para identificação de dependência espacial na análise de dados de um experimento em delineamento sistemático tipo “leque”. Piracicaba: ESALQ/USP, 2005. 72p. **Dissertação Mestrado**.

OLIVEIRA, M. C. S., SILVA, M. F. de O. **DINÂMICA RECENTE DA CAFEICULTURA NA BAHIA: um estudo sobre a produção de cafés especiais na Chapada Diamantina, Bahia**. Vitória da Conquista, Bahia, 2017.

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**, 2018.

PADOLFI, A. S.; RAMALDES, G. P.; DOS SANTOS, O. L. Análise De Índice De Vegetação Através De Imagens Obtidas Por Vant. **Revista Científica Faesa**, v. 14, n. 1, p. 142–162, 2018.

PENG, F.; MU, M.; SUN, G. Responses of soil moisture to climate change based on projections by the end of the 21st century under the high emission scenario in the ‘Huang–Huai–Hai Plain’ region of China. **Journal of Hydro-environment Research**, v. 14, n. 1, p. 105-118, 2017.

PEZZINI, L. F & TORRES, F. O. A UTILIZAÇÃO DE AERONAVE REMOTAMENTE PILOTADA (Remotely-Piloted Aircraft – RPA) The use of remotely piloted aircraft (RPA) IN THE. n. 2006, p. 137–154, 2018.

PEZZOPANE, J. R. M.; BERNARDI, A. C. C.; BOSI, C.; CRIPPA, P. H.; SANTOS, P. M.; NARDACHIONE, E. C. Assessment of Piatã palisadegrass forage mass in integrated livestock production systems using a proximal canopy reflectance sensor. **European Journal of Agronomy**, v. 103, p. 130-139, 2019.

PIZARRO, M. A. Ministério Da Ciência E Tecnologia Instituto Nacional De Pesquisas Espaciais Sensoriamento Remoto Hiperespectral Para a Caracterização E Identificação Mineral Em Solos Tropicais. 1999.

PONZONI, F. J. Comportamento espectral da vegetação. In. Sensoriamento Remoto - Reflectância dos alvos naturais. Brasília: UnB, EMBRAPA, 2001. p.157-199.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: Ed. Parênteses, 2010.

QI, J. C.; MORAN, M.S. Biophysical Parameter Estimations Using Multidirectional Spectral Measurements, **Remote Sensing of Environmental**, 54:71-83, 1995.

QUEIROZ, D. M.; PINTO, F. A. C.; ZANDONADI, R. S.; EMERICH, I. N.; SENA JÚNIOR, D. G. Uso de técnicas de Agricultura de Precisão para a cafeicultura de montanha. In: **Zambolim, L. Efeitos da irrigação sobre a qualidade e produtividade do café**. Viçosa: Editora UFV, 2004. Cap.3, p.77-108.

RAMIREZ, G. M.; JÚNIOR, J. Z. Estimation of biophysical parameters of coffee fields based on high-resolution satellite images. **Eng. Agrícola**, p. 468–479, 2010.

- RANGO, A.; LALIBERTE, A.; HERRICK, J. E.; WINTERS, C.; HAVSTAD.; STEELE, C.; BROWNING, D. Unmanned aerial vehicle- based remote sensing for rangeland assessment, monitoring, and management. **Journal of Applied Remote Sensing**, v. 3, n. 1, p.33542, 2009.
- REGER, M.; BAUERDICK, J.; BERNHARDT, H. Drones in der Landwirtschaft: Aktuelle und zukünftige Rechtslage in Deutschland, der EU, den USA und Japan. *Landtechnik*, v.73(3): 62-80, 2018.
- RIBEIRO JUNIOR, P. J.; DIGGLE, P. J. GeoR a package for geostatistical analysis. **R-News**, New York, v. 1, n. 2, p. 14-18, June 2001.
- RODRIGUES JUNIOR, F. A.; VIEIRA, L. B., QUEIROZ, D. M., SANTOS, N. T. Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 8, p. 778–787, 2011.
- RODRIGUES, S. C. A. Modelo de Regressão Linear e suas aplicações. 2012. 94p. Relatório de Estágio para obtenção do Grau de Mestre em Ensino de Matemática no 3º Ciclo do Ensino Básico e no Ensino Secundário- Universidade da Beira Interior, Covilhã, 2012.
- RODRIGUES, R. A. S.; MONTENEGRO, A. A. A.; SANTOS, D. P.; MAGALHÃES, A. G.; FONTES JÚNIOR, R. P. Variabilidade espacial da umidade e das frações granulométricas do solo em um plantio de bananeiras irrigado no semiárido pernambucano. **Revista Conexões Ciência e Tecnologia**, v. 11, n. 3, p. 134-143, 2017.
- RONCHI, C. P. (2015) Respostas ecofisiológicas de cafeeiros submetidos ao deficit hídrico para concentração da florada no Cerrado de Minas Gerais. **Pesq. agropec. bras.**, Brasília, v.50, n.1, p.24-32
- RONDEAUX G, STEVEN M & BARET F. 1996. Optimization of soil adjusted vegetation indices. **Remote Sensing of Environment**, 55: 95– 107.
- ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W.; HARLAN, J.C. Monitoring the vernal advancement of retrogradation of natural vegetation. **Greenbelt: National Aerospace Spatial Administration**, 1973. 371p.
- SAMPAIO, F. M.T.; FERREIRA, M.M.; OLIVEIRA, M.S.; ALMEIDA, A.C. & JOSÉ, M.R. Variabilidade espacial da umidade de um Latossolo Vermelho-Amarelo sob plantio direto. **Engenharia Agrícola**, Jaboticabal, v.30, n.5, p.854-861, set./out, 2010.
- SAMPAIO, H. S.; BOURSCHEIDT V.; SARRACINI, L. H.; JORGE, L. A. C.; BETTIOL, G. M.; BERNARDI, A. C. C. Comparação entre índices de vegetação obtidos por imagens aéreas com veículo aéreo não tripulado (vant) e satélite. **Brazilian Journal of Biosystems Engineering** v. 14(2) 111-124, 2020.
- SANTANA, L. S., SANTOS, L. M., MACIEL, D. A., BARATA, R. A. P., REYNALDO, É. F., & ROSSI, G. (2019). VEGETATIVE VIGOR OF MAIZE CROP OBTAINED THROUGH VEGETATION INDEXES IN ORBITAL AND AERIAL SENSORS IMAGES. **Revista Brasileira de Engenharia de Biosistemas**, 13(3), 195-206.

SANTOS, D.S.; SOUZA, E.G.; NÓBREGA, L.H.P.; BAZZI, C.L.; GONÇALVES JÚNIOR, A.C. Variabilidade espacial de atributos físicos de um Latossolo Vermelho após cultivo de soja. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16, p.843-848, 2012.

SANTOS, E. O. DE J., GONTIJO, I., SILVA, M. B., PARTELLI, F. L. Sampling design of soil physical properties in a Conilon coffee field. **Revista Brasileira de Ciencia do Solo**, v. 41, p. 1–13, 2017.

SANTOS, L. M. D., ANDRADE, M. T., SANTANA, L. S., ROSSI, G., MACIEL, D. T., BARBOSA, B. D. S., & FERRAZ, G. A. S. Analysis of flight parameters and georeferencing of images with different control points obtained by RPA. **Agronomy Research**, 17(5), 2054–2063, 2019.

SANTOS, L. M.; FERRAZ, G. A. S.; BARBOSA, B. D. S.; DIOTTO, A. V.; MACIAL, D. T.; XAVIER, L. A. G. Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture**, p. 1-15, 2020.

SARMIENTO, C. M.; RAMIREZ, G. M.; COLTRI, P. P.; SILVA, L. F. L.; NASSUR, O. A. C.; SOARES, J. F. Comparison of supervised classifiers in discrimination coffee areas fields in Campos Gerais - Minas Gerais. **Coffee Science**, v. 9, n. 4, p. 546–557, 2014.

SCHOLANDER P. F.; HAMMEL, H. T.; BRADSTREET, E. D.; HEMMINGSEN, E. A. (1965) Sap pressure in vascular plants. **Science** 148:339.

SERAFIM, M. E. et al. Disponibilidade hídrica e distinção de ambientes para cultivo de cafeeiros. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 4, p. 362–370, 2013.

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

SILVA, A. V.; SILVA, A. M. da.; COELHO, G.; REZENDE, F. C.; SATO, F. A. Produtividade e potencial hídrico foliar do cafeeiro Catuaí, em função da época de irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.12, n.1, p.21–25, 2008

SILVA, J. M; PASSOS, A. L. R.; BELTRÃO, F. A. S. Análise espacial da densidade, umidade e resistência mecânica do solo à penetração sob sistemas de cultivo. **Engenharia Ambiental - Espírito Santo do Pinhal**, v. 6, n. 3, p. 103-118, set /dez. 2009.

SILVA, A. P.; BABUJIA, L. C.; FRANCHINI, J. C.; SOUZA, R. A.; HUNGRIA, K. Microbial biomass under various soil-and-crop-management systems in short and long-term experiments in Brazil. **Field Crops Research**, v. 119, n.1, p. 20-26,2010.

SILVA, V. A. et al. Physiological response of Conilon coffee clone sensitive to drought grafted onto tolerant rootstock. **Pesquisa Agropecuaria Brasileira**, v. 45, n. 5, p. 457–464, 2010.

SILVA, S. A.; LIMA, J. S. S. Atributos físicos do solo e sua relação espacial com a produtividade do café Arábica. **Coffee Science**, v. 8, n. 4, p. 395–403, 2013.

SILVA, V. A.; SALGADO, S. M. DE L.; SÁ, L. A. DE; REIS, A. M.; SILVEIRA, H. R. DE O.; MENDES, A. N. G.; BARBOSA, J. P. R. A. D.; PEREIRA, A. A. Use of physiological characteristics to identify genotypes of arabic coffee tolerant to *Meloidogyne paranaensis*. **Coffee Science**, v. 10, n. 2, p. 242 - 250, 31 May 2015.

SILVA, V. A. et al. 2015. Uso de características fisiológicas na identificação de genótipos de café arábica tolerantes ao *Meloidogyne Paranaenses*. **Coffee Science**, Lavras, v. 10, n. 2, p. 242 – 250.

SILVA, C. A. 2017. 44p. Alterações fisiológicas e morfoanatômicas induzidas pelo déficit hídrico em duas cultivares de soja. Dissertação Mestrado em Fisiologia Vegetal- Universidade Federal de Viçosa, Viçosa, 2017.

SILVA, B. M.; OLIVEIRA, G. C.; SERAFIM, M. E.; SILVA, E. A.; GUIMARÃES, P. T. G.; MELO, L. B. B.; NORTON, L. D.; CURI, N. Soil moisture associated with least limiting water range, leaf water potential, initial growth and yield of coffee as affected by soil management system. **Soil and Tillage Research**, v. 189, n. May 2018, p. 36–43, 2019.

SIQUEIRA, G. M.; VIEIRA, S. R.; CEDDIA, M. B. Variabilidade de atributos físicos do solo determinados por métodos diversos. **Bragantia** 2008; 67(1):203-211.

SLONGO, A. G.; MORAES, D. D.; MANTOVANI, L. Q.; VENTURINI, M. S. Desenvolvimento de uma Aeronave Remotamente Pilotada para pulverização agrícola. **II Congresso Aeroespacial Brasileiro** - CAB 16-19 de setembro de 2019, Santa Maria, RS, Brasil.

SOUZA, Z. M.; MARQUES JUNIOR, J.; PEREIRA, G. T.; BARBIERI, D. M. Variabilidade espacial da textura de um Latossolo Vermelho eutroférico sob cultivo de cana-de-açúcar. **Engenharia Agrícola**, v.24, n.2, p.309-319, 2004.

SOUZA, E. R., MONTENEGRO, A. A.; FREIRE, M. B. G. S. Evolução e variabilidade espacial da salinidade em Neossolo Flúvico cultivado com cenoura sob irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.12, n.6, p.584-592, 2008.

SOUZA, Z. M.; MARTINS FILHO, M. V.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Variabilidade espacial de fatores de erosão em Latossolo Vermelho eutroférico sob cultivo de cana-de-açúcar. **Engenharia Agrícola**, v.25, n.1, p.105-114, 2005.

SOUZA, K. R.; VIEIRA, T. G. C.; ALVES, H. M. R.; VOLPATO, M. L.; ALVES, L. A. P. A.; SOUZA, C. G.; ANDRADE, L. N. Classificação automática de imagem do satélite rapideye para o mapeamento de áreas cafeeiras em Carmo de Minas, MG. Trabalho apresentado no **Simpósio de Pesquisa dos Cafés do Brasil** (7.: 2011: Araxá, MG). Anais Brasília- DF: Embrapa- Café, 2011.

SOUZA, C. G.; CARVALHO, L.; AGUIAR, P.; ARANTES, T. B. Machine learning algorithms and variable of remote sensing for coffee cropping mapping. **Boletim de Ciencias Geodesicas**, v. 22, n. 4, p. 751–773, 2016.

SUN, L. LI, PS LAMMERS, Q. ZENG, J. LIN, H. SCHUMANN. A solar-powered wireless cell for dynamically monitoring soil water content. *Computers and Electronics in Agriculture*, **Elsevier**, v. 69, n. 1, p. 19–23, 2009.

TAIZ, L.; ZEIGER, E. Fisiologia vegetal. Porto Alegre: Artmed, 2004. p.449-484.



TANQUES, R. C. et al. Caracterização Da Umidade Do Solo Em Café Sombreado Com Gliricidia, Banana E Inga Comparado Com Café Em Pleno Sol. p. 2015–2019, 2019.

TOPIK, S. The integration of the world coffee market. In: **CLARENCE-SMITH, William Gervase; TOPIK, Steven (Org.)**. The global coffee economy in Africa, Asia and Latin America, 1500-1989. New York: Cambridge University Press, 2003.

TRABAQUINI, K.; MIGLIORANZA, E.; FRANCA, V. P. N.; COELHO, O. Caracterização de lavouras cafeeiras, utilizando técnicas de geoprocessamento e Sensoriamento Remoto, no município de Umuarama, PR. **Ciência e Agrotecnologia**, Lavras, v. 35, n. 1, p. 35-44, fev. 2011.

VELLOSO, M. H. **Coffe inventory through orbital imagery**. Rio de Janeiro: Instituto Brasileiro do Café, 1974. 20p. (SR-525).

VELLOSO, M. H.; SOUZA, D.D. **Sistema automático de inventário cafeeiro**. Rio de Janeiro: Instituto Nacional do Café, 1976. 8p.

VELLOSO, M. H.; SOUZA, D. D. **Trabalho experimental de inventariação automática de cafezais utilizando imagens orbitais e o equipamento image-100**. Rio de Janeiro: Instituto Brasileiro do Café, 1978. 2p.

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. **Brazilian Journal of Biosystems Engineering** v. 12(3): 286-298, 2018.

VIEIRA, S.R.; NIELSEN, D.R.; BIGGAR, J.W.; TILLOTSON, P.M. The Scaling of semivariograms and the kriging estimation. **Revista Brasileira de Ciência do Solo**, Viçosa, 21:525-533, 1997.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F.; ALVAREZ V., V. H.; SCHAEFER, C. E. G. R. **Tópicos especiais em ciências do solo**. Sociedade Brasileira de Ciência do Solo, Viçosa, 2000. p.1-54.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: Novaes, R.S.; Alvarez, V. V. H.; Schaeser, C. E. G. R. **Tópicos em Ciências do Solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, v.3, p.1-54, 2003.

VINCINI, M., AMADUCCI, S., & FRAZZI, E. (2014). Empirical Estimation of Leaf Chlorophyll Density in Winter Wheat Canopies Using Sentinel-2 Spectral Resolution. **IEEE Transactions on Geoscience and Remote Sensing**, 52(6), 3220–3235. doi:10.1109/tgrs.2013.2271813

VOLPATO, M. M. L.; VIEIRA, T. G. C.; ALVES, H. M. R.; SANTOS, W. J. R. Imagens do sensor MODIS para monitoramento agrometeorológico de áreas cafeeiras. *Coffee Science*, Lavras, v. 8, n. 2, p. 176-182, abr/jun.2013.

VOLPATO, M. M. L. et al. Relação Entre Índices De Vegetação De Áreas Cafeeiras E Variáveis Do Balanço Hídrico, Em Santo Antônio Do Amparo , Mg 1 Relationship Between Vegetation Index in Area Coffee and Variable of the Water Balance , in Santo Antônio Do Amparo , Mg. 2019.

XAVIER, A. C.; LIMA, J. S. S.; FONSECA, A.S.; QUINTO, V. M. Aplicação da Agricultura de Precisão no Cafeeiro Conilon. In: PRATISSOLI, D.; JUNIOR, W. C. J.; ZAGO, H. B.; ALVES, F. R.; VIANA, U. R.; JUNIOR, H. J. G. S.; RODRIGUES, C. **Tópicos Especiais em Produção Vegetal III**. Alegre, ES. p. 800-809, 2012.

XIANG, H.T.; TIAN, L. 2011: Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). **Biosyst. Eng.** 108 (2), 174-190.

ZHANG, P.; SHAO, M. Temporal stability of surface soil moisture in a desert area of northwestern China. **Journal of Hydrology**. v.505, p.91–101, 2013.

ZHANG, L. et al. Mapping maizewater stress based on UAV multispectral remote sensing. **Remote Sensing**, v. 11, n. 6, p. 1–24, 2019.

ZHU, Y.; SHAO, M. Variability and pattern of surface moisture on a small-scale hillslope in Liudaogou catchment on the northern Loess Plateau of China. **Geoderma**, v.147, p.185-191, 2008.

ZUCCO, G.; BROCCA, L.; MORAMARCO, T.; MORBIDELLI, R. Influence of land use on soil moisture spatial–temporal variability and monitoring. **Journal of Hydrology**, v. 516, n. 1, p. 193-199, 2014.

WEBSTER, R.; OLIVER, M. Geostatistics for environmental scientists. **Chichester: John Wiley & Sons**, 2001. 271 p.