



LUANA MENDES GONÇALVES

**ESTIMATIVA DE PARÂMETROS BIOFÍSICOS DE
LAVOURA CAFEIEIRA A PARTIR DE IMAGENS
OBTIDAS POR AERONAVE REMOTAMENTE
PILOTADA**

**LAVRAS- MG
2018**

LUANA MENDES GONÇALVES

**ESTIMATIVA DE PARÂMETROS BIOFÍSICOS DE LAVOURA CAFEIEIRA A
PARTIR DE IMAGENS OBTIDAS POR AERONAVE REMOTAMENTE
PILOTADA**

Dissertação apresentada à
Universidade Federal de Lavras,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia Agrícola, para a
obtenção do título de Mestre.

Prof. Dr. Gabriel Araújo e Silva Ferraz

Orientador

Prof. Dr. Adriano Valentim Diotto

Coorientador

**LAVRAS-MG
2018**

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

Gonçalves, Luana Mendes.

Estimativa de parâmetros biofísicos de lavoura cafeeira a partir
de imagens obtidas por aeronaves remotamente pilotadas / Luana
Mendes Gonçalves. - 2018.

54 p. : il.

Orientador(a): Gabriel Araújo e Silva Ferraz.

Coorientador(a): Adriano Valentim Diotto.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2018.

Bibliografia.

1. Precision Agriculture. 2. Drone. 3. Unmanned Aircraft
Systems (UAS). I. Ferraz, Gabriel Araújo e Silva. II. Diotto,
Adriano Valentim. III. Título.

LUANA MENDES GONÇALVES

**ESTIMATIVA DE PARÂMETROS BIOFÍSICOS DE LAVOURA CAFEIEIRA A
PARTIR DE IMAGENS OBTIDAS POR AERONAVE REMOTAMENTE
PILOTADA
ESTIMATION OF BIOPHYSICAL PARAMETERS OF COFFEE
PLANTATION FROM IMAGES OBTAINED BY A REMOTELY PILOTED
AIRCRAFT**

Dissertação apresentada à
Universidade Federal de Lavras,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia Agrícola, para a
obtenção do título de Mestre.

APROVADA em 20 de julho de 2018.

Dr. Virgílio Anastácio da Silva UFLA

Dra. Margarete Marin Lordelo Volpato EPAMIG

Prof. Dr. Gabriel Araújo e Silva Ferraz
Orientador

Prof. Dr. Adriano Valentim Diotto
Co-orientador

**LAVRAS-MG
2018**

À Deus, por me dar oportunidades incríveis de aprendizado, não só acadêmico mas pessoal. Por conceder forças para lutar cada dia, pelo Seu amor incondicional e por direcionar os meus passos nos caminhos do Bem.

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

Ao meu amado noivo, Ricardo, aquela pessoa que Deus colocou em minha vida para levantar em minhas quedas, enxugar minhas lágrimas, não me deixar desistir e sempre colocar um sorriso em meu rosto!

DEDICO

AGRADECIMENTOS

À Universidade Federal de Lavras, especialmente ao Departamento de Engenharia e ao Programa de Pós Graduação em Engenharia Agrícola, pela oportunidade.

À instituição de fomento, Capes pela concessão da bolsa de mestrado.

Ao professor Gabriel Araújo e Silva Ferraz, pela orientação, paciência, conselhos, conversas, atenção, boa vontade, disposição em ajudar e todo o conhecimento compartilhado também.

Ao professor e coorientador Adriano Valentim Diotto pela parceria no experimento e por todo apoio dado no desenvolvimento deste projeto.

Ao professor Diogo Tubertini Maciel, por abraçar a causa do uso de drones na agricultura, por acreditar no projeto, por comprar um drone para nos ajudar nesta missão e por todo apoio e disposição.

A secretaria da pós graduação, na pessoa da Helem, por sempre ser solícita e cheia de boa vontade em nos ajudar.

Aos membros da banca, Margarete Marin Lordelo Volpato e Virgílio Anastácio da Silva, por toda atenção despendida, e por todas as contribuições para o presente trabalho.

Aos alunos de iniciação científica envolvidos nas coletas e processamento dos dados, Leticia Aparecida Gonçalves Xavier, Sthéfany Airane dos Santos, Marco Thulio Andrade, Dayane Saturnino de Santana e a todo grupo de estudo, NESA, que contribuiu para o avanço das pesquisas.

A todos os amigos do departamento, em especial Brenon Diennevan Souza Barbosa, Bruna Pontara Vilas Boas Ribeiro e Maria Alice Junqueira, pela companhia, amizade, conversas, risadas, choros e conselhos.

MUITO OBRIGADA!

RESUMO

A Agricultura de Precisão (AP) se baseia em um conjunto de técnicas e tecnologias que otimiza os recursos utilizados pelo produtor identificando variabilidade espacial na lavoura. Dentro deste conjunto pode-se citar o sensoriamento remoto que auxilia na obtenção de dados remotamente e no suporte localizado de manejos agrícolas. Assim objetivou-se com este trabalho obter medidas indiretas de altura e diâmetro de copa de cafeeiros utilizando imagens de alta resolução espacial detectadas por uma Aeronaves Remotamente Pilotadas (Remotely Piloted Aircraft – RPA); propor modelo que sirva para estimar tais parâmetros; realizar análise da porcentagem de cobertura e índice de área foliar ao longo do meses de acompanhamento e calcular e mapear coeficiente de cultura (Kc) utilizando dados de altura e diâmetro de copa detectados pela RPA. O experimento foi realizado em uma lavoura cafeeira pertencente à Universidade Federal de Lavras, Lavras/MG. Utilizou-se uma RPA de asa rotativa, em modo de voo autônomo, contendo uma câmera convencional, altura de 30 m, com sobreposição de imagem de 80% e velocidade de 3 m/s. As imagens foram coletadas uma vez por mês, de junho de 2017 a março de 2018, no mesmo dia de obtenção das imagens foram coletados, em campo, dados de altura e diâmetro de copa das plantas do cafeeiro a fim de compará-los. O processamento das imagens foi realizado no software PhotoScan e as análises foram feitas no Qgis. Obteve-se correlação de 85% entre valores de altura de campo e valores de altura obtidos por meio da RPA, e 95% de correlação entre valores de diâmetro de copa obtidos em campo e os valores obtidos por meio da RPA, sendo possível propor um modelo de estimação de parâmetros biofísicos, como altura e diâmetro de copa de cafeeiros, tendo valores provindos de imagem obtidas por RPA. Foi possível analisar a Porcentagem de cobertura de terreno e o Índice de Área Foliar por meio de dados remotamente, além de propor um mapa de Kc para a área do estudo.

Palavras-chave: Agricultura de Precisão, Drone, cafeeiros, Sistemas de Aeronaves Não Tripuladas, ortomosaico.

ABSTRACT

Precision Agriculture (PA) is based on a set of techniques and technologies that optimizes the resources used by the producer, identifying spatial variability in the crop. Within this set it is possible to cite the remote sensing that assists in obtaining data remotely and in the localized support of agricultural managements. The objective of this work was to obtain indirect measures of height and diameter of coffee trees using high spatial resolution images detected by a Remotely Piloted Aircraft (RPA); propose a model that may be used to estimate such parameters; to perform analysis of the coverage percentage and leaf area index over the follow-up months and to calculate and to map coefficient of culture (Kc) using data of height and canopy diameter detected by RPA. The experiment was carried out in a coffee plantation belongs at the Federal University of Lavras, Lavras, MG. A rotating wing RPA was used in autonomous flight mode, carrying a conventional camera, height of 30 m, with image overlap of 80% and velocity of 3 m/s. The images were collected once a month, from June 2017 to March 2018, at the same day that the images were collected, data of height and canopy diameter of the coffee plants where collected in the field as well, in order to compare them. The images were processed in the PhotoScan software and the analyzes were done in Qgis. It was obtained a correlation of 85% between field height values and height values obtained through RPA, and 95% correlation between values of canopy diameter obtained in the field and the values obtained through RPA. It made possible to propose an estimation equation of biophysical parameters, such as height and crown diameter of coffee trees, by using values derived from image obtained by RPA. It was possible to analyze the Percentage of land cover and Foliar Area Index by data obtained remotely, besides proposing a map of Kc for the variety of coffee under study.

Keywords: Precision Agriculture, Drone, coffee, Unmanned Aircraft Systems (UAS), orthomosaic.

SUMÁRIO

1 INTRODUÇÃO	7
2 REFERENCIAL TEÓRICO	9
2.1 Aspectos Gerais da Cultura do Cafeeiro	9
2.2 Agricultura de Precisão e Cafeicultura de Precisão	10
2.3 Sensoriamento Remoto	12
2.4 Aeronaves Remotamente Pilotadas	14
2.4.1 Aeronaves Remotamente Pilotadas na Agricultura	15
3 MATERIAL E MÉTODOS	16
3.1 Visão Geral do estudo	16
3.2 Caracterização da área de estudo	17
3.3 Planejamento de voo e aquisição das imagens	19
3.4 Processamento das imagens	22
3.5 Coleta de dados de campo	26
3.6 Obtenção de Parâmetros Biofísicos	27
3.7 Estatísticas e validação de dados	29
4 RESULTADOS E DISCUSSÃO	31
4.1 Estimativa da altura e diâmetro de copa dos cafeeiros	31
4.2 Porcentagem de cobertura do terreno obtida pela aeronave	39
4.3 Índice de Área Foliar obtido pela aeronave	42
4.4 Coeficiente de Cultura obtido pela aeronave	44
5 CONCLUSÃO	45
REFERÊNCIAS	45

1 INTRODUÇÃO

O Sensoriamento Remoto (SR) é uma tecnologia de obtenção de dados e pode ser usado na Agricultura de Precisão (AP) a fim de detectar variações no campo, podendo identificar áreas mais produtivas, áreas não homogêneas e áreas que apresentam alguma anomalia. Estas áreas podem ser reconhecidas, de maneira indireta, como zonas de manejo para posterior intervenção de maneira diferenciada, aplicando técnicas de AP. Tais áreas podem ser localizadas por meio de vários tipos de plataformas dependendo da altitude, como satélites geoestacionários, estações espaciais, aviões, helicópteros, aeronaves pequenas controladas por controle remoto, balões dirigíveis, entre outras, que podem ser utilizadas indiretamente para coletar dados.

Geralmente, com plataformas mais próximas ao alvo obtém-se imagens de maior resolução espacial. Essas imagens são importantes, pois além de detalhar podem detectar variações no campo, na qual um homem por si só, teria que percorrer a lavoura com muita atenção a fim de identificar alguma anomalia. Além do ganho em precisão, o mapeamento com imagens de alta resolução espacial permite extrair parâmetros importantes da planta, como: altura, diâmetro de copa, espaçamento, detectar padrões e áreas homogêneas. Outra vantagem seria a obtenção de respostas de campo com mais rapidez por meio de uma imagem, facilitando manejos e intervenções na lavoura.

Dentro deste contexto, para monitoramento de lavouras, quantificação de falhas de plantio, aplicação de índices de vegetação, dentre outras aplicações pode-se utilizar as Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft* – RPA, termo em inglês), conhecidas também como “drone” ou “VANT” (Veículo Aéreo Não Tripulado) que podem captar estes dados e informações indiretamente. Estas plataformas, antigamente de uso exclusivo de militares, hoje se tornaram uma tecnologia mais acessível e flexível, podendo embarcar câmeras e sensores, estando mais disponível ao agricultor. Estas aeronaves podem ser de asas fixa ou rotativa, e as imagens captadas por elas podem apresentar baixo custo em relação as imagens obtidas por satélites e as aeronaves tripuladas. Possuem ainda como vantagem a capacidade para realizar missões programáveis, variando velocidade da aeronave, altura de voo, sobreposição das imagens, e voos de forma automática. Além de ter alta resolução espacial, tem-se também uma excelente resolução temporal, pois a maioria dos satélites tem um tempo de revisita determinado, realizando o mapeamento de uma área, a cada 16 dias como o Landsat, ou

a cada 2,4 dias como Quickbird. Já as RPA podem ser operadas a qualquer momento, desde que tenha condições climáticas favoráveis e autonomia de voo suficientes.

As RPA são plataformas com alto potencial de SR para a AP pela sua autonomia e facilidade de obtenção de dados no meio agrícola. Pesquisas já realizadas para as culturas de grãos e culturas perenes mostraram-se eficientes e ressaltaram as potencialidades desta tecnologia para a AP. Entretanto para a cafeicultura, as pesquisas ainda são incipientes utilizando esta tecnologia.

O cenário mundial de produção de café para a safra 2017/2018 prevê 159 milhões de sacas (60 kg), tal previsão é equiparada com a safra 2016/2017, porém o consumo mundial de café tem aumentado sendo previsto um consumo de 158 milhões de sacas, o Brasil tem participação significativa nestes dados de produção do grão, sendo o maior produtor e contribuindo com 45,5 % da produção mundial de café arábica, e o segundo maior produtor contribuindo com 18 % da produção mundial de café robusta, na produção total do grão o Brasil ocupa a primeira posição contribuindo com 32,7 % do total da produção mundial (USDA, 2018).

Sendo o café uma cultura de valor comercial agregado, importante para o agronegócio brasileiro, este tipo de estudos se mostram promissores e necessários para o monitoramento da cultura. Desta forma, acredita-se que é possível determinar parâmetros biofísicos de uma lavoura cafeeira a partir de imagens de alta resolução espacial obtidas por RPA.

Diante do exposto, o presente trabalho teve como objetivo:

- a) Obter de medidas indiretas de altura e diâmetro de copa de cafeeiros utilizando imagens de alta resolução espacial detectadas por uma RPA;
- b) Propor modelo para estimar parâmetros biofísicos por meio das imagens obtidas pela RPA;
- c) Realizar análise da porcentagem de cobertura e índice de área foliar ao longo do meses de acompanhamento e;
- d) Demonstrar uma aplicabilidade dos dados obtidos para a cultura do café, através do cálculo e mapeamento do coeficiente de cultura (K_c) utilizando dados de altura e diâmetro de copa detectados pela RPA.

2 REFERENCIAL TEÓRICO

2.1 Aspectos Gerais da Cultura do Cafeeiro

O cafeeiro (*Coffea sp*) é uma planta de sub-bosque, arbusto da família Rubiaceae, apresenta um ciclo fenológico de dois anos e um crescimento contínuo, com ramos ortotrópicos que crescem verticalmente e ramos plagiotrópicos que crescem horizontalmente. Oriundo das regiões altas da Etiópia (África), segundo Guimarães et al. (2002) o café se expandiu para Arábia, levado por mercadores, chegando no século XVII, na Itália e Inglaterra no ano de 1670, chegou na França no ano de 1671, posteriormente Alemanha, Suíça, Dinamarca, Holanda, Guiana Holandesa (hoje Suriname), Guiana Francesa, até chegar no Brasil (Belém do Pará) em 1727, de onde foi levado para o Rio de Janeiro e difundido para os estados de São Paulo, Minas Gerais e Espírito Santo. (MENDES; GUIMARÃES, 1997; GRANER; GODOY JUNIOR, 1967).

O café é uma *commodite* agrícola com importância no mercado tanto nacional como internacional. Segundo Cunha et al. (2017), o setor do café movimenta 35 bilhões de dólares anualmente à nível mundial. Os maiores produtores na safra de 2016/2017 foram Brasil, Vietnã seguido da Colômbia (USDA, 2018). Os principais estados produtores no país são Minas Gerais, Espírito Santo, São Paulo, Paraná, Bahia e Rondônia (CUNHA et al., 2017).

Por ter valor agregado e ser um dos principais produtos agrícolas, entender alguns parâmetros biofísicos é útil para acompanhar o crescimento, o desenvolvimento e a produtividade da cultura. Estudos sobre o crescimento e desenvolvimento do cafeeiro, tem uma vasta aplicação na pesquisa agropecuária, pois permite ao pesquisador comparar o comportamento de uma planta ou uma parte de interesse diante diferentes situações de experimentos (MAIA et al., 2009).

Alguns parâmetro biofísicos que podem inferir sobre o crescimento e desenvolvimento de uma cultura são: altura de planta (m), diâmetro de copa (m), espaçamento entre linhas (m), espaçamento entre plantas (m), IAF ($m^2 m^{-2}$), porcentagem de cobertura do terreno pelas plantas (%), rugosidade (m), densidade populacional (número de plantas ha^{-1}) e biomassa ($t ha^{-1}$). Estudos realizados por Ramirez e Zullo Júnior (2010) estimaram tais parâmetros a partir de imagens de satélites com alta resolução.

O índice de área foliar (IAF) é a relação entre a área foliar e a área do terreno ocupado pela cultura. Segundo Favarin et al. (2002), a área foliar de uma cultura é um

parâmetro indicativo de produtividade devido ao processo fotossintético ocorrido nas folhas. Assim, com este parâmetro é possível inferir a eficiência fotossintética, padrões de crescimento e desenvolvimento, variações no crescimento causadas por diferenças ambientais e genéticas e danos decorrentes de pragas, doenças e manejo (FONSECA; CONDÉ, 1994).

O consumo de água de uma cultura pode ser estimado por meio de coeficientes de cultura (K_c) que está relacionado com a evapotranspiração da cultura (ET_c), avaliada experimentalmente, e a evapotranspiração de referência (ET_o), obtidas por lisímetros ou pelo emprego de modelos de estimativa (STONE; SILVEIRA, 1995; OLIVEIRA et al., 2007). Durante o ciclo de uma cultura, ter o conhecimento da evapotranspiração da cultura e seu coeficiente de cultura é de suma importância para dimensionar e manejar sistemas de irrigação (OLIVEIRA et al., 2007), segundo os mesmos autores, a evapotranspiração da cultura não deve ser estabelecida com base em um único valor de K_c , pois dependendo da época do ano, pode prejudicar as plantas com excesso de irrigação ou com déficit hídrico. Valores de K_c de um cafeeiro adulto encontrados por Oliveira et al. (2003) no período de junho a setembro variaram de 0,72 até 1,50.

Neste contexto, estimar os valores de K_c com base em parâmetros biofísicos de plantas de cafeeiros pode ser adequado e viável, quando comparado com a determinação de coeficiente que requer experimentação agrônômica. A produção de café se faz uso de diversas variedades, além de se encontrar em regiões climáticas distintas, o K_c de uma cultura pode variar de acordo com seu estágio de desenvolvimento, o clima e até mesmo a variedade em questão.

2.2 Agricultura de Precisão e Cafeicultura de Precisão

A Agricultura de Precisão (AP), segundo Bernardi et al. (2015), pode ser definida como práticas agrícolas baseadas em tecnologias de informações que buscam o tratamento da variabilidade espacial da lavoura, na qual constitui-se no ciclo de coleta de dados, análises e interpretação, geração de recomendações, aplicação no campo e avaliação dos resultados (GEBBERS; ADAMCHUK, 2010).

A AP utiliza-se de métodos e técnicas a fim de monitorar áreas com maior precisão. Objetiva-se identificar variações no campo utilizando tecnologias geoespaciais para lidar com a variabilidade (ZHANG; KOVACS, 2012). Pode-se entender que a AP se apresenta como um conjunto de tecnologias, nas quais o agricultor pode optar por formar um sistema que atenda às suas necessidades de campo e ao seu estilo de gestão

(BATTE; EHSANI, 2006), a fim de identificar estratégias para aumentar eficiência e rentabilidade.

Entretanto, a AP não é só aplicada em propriedades com grandes extensões, Stafford (2000) pontua que há séculos os agricultores consideram a variabilidade espacial na implantação da lavoura. Logo os agricultores mais observadores e experientes reconhecem áreas diferentes na sua propriedade, áreas com maior capacidade de reter água, áreas com maior quantidade de matéria orgânica, áreas com boa drenagem, áreas que precisam de correção, plantas que necessitam de uma quantidade maior de irrigação, adubação, sendo estes, fatores que influenciam na decisão de implantar e manejar culturas.

Assim, considerar a variabilidade é considerar que a lavoura não é uniforme, tendo várias aptidões agronômicas dentro de uma mesma propriedade, mesmo que pequena (INAMASU; BERNARDI, 2014).

Na cafeicultura, a AP, ainda precisa ser desenvolvida e implantada, mas há uma propensão para que seja pesquisada, difundida e adotada devido aos benefícios que pode suscitar como eficiência, sustentabilidade ambiental e econômica. Segundo Balastreire et al. (2001) no Brasil há um vasto campo para ser pesquisado e aplicado a AP, não somente pela importância, mas também pelo alto grau tecnológico e valor econômico das lavouras.

A Cafeicultura de Precisão se baseia na aplicação da AP na cultura do café, e este termo foi elucidado por Alves, Queiroz e Pinto (2006). De acordo com Ferraz et al. (2012), a Cafeicultura de Precisão é definida 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.

Na literatura, diversas pesquisas já foram realizadas aplicando a AP na cafeicultura com a finalidade de se estudar a variabilidade espacial de atributos de solo (FERRAZ, et al. 2012), planta (FERRAZ et al., 2017), produtividade (FERRAZ, et al. 2012; FONSECA et al., 2015), aplicação à taxa variável (BARROS et al., 2015; MOLIN et al., 2010), modelagem de doenças como a ferrugem e a cercospora (ALVES et al., 2009).

Porém novas tecnologias na área de sensoriamento remoto estão surgindo dando outro enfoque para utilização da AP na cafeicultura. Ainda existem poucos trabalhos que estudam a dosagem de insumos. Mas com sensores embarcados em RPA, será possível

obter o mapeamento, por exemplo, de plantas daninhas com o voo e realizar mapas de aplicação de defensivos de forma localizada e precisa. Já existem estudos como estes, porém em culturas de grãos, no entanto, para cafeicultura seriam estudos importantes para redução de insumos. Além de outras aplicações pontuais e precisas, como identificação de doenças, pragas, desfolha, que podem ser estudadas para o avanço da cafeicultura de precisão.

2.3 Sensoriamento Remoto

Dentro destas tecnologias geoespaciais que a AP utiliza para detectar a variabilidade de campo pode-se citar: Sistemas de Informação Geográfica; Sistema Global de Navegação por Satélite (GNSS); Sensoriamento Remoto (SR); sensores de: solo, planta, produtividade; dispositivos de aplicação à taxa variável; entre outros que podem auxiliar na obtenção de dados e dar suporte localizado no manejo agrícola.

Sendo a agricultura uma prática muito dinâmica, há a necessidade de ter um frequente monitoramento, e dentro deste contexto tem-se os produtos derivados do SR que podem oferecer dados e informações em tempo quase que real (SEELAN et al., 2003). A AP segundo o mesmo autor, requer informações frequentes sobre determinado cultivo ao longo do seu estágio de desenvolvimento, e muitas vezes estas informações precisam ter alta resolução espacial.

Segundo Moriya (2015), os produtos de SR tem um potencial grande nas aplicações da AP, incentivando o desenvolvimento de novas abordagens metodológicas e aplicações que produzam informações espaciais de boa qualidade para auxiliar o produtor rural nas decisões e planejamento de culturas.

O SR obtém informações sobre alvos através de sensores em plataformas a nível orbital, chegando a uma resolução espacial de 0,61 cm na banda pancromática obtida pelo satélite QuickBird (RANGO et al., 2006). Ramirez e Zullo Júnior (2010) utilizando as bandas verde e azul deste satélite com resolução espacial de 2,44 m, concluíram que o uso de tais imagens com alta resolução espacial são promissoras no estudo de áreas cafeeiras por obter um maior detalhamento da área e a detecção de características biofísicas importantes para a cultura. No nível suborbital, utilizando RPA, Rango et al. (2006) conseguiram uma resolução espacial de 5 cm podendo ser útil em estudos que requer um nível de detalhamento maior. A resolução espacial das RPA está diretamente relacionada com a altura de voo, Severtson et al. (2016) conseguiram uma resolução especial de 8,1 mm e 65 mm, com altura de voo de 15 e 120 m respectivamente.

Apesar das plataformas de SR em nível orbital obterem uma resolução espacial em metros e até em centímetros, dependendo do satélite, segundo Zhang e Kovacs (2012), em casos emergenciais de acompanhamento de culturas, análise de déficit nutricional, previsão de safra, estes sensores orbitais não podem fornecer dados contínuos. Além disso tem limitações como custos elevados, falta de flexibilidade operacional e baixa resolução espacial e temporal (WHITEHEAD; HUGENHOLTZ, 2014). Outro fator que interfere na aquisição de imagens em nível orbital, são as condições climáticas, em dias nublados, pois há o impedimento da passagem da energia solar e conseqüentemente a perda de informação de dados da superfície (HONKAVAARA et al., 2013).

Mesmo com os avanços da ciência em SR, devido às limitações citadas, alguns estudos foram realizados para buscar plataformas diferentes nos quais se mostrassem eficientes na obtenção de dados remotos com custos mínimos. Alguns exemplos destas plataformas estudadas foram os dirigíveis (INOUE et al., 2010; VERICAT et al., 2008); balões (VIERLING et al., 2006) e pipas (ABER et al. 2002; ABER et al., 2009). Embora sejam plataformas com custo reduzido em relação as plataformas orbitais, tais dependem de manobras manuais operacionalmente impraticáveis para certos locais dificultando o monitoramento e acompanhamento de culturas, por exemplo (WHITEHEAD; HUGENHOLTZ, 2014; ZHANG; KOVACS, 2012).

Segundo Whitehead e Hugenholtz (2014), existem várias peculiaridades que torna a RPA uma tecnologia potencial como: baixo custo em relação à aeronaves pilotadas e às plataformas orbitais; obtenção de dados de forma autônoma e capacidade de realizar missões; capacidade de operar em condições climáticas adversas e em ambientes perigosos e menor risco de exposição do piloto.

Sendo assim, as RPA estão sendo estudadas e utilizadas para obtenção de imagens de alta resolução temporal (adquiridas várias vezes por dia), resolução espacial (em centímetros e até em milímetros) além de baixos custos operacionais comparados com aeronaves tripuladas e principalmente os satélites de alta resolução espacial (HARDIN; HARDIN, 2010; HONKAVAARA et al., 2013; HUNT et al., 2005; LALIBERTE; RANGO, 2011; LELONG et al., 1998; NEBIKER et al., 2008; RANGO et al., 2009; TORRES-SÁNCHEZ et al., 2014; XIANG; TIAN, 2011). Podendo ser aplicadas em áreas menores e em locais pontuais com facilidade de obtenção de dados em menor tempo, acompanhando o crescimento de diversas culturas.

2.4 Aeronaves Remotamente Pilotadas

Atualmente, uma recente forma de aquisição de imagens digitais remotas tem emergido, os Sistemas de Aeronaves Não Tripuladas correspondente à terminologia em inglês *Unmanned Aircraft Systems* (UAS). No Brasil, segundo a portaria DECEA, os UAS são compostos por aeronaves com elementos associados e empregadas sem piloto a bordo, podendo ser Aeronaves Remotamente Pilotadas (RPA) ou Aeronaves totalmente autônoma (DECEA, 2017).

As RPA são aeronaves cujo controle é remoto, através de interface como computador; simulador; dispositivo digital ou controle remoto, diferente das Aeronaves Autônomas que uma vez programadas não tem intervenção externa durante o voo, tendo seu uso proibido no Brasil (DECEA, 2017). As RPA são consideradas uma subcategoria das aeronaves não tripuladas.

O termo *Unmanned Aerial Vehicles* (UAV), segundo a ICAO (2016), é um termo obsoleto, pois as organizações da aviação empregam o termo aeronave, assim adotou um termo que seja reconhecido mundialmente para se ter uma padronização, outro motivo deve-se à complexidade destas aeronaves para funcionar, na qual requer estação em solo, o enlace de pilotagem entre a aeronave e o piloto além de outros elementos necessários para concretizar um voo seguro, com isso o termo veículo seria inapropriado para representar todo o sistema que precisa-se levar em consideração.

Estudos relacionados com UAS tem-se desenvolvido mundialmente proporcionando pesquisas sobre estes ou popularmente conhecidos por drones, nome originário dos Estados Unidos, cujo significado do termo em inglês vem de zangão, zumbido, devido ao som que produz quando em funcionamento, se assemelhando ao zumbido de tal inseto. Existem outras terminações encontradas na literatura como *Unmanned Aerial Vehicles* (UAV) (CANDIAGO et al. 2015; GRENZDÖRFFER; ENGEL; TEICHERT, 2008; LÓPEZ-GRANADOS et al., 2016; PEÑA et al., 2013; TOKEKAR et al., 2016), *Remotely Piloted Aircraft Systems* (RPAS) (CRISTEA et al., 2016), *Remotely Piloted Aircraft* (RPA) (GILES, 2016; ZAJKOWSKI et al., 2016; ICAO, 2016), *Remotely Piloted Vehicles* (RPV) (HARDIN; HARDIN, 2010; SIEBERT; TEIZER, 2014), *Unmanned Aircraft Systems* (UAS) (WHITEHEAD; HUGENHOLTZ, 2014; ICAO, 2016), *Remotely Operated Aircraft* (ROA) (UYSAL; TOPRAK; POLAT, 2015), VANT (Veículos Aéreos Não Tripulados) (MEDEIROS et al., 2008).

Diante desta situação e de várias terminologias que surgiram para representar estas aeronaves, a ICAO (2016) designou o termo RPA como padrão, assim também neste trabalho, utilizar-se-á deste termo.

2.4.1 Aeronaves Remotamente Pilotadas na Agricultura

Pesquisas na literatura científica mostram que as imagens digitais obtidas por meio de RPA têm sido utilizados com sucesso para gerar diversos produtos para diversas culturas. Em seus estudos Primicerio et al. (2012) coletaram imagens obtidas por meio de uma plataforma hexacóptero com câmera contendo infravermelho próximo (*Near Infrared- NIR*) nos quais obtiveram Índices de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index- NDVI*) de um vinhedo cujos dados estavam em concordância com os dados de refletância obtidos em campo, assim foi possível gerar mapas de vigor vegetativo.

Gómez-Candón et al. (2016) obtiveram boa correlação de imagens térmicas obtidas por RPA com dados de campo medidos com termoradiômetros, na cultura de macieira metade irrigada e metade submetida à estresse hídrico. Observaram a temperatura da copa significativamente mais alta em árvores estressadas.

Pesquisas sobre a dinâmica de vegetação em florestas, identificação de clareiras e monitoramento foram realizadas por Getzin, Wiegand e Schöning (2012), concluíram que o uso de RPA podem ser utilizadas para tais estudos, obtendo imagens de alta resolução e também sendo ferramenta para controle de florestas. Os autores ponderam que o baixo custo das missões com RPA permitem registrar a dinâmica da vegetação durante o ano.

Panagiotidis et al. (2016) estimaram altura e diâmetro de copa de uma área florestal por meio imagens obtidas por RPA, para as alturas utilizaram modelos de altura de dossel (*Canopy height models- CHM*) e para diâmetro, as imagens foram segmentadas e utilizaram ferramentas de medida disponíveis em software de geoprocessamento, e com isso correlacionaram estes dados com medições de campo e obtiveram precisão aceitável concluindo que o método é viável para extração de tais parâmetros.

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

Herwitz et al. (2004) utilizaram RPA para coleta de imagens com objetivo de monitorar e apoiar as decisões na plantação de café, para os autores vários aspectos de manejo da cultura podem se beneficiar da observação aérea. O estudo demonstrou a

capacidade de monitoramento da RPA em um período prolongado, além de obter imagens com alta resolução espacial, mapear focos de capim-colonião e diferenciar a cobertura do solo nas áreas monitoradas, assim concluíram que as RPA é uma ferramenta ampla que complementa a utilização de satélites e aeronaves pilotadas para apoio à agricultura.

Com isso, verifica-se que existem trabalhos na literatura aplicando a tecnologia em algumas culturas perenes. Logo vê-se a necessidade de ampliar os estudos e contribuir para o desenvolvimento do agricultura agregando ainda mais valor para a cafeicultura, pois a utilização da RPA para imageamento de áreas cafeeiras pode-se obter produtos rápidos, com baixo custo, alto valor tecnológico e com grande precisão, desde que tenha uma metodologia e sejam processadas e analisadas corretamente.

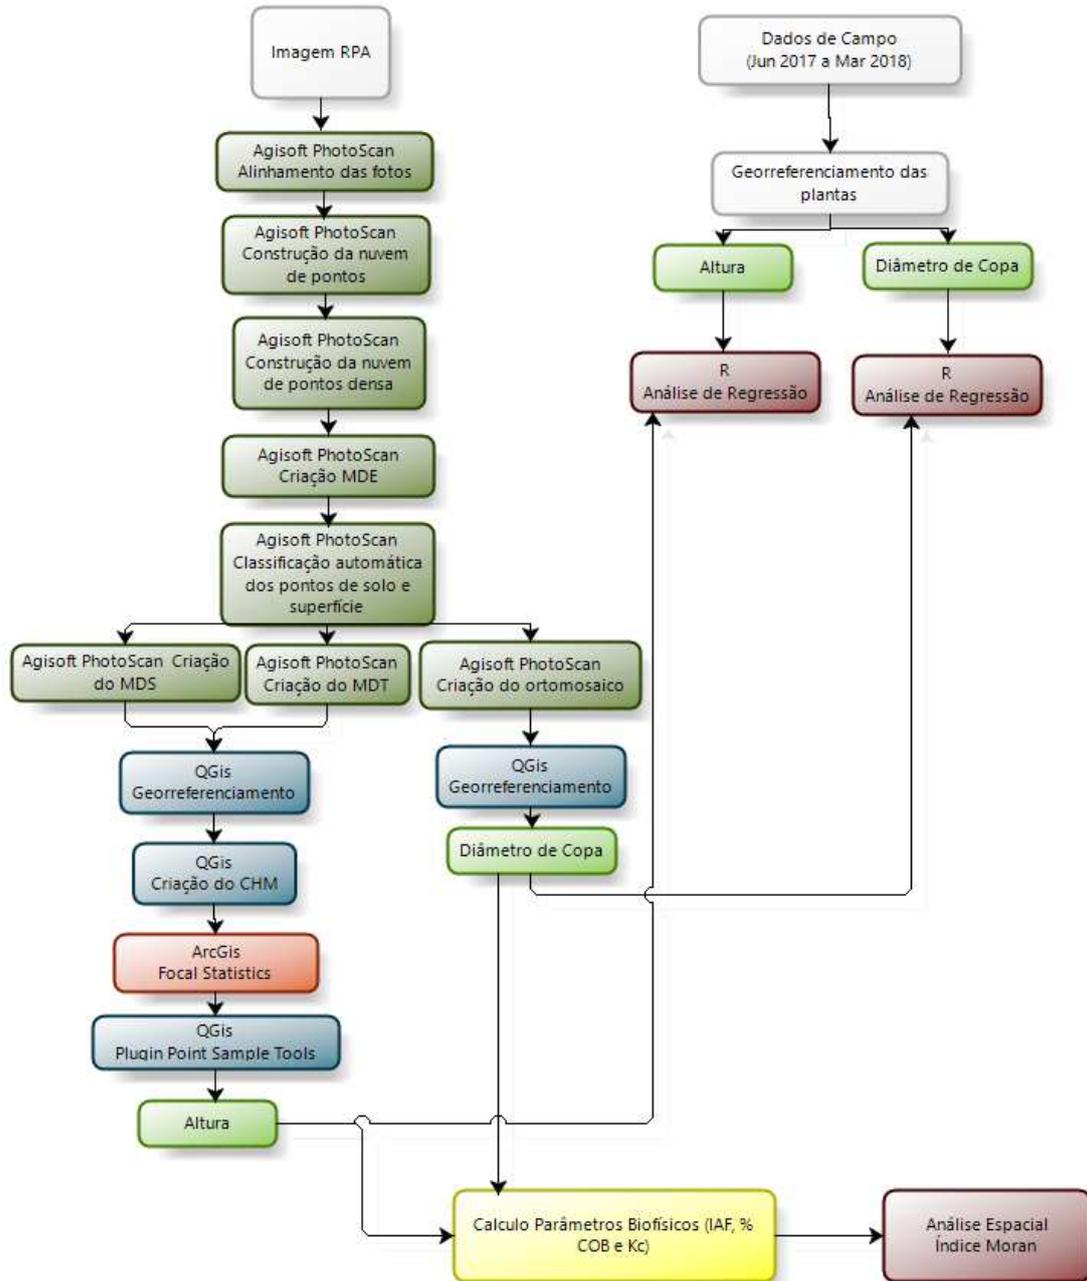
3 MATERIAL E MÉTODOS

3.1 Visão Geral do estudo

Foram abordadas diferentes etapas de trabalho, tais como: caracterização da área experimental, obtenção das imagens, coleta de dados in situ, processamento das imagens, obtenção de parâmetros biofísicos, estatística e validação dos dados.

A Figura 1 ilustra de forma resumida a metodologia utilizada.

Figura 1 - Fluxograma da metodologia usada.

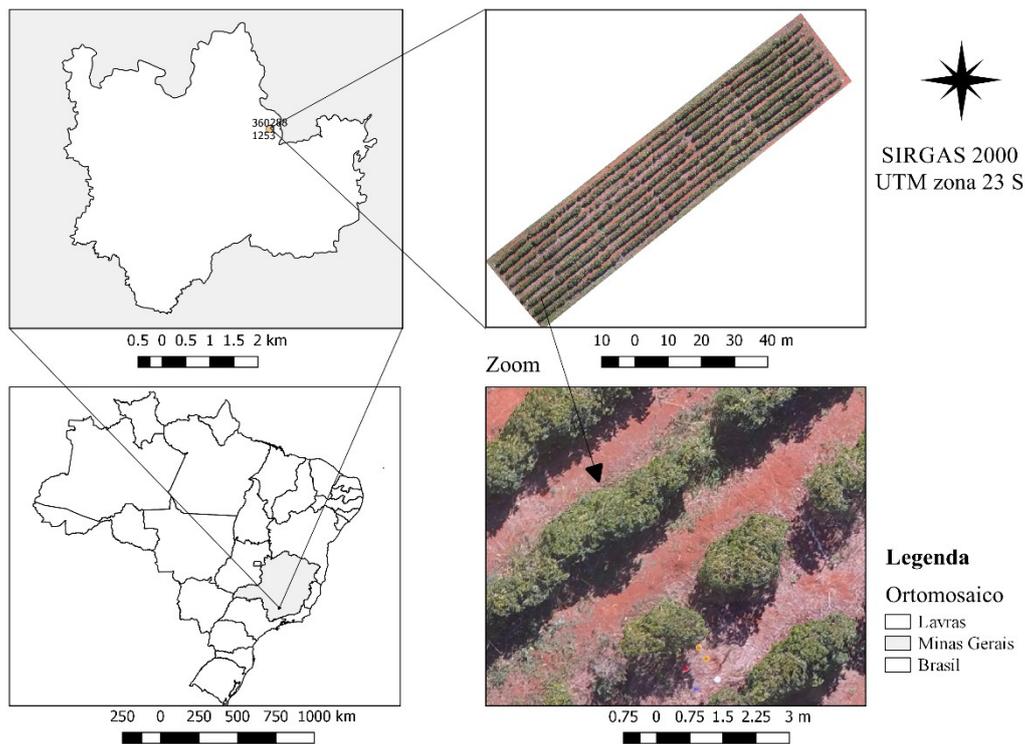


Fonte: Da autora (2018).

3.2 Caracterização da área de estudo

A área de estudo é remanescente de um experimento, cujos tratamentos são descritos por Caldas et al. (2018), localizada no município de Lavras, Minas Gerais, em uma área de 0,32 ha de lavoura cafeeira pertencente à Universidade Federal de Lavras (UFLA), as coordenadas geográficas central da área são 21°13'33.17" de latitude sul e 44°58'17.54" de longitude oeste de Greenwich e 936m de altitude (FIGURA 2).

Figura 2 - Localização da área de estudo.



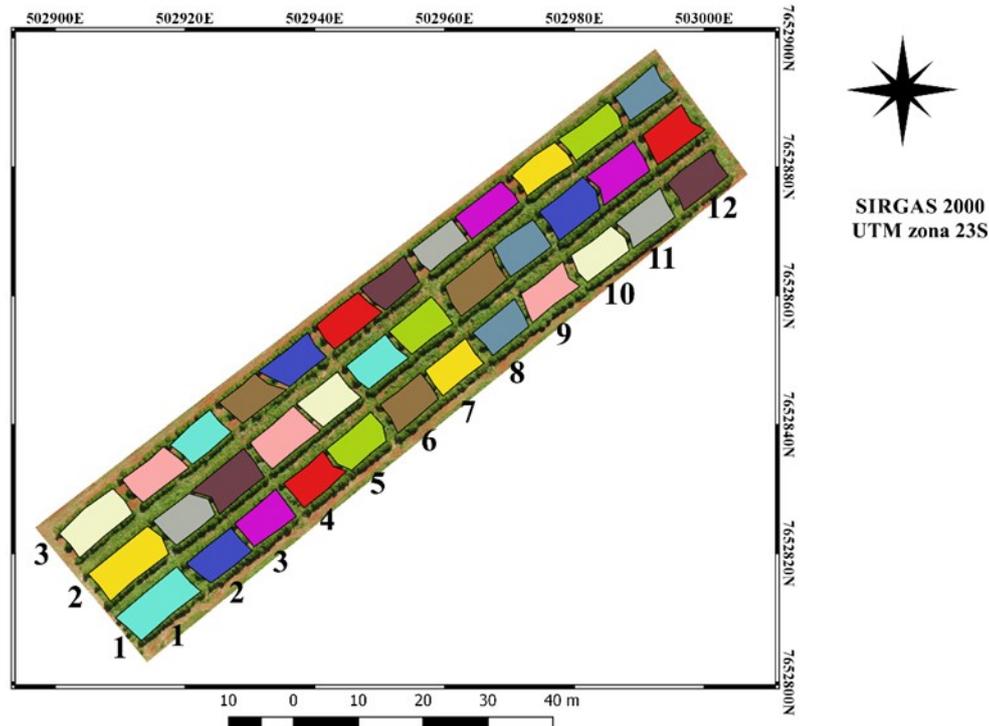
Fonte: Da autora (2018).

O clima da região, segundo a classificação de Koppen, é do tipo Cwa, caracterizado por uma estação seca no inverno e uma estação chuvosa no verão, a precipitação média anual é de 1.460mm e a temperatura média anual de 20,4°C, com a mínima de 17,1 °C em julho e a máxima de 22,8 °C em fevereiro (DANTAS; CARVALHO; FERREIRA, 2007).

A cultura foi implantado em fevereiro de 2009 com a espécie *Coffea arabica* L., cultivar Travessia e espaçamento de 2,60 x 0,60m, totalizando 36 blocos com 3 linhas de plantio e 14 plantas por linhas (FIGURA 3). Os cafeeiros passaram pelo processo de poda (esqueletamento) na terceira semana de julho de 2016. O esqueletamento, segundo Queiroz-Voltan et al. (2006) é considerado uma poda drástica que consiste na eliminação de grande parte dos ramos plagiotrópicos, cerca de 20 cm no topo finalizando com 40 cm nos plagiotrópicos baixeiros, com recuperação da produção em torno de um ano.

Em 2017 não houve continuação dos tratamentos impostos de irrigação e fertirrigação, ficando um provável efeito residual das adubações anteriores.

Figura 3 - Croqui da área experimental com a distribuição dos blocos.



Fonte: Da autora (2018).

3.3 Planejamento de voo e aquisição das imagens

O desenvolvimento do projeto consistiu na obtenção de imagens da lavoura cafeeira, previamente descrita, utilizando câmera convencional embarcada na aeronave remotamente pilotada (FIGURA 4), cujo controle é realizado por meio de um controle remoto integrado com sistema de posicionamento global por satélite (GNSS), com voo autônomo. As imagens foram coletadas durante os meses de junho de 2017 a março de 2018. No mesmo dia de obtenção das imagens, foram coletados dados de campo (que serão descritos no ítem 3.5 deste trabalho) para posteriores correlações.

A aeronave utilizada, modelo DJI Phantom 3 profissional, se classifica como plataforma de asa rotativa com quatro hélices (quadricóptero) (FIGURA 4), com quatro motores alimentados por uma bateria, com decolagem e aterrissagem vertical, autonomia de voo de até 23 minutos e *Gimbal* para estabilização da câmera, amortecimento e correção de orientação durante a obtenção das fotos, orientado perpendicularmente ao solo.

Figura 4 - Aeronave Remotamente Pilotada com destaque para a câmera, hélice e controle remoto.

Hélices



Controle Remoto

Câmera

Fonte: Da autora (2018).

A câmera digital fica acoplada em sua estrutura, da marca Sony, modelo EXMOR 1/ 2.3'', com resolução de 12 megapixels em cores verdadeiras (*Red-R, Green-G, Blue-B*) espectro do visível, e resolução radiométrica de 8 bits, lente 20 mm com abertura óptica de $f/2.8$, com resolução de 4000 x 3000 pixels (12 megapixel). As imagens capturadas foram armazenadas em um Cartão SD para posteriores análises.

O planejamento de voo é uma etapa preliminar primordial para obtenção de produtos de qualidade e que supram os objetivos. Para realizar o planejamento de voo, existem softwares que podem ser utilizados ainda no escritório para realização de tal ação, enviando posteriormente o plano de voo para a RPA. Outra possibilidade seria realizar o planejamento por meio de aplicativos instalados em Smartphone ou tablets conectados no controle remoto da RPA que permitem realizar o planejamento das missões minutos antes do voo. Para cada Aeronave, seja ela de asa fixa ou rotativa, haverá um software ou aplicativo compatível para planejar e executar missões como mostram os estudos realizados por Romero et al. (2015) na qual para eBee utilizou-se o eMotion 2, para o X8 utilizou o Mission Planner e para o Phantom 2 utilizou o aplicativo DJI-Phantom.

Neste estudo, os voos foram planejados com o aplicativo DroneDeploy (2016), software gratuito instalado em um android, e que está relacionado com FCU da RPA (*Flight Control Unit - Unidade de Controle de Voo*). Este sistema é chamado de *Ground Station* (Estação de Solo) e é composto por subsistemas de telemetria e registro, manobras automáticas e planejamento de missão. Através desta Estação de Solo que realiza o planejamento do voo configurando rota, velocidade, sobreposição de imagem e altura de

voo, e também é responsável pelo enlace de pilotagem (*downlink*), que tem por objetivo prover indicação dos dados como posição e situação atual (atitude, velocidade, quantidade de imagens, bateria, etc.) da RPA para o piloto remoto, a fim de permitir o gerenciamento do voo.

Geralmente os softwares ou aplicativos permitem planejar e executar o voo sendo possível realizar algumas definições de voo antes da execução da missão. Nos softwares e aplicativos compatíveis para cada RPA, é possível criar um projeto novo, o usuário pode informar dados para configurações de projeto como: sistemas de coordenadas, área e configurações da câmera que são importantes para o funcionamento correto da missão, sendo que todas estas informações serão armazenadas em um banco de dados que posteriormente será enviado para que a aeronave execute (HERNANDEZ-LOPEZ et al., 2013).

Depois de ativar o projeto deve-se delimitar a área de interesse, definir a sobreposição das imagens, altitude de voo, direção de voo e velocidade da aeronave. Alguns softwares não dão a opção de sobreposição longitudinal e lateral.

Investigações realizadas por Mesas-Carrascosa et al. (2016) mostram que a sobreposição é um fator que interfere na precisão e qualidade do produto final. Os autores testaram duas configurações de sobreposição longitudinal e transversal (80%–50% e 70%–40%), e constataram que a maior sobreposição (longitudinal 80% e transversal 50%) foi a mais recomendada para elaboração do ortomosaico. Porém, dependendo do objetivo e do produto final, a realização de sobreposições maiores aumentará o tempo de captura das imagens, o que resultará numa quantidade maior de nuvem de pontos e consequentemente maior o tempo de processamento. Deve-se assim estudar e avaliar se há a necessidade de uma maior quantidade de sobreposições para a aplicação utilizada.

Uma recomendação dos autores Siebert e Teizer (2014) é usar áreas de cobertura longitudinais e transversais suficientes pelo menos 70 e 40%, respectivamente. No estudo, estas faixas tiveram sobreposições lateral (*side-lap*) de 80% e longitudinal (*forward-lap*) de 80% a fim de gerar corretamente o mosaico da imagem, a altura de voo para a captura das imagens foi padronizada a 30 m de altitude em relação ao solo (TABELA 1).

A velocidade é um parâmetro importante a ser definido, pois velocidades altas podem causar desfoque e um efeito de arrasto, gerando borrões na imagem. Foi adotada a velocidade horizontal de 3 m/s, resultado de teste preliminares, que permite imagens nítidas (TABELA 1).

Tabela 1 - Parâmetros definidos para missão executada pela RPA.

Câmera	Sony EXMOR 1/ 2.3''
Resolução da Câmera	12 MP
Distância Focal	20 mm
Recobrimento Vertical	80%
Recobrimento Horizontal	80%
Resolução espacial	4 cm
Altitude de Voo	30 m
Velocidade	3 m/s
Área imaginada	0,42 ha

Fonte: Da autora (2018).

Segundo Bater et al. (2011), as imagens de câmeras RGB são fortemente influenciadas por mudanças de iluminação horárias, diárias e sazonais, desta maneira, durante o período de coleta, padronizou-se a obtenção das fotos entre o período de 11 a 14 horas, visando obter o período de maior luminosidade na área.

Após a realização do planejamento de voo pode-se enviar a rota do software para a RPA, esta conexão é chamada na literatura de *downlink* (ZHANG; KOVAC, 2012). As imagens capturadas podem assim ser transmitidas (*downlink*) para a estação terrestre ou armazenados em cartão de memória acoplado na RPA.

Antes da realizar o voo fez-se avaliação da área e observou-se alguns fatores de segurança para operação da aeronave, para o operador e para as pessoas envolvidas ao redor da operação, como: condições climáticas; presença de objetos, postes, árvores, torres de transmissão elétrica; locais apropriados para voo longe de aeroportos e áreas com alta densidade populacional; local de pouso e decolagem; condições do terreno e fatores limitantes referentes à legislações vigentes.

Uma vez configurado o plano de voo, deve-se salvar a missão. Para executar a missão, deve-se conectar o smartphone, tablet ou computador ao controle remoto da Aeronave via USB, ligar o controle remoto e a aeronave. Selecionar a missão desejada e enviar para a aeronave, antes de executar o voo, irá aparecer um checklist para verificar o voo, após a verificação a aeronave está pronta para decolar.

3.4 Processamento das imagens

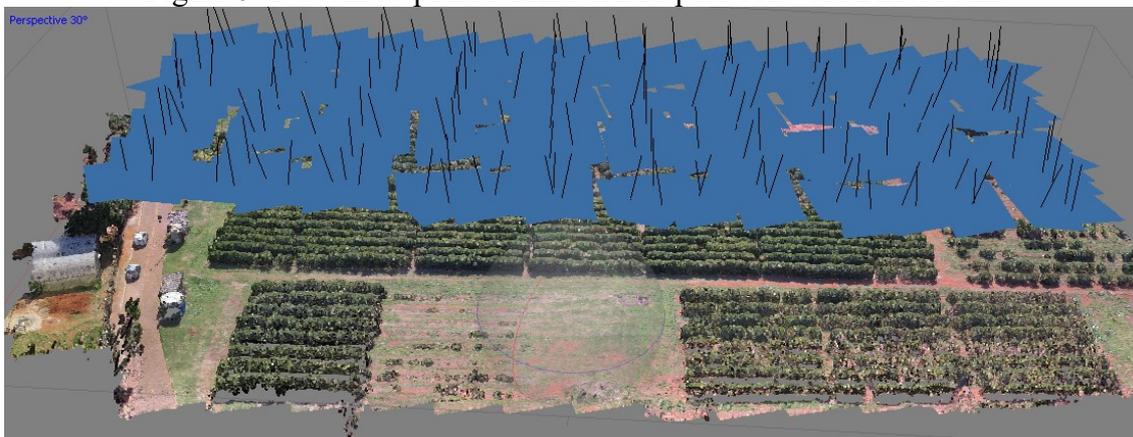
Para o processamento das imagens utilizou-se um computador com hardware Intel Core i7, 8 GB de RAM e Windows 10, 64 bits com placa de vídeo NVIDIA GeForce 920M, 6 GB de memória.

O processamento das imagens adquiridas por meio da RPA consiste em um *workflow* semi-automático, no qual a maioria dos softwares realizam um fluxo semelhante, seguem o processo de calibração da câmera, alinhamento das imagens, geração de nuvem de pontos a fim de gerar o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDT), tais produtos podem ser utilizados para a produção de mosaico de ortofotos, modelagem 3D e obtenção de informações métricas como cálculo de área, volume, alturas, entre outras. (NEX; REMONDINO, 2014; HUGENHOLTZ et al., 2013)

Segundo Whitehead e Hugenholtz (2014) existem vários pacotes de softwares já desenvolvidos que permitem a automação, com isso usuários podem produzir mosaico de ortofotos em menos tempo que utilizando a fotogrametria convencional, pode-se citar Photosynth (FONSTAD et al., 2013; TURNER; LUCIEER; WALLACE, 2014) e o Photoscan (TURNER; LUCIEER; WALLACE, 2014).

No estudo, utilizou-se o software PhotoScan da Agisoft (2017) versão 1.2.4, para criação do ortomosaico e geração do Modelo Digital de Superfície (MDS) e Modelo Digital de Terreno (MDT). Este software identifica na imagem pontos homólogos e cria uma região contínua por estereoscopia gerando uma nuvem de pontos (FIGURA 5).

Figura 5- Nuvem de pontos densa criada pelo software PhotoScan.

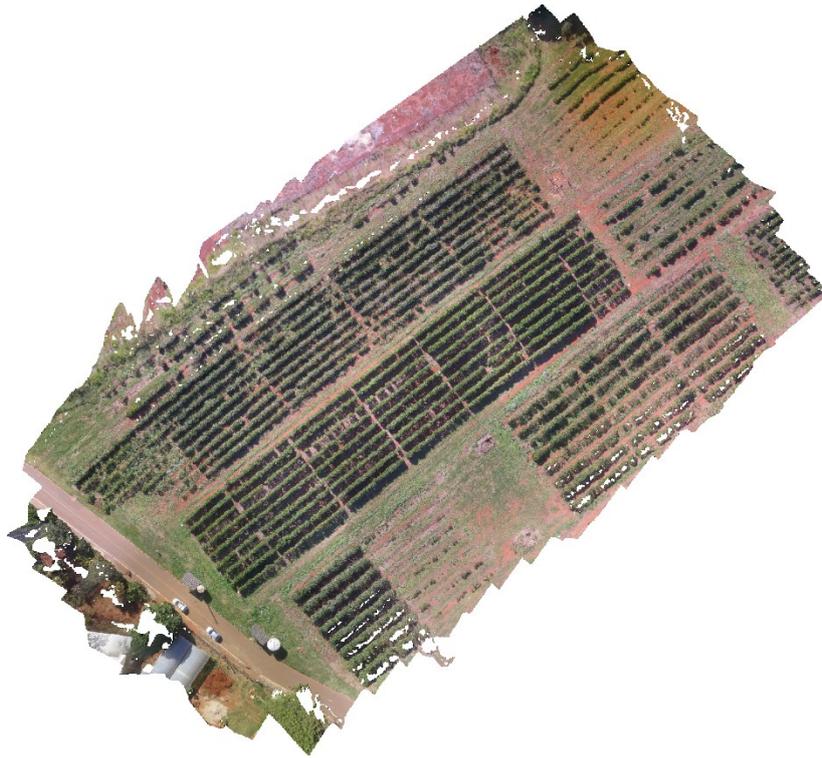


Fonte: Da autora (2018).

Devido a altitude das RPA ser pequena, tem-se o aumento da resolução espacial, entretanto não consegue abranger grandes extensões como é o caso das plataformas orbitais, sendo necessário capturar um grande número de imagens para abranger áreas maiores de interesse. Assim o mosaico destas imagens é um pré-processamento necessário (ZHANG; KOVACS, 2012).

Com a nuvem de pontos o software cria a nuvem de pontos densa e a partir dessa cria-se o modelo reconstruído do local de estudo, sendo possível obter o Ortomosaico (FIGURA 6) como produto final do processamento realizado no PhotoScan. Todo o processamento do PhotoScan foi realizado com alta precisão para obtenção dos dados corretamente.

Figura 6- Ortomosaico gerado pelo software PhotoScan



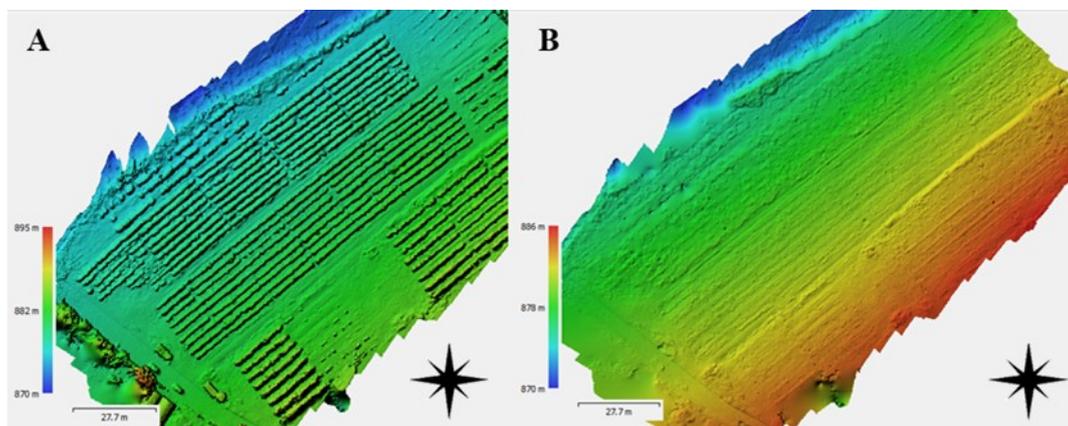
Fonte: Da autora (2018).

Para obtenção do MDT e MDS pode-se utilizar filtragem adequada ou classificação de nuvens de pontos para distinguir pontos de terreno e pontos acima da superfície. Esta classificação pode ser obtida usando vários softwares, como LasTools e Agisoft PhotoScan, e este último está equipado com uma ferramenta de classificação de pontos automático. Para a criação MDT utilizou-se filtros para separar vegetação, edifícios e outros objetos que estejam acima de 0,1 m de altura do nível do solo. Três parâmetros constituíram os principais critérios para extração de pontos da informação da nuvem de pontos: tamanho da célula (m), ângulo máximo (graus) e distância máxima (m), em que adotou-se valores de célula: 50, ângulo: 15, distância: 0,1.

O MDS e o MDT (FIGURA 7) criados no software PhotoScan foram exportados em arquivo GeoTiff, georreferenciados na projeção Universal Transversa de Mercator

(UTM), no datum SIRGAS 2000 zonal 23 S, de acordo com as coordenadas dos pontos de controle (FIGURA 9) coletadas na área de estudo e recortados utilizando um polígono da área de interesse no formato shapefile (.shp).

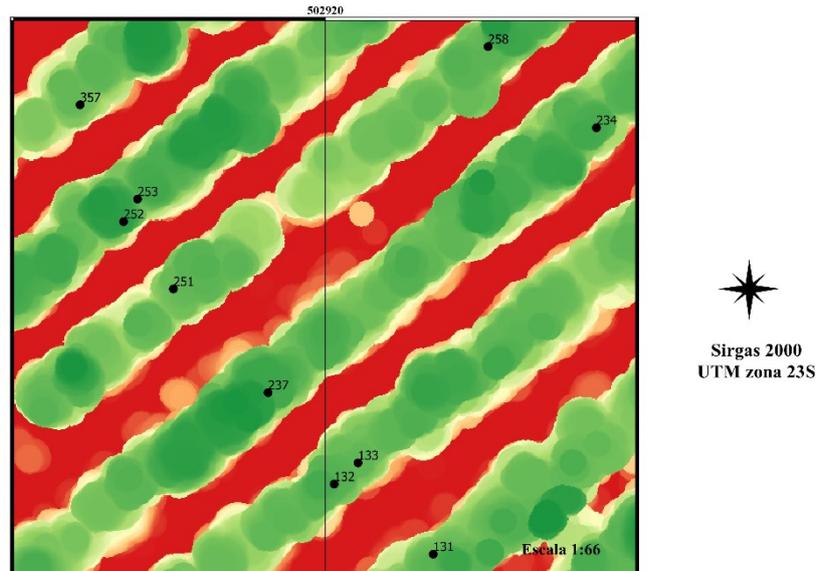
Figura 7 - Modelo Digital de Elevação construído pelo software PhotoScan. a) Modelo Digital de Superfície (MDS) e b) Modelo Digital de Terreno (MDT).



Fonte: Da autora (2018).

Para obtenção da altura de plantas, seguiu-se a metodologia proposta por Panagiotidis et al. (2016), na qual obtém-se um Modelo de Altura do Dossel (*Canopy Height Model-CHM*) através da subtração do MDS do MDT. Para a extração correta dos valores de altura de plantas, utilizou-se a ferramenta Statistics Focal (FIGURA 8) do ArcGis versão 10.5 (ESRI, 2017), no qual identifica o maior valor de pixel na copa das árvores do CHM, evitando valores menores ou maiores de pixel na copa das árvores. Para obtenção dos dados de altura de plantas já tabulados, utilizou-se o plugin Point Sampling Tool do software QuantumGis (QGis) versão 2.16.3 gratuito.

Figura 8- Mapa dos máximos valores de altura resultado da ferramenta focal Statistics.



Fonte: Da autora (2018).

O diâmetro de copa das plantas foram extraídos do ortomosaico utilizando a ferramenta de medida do QGIS.

Todo processamento foi realizado para os 10 meses de dados obtidos por meio da RPA.

3.5 Coleta de dados de campo

Foram coletados dados de altura de plantas (h) e diâmetro de copa (D), as coletas foram realizadas uma vez por mês, no período de junho de 2017 a março de 2018, no mesmo dia de obtenção das imagens digitais, a fim de acompanhar o desenvolvimento da lavoura. Foram coletados 4 pontos amostrais de plantas de café nos 36 blocos distribuídos na área, totalizando 144 plantas, seguindo a metodologia de amostragem proposta por Ferraz et al. (2017a), com trena convencional.

A área em estudo, bem como as plantas amostradas foram georreferenciadas com auxílio de um receptor de sinal GNSS com erro médio de 7mm, de forma a obter as plantas amostradas bem como os pontos iniciais e finais de cada tratamentos. Pontos de controle e elementos possíveis de serem identificados nas imagens foram coletados de forma a viabilizar a correção do georreferenciamento das imagens e posterior obtenção de informações por meio da imagem.

Os Pontos de Controles Terrestres (*Ground Control Points* -GCP) precisos são dados importantes para a correção geométrica dos produtos obtidos por detecção remota, assim com os GCPs podem aumentar consideravelmente a precisão dos mapas, estes

pontos de controle são alvos marcados no chão, ou pontos característicos do terreno como cruzamento de estradas, esquinas, cantos de construções que podem ser identificados na imagem (WANG et al., 2012). Para isso deve-se coletar as coordenadas com um receptor Sistema de Posicionamento Global (*Global Positioning System*-GPS) de Cinemática em Tempo Real (*Real Time Kinematic*-RTK) ou Cinemática Pós-Processado (*Post-Processed Kinematic*-PPK) para ter-se boa precisão.

Trabalhos realizados com RPA para obtenção de imagens obtiveram bons resultados utilizando uma quantidade mínima de pontos e os mesmos espalhados na área de estudo. Alguns trabalhos como de Wallace et al. (2016) utilizaram 24 alvos como GCPs coletados com GPS em tempo Real (RTK) dupla frequência em uma área de 30 x 50 m obtendo um erro de posição dentro de $\pm 0,05$ m horizontalmente e $\pm 0,20$ m verticalmente. Turner, Lucieer e De Jong (2015) coletaram 23 GCPs com GPS RTK dupla frequência, em uma área de 125 x 60 m e obtiveram valores de RMSE em torno de 0,04-0,05 m na horizontal e 0,03-0,04 m na vertical.

No estudo os pontos de controle (FIGURA 9) foram demarcados na área, quatro deles nas extremidades e outros dois distribuídos no meio da área, totalizando seis pontos de controle visíveis. Estes pontos foram confeccionados com uma placa de papelão quadrada de 40 cm x 40 cm, e foram pintados com tinta spray branca para se destacar na imagem de maneira que sejam visíveis. Os locais dos pontos de controles foram demarcados na área com uma estaca georreferenciados e antes de todos os voos as placas foram colocadas no local demarcado. Deste modo as placas puderam ser visualizadas na imagem permitindo a correção do georreferenciamento.

Figura 9 - Placa representando pontos de controle. A. Dispostas na área do cafeeiro. B. Detalhes da placa.



Fonte: Da autora (2018).

3.6 Obtenção de Parâmetros Biofísicos

Para o cálculo dos parâmetros biofísicos, utilizou a Equação (1) de IAF, exposto por Favarin et al. (2002), este parâmetro foi calculado utilizando dados extraídos da RPA.

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

em que,

D - diâmetro das plantas, m, e

h - altura das plantas, m.

A porcentagem de cobertura do terreno pelas plantas de café (%COB) foi calculada conforme Ramirez e Zullo Júnior (2010), na qual leva em consideração a área ocupada pelas plantas, considerando espaçamentos entre plantas menor ou igual ao diâmetro médio das plantas (talhões com formação em renque) Equação (2):

$$\%COB = \left(\frac{D}{EL} \right) \times 100 \quad (2)$$

em que,

D - diâmetro das plantas, m, e

EL - espaçamento entre linhas de plantio, m.

Para a estimativa dos coeficientes de cultura (K_c), utilizou-se a Equação (3) proposta por Villa Nova et al. (2002):

$$K_c = 0,347 \times AF \left(\frac{N_p}{10000} \right) + kcd \left(1 - \frac{0,785 D_c^2}{DP \times DL} \right) \quad (3)$$

em que,

N_p - Número de plantas

AF – Área Foliar

D_c - Diâmetro da copa, m

DL- Distância entre linhas, m

DP- Distância entre plantas, m

K_{cd} - coeficiente da cultura representativo da cobertura vegetal das entre linhas ($K_{cd}=1$ na presença de cobertura vegetal transpirante e $K_{cd}=0,5$ ausência de cobertura vegetal transpirante).

3.7 Estatísticas e validação de dados

No conjunto de dados mensais foi realizada estatística descritiva (média, mediana, máximo, mínimo, primeiro e terceiro quartil) para dar suporte a análise exploratória dos dados. Aplicou-se uma análise prévia de qualidade nos dados, que teve por objetivo eliminar dados discrepantes e valores irreais de altura e diâmetro de copa bem como tirar possíveis *outliers* que poderiam interferir na estimativa do modelo podendo cometer erros de estimativas, já que o Coeficiente de Correlação de Pearson (R) é fortemente influenciado por tais erros. Calculou-se o Coeficiente de Determinação (R^2) para cada mês para avaliar o ajustamento do modelo linear aos dados mensais, através deste coeficiente pode-se inferir se o modelo é capaz de representar ou não o fenômeno, na qual o valor de R^2 pode variar de 0 a 1, sendo R^2 igual a 1 uma correlação perfeita.

Com o resultado do bom ajuste, pode-se utilizar o conjunto de dados dos 10 meses de avaliação para comparar a estimativa da altura das plantas e do diâmetro de copa dos cafeeiros obtidas por meio da RPA com as medições de campo. Utilizou-se regressão linear ($Y=\beta_0+\beta_1X$) para modelar a relação das variáveis, feita a partir dos dados preditos (dados da imagem) e observados (dados de campo), onde os coeficientes de regressão são β_0 e β_1 o intercepto e a inclinação da reta, respectivamente. Para os dados de altura resultaram em 1179 pares de observações (dados imagem x dados de campo) ao longo dos 10 meses de acompanhamento que foram correlacionados. Para os dados de diâmetro de copa, obteve-se 1164 pares de observações que também foram correlacionados. E calculou-se o coeficiente de correlação de Pearson (R) para medir o grau de relação linear entre as variáveis em estudo.

Para avaliar se as estimativas foram significativas, p-valor $p<0,05$, aplicou-se teste t, calculou-se os resíduos como a diferença entre os parâmetros estimados pelas imagens da RPA e as medições de campo, também calculou a Média Absoluta do Erro (MAE), Equação(4), bem como a Raiz Quadrada do Erro Médio (RMSE), dada pela Equação (5).

$$MAE = \frac{1}{N} \sum_{i=1}^n |P_i - O_i| \quad (4)$$

em que

P_i – variável estimada pelo método testado

O_i – variável observada

N- número de pares de valores.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}} \quad (5)$$

em que:

P_i – variável estimada pelo método testado

O_i – variável observada

N- número de pares de valores.

Todas as análises estatísticas foram feitas no software livre (R DEVELOPMENT CORE TEAM. R, 2018).

Para a obtenção dos parâmetros como IAF e %COB utilizou-se a média das quatro plantas amostradas para os 36 blocos da área e avaliou durante os dez meses de coleta, já para o mapa do Kc utilizou-se a média das 4 plantas de cada bloco para os meses de junho e março, primeiro e último mês de análise. Utilizou-se planilhas eletrônicas para os cálculos (IAF, %COB) e organização dos dados, e para análise da estatística espacial, utilizou-se o software livre GeoDa (ANSELIN, 2006).

Para estimar a variabilidade espacial dos dados da área de estudo, utilizou a matriz de proximidade espacial calculada com auxílio do GeoDa, na qual utilizou o critério “queen”, ou seja, considera vizinhança de segunda ordem, assim para $w_{ij}=1$ se o i -ésimo bloco compartilha, pelo menos um lado com o j -ésimo bloco, caso contrário $w_{ij}=0$. Para validar a estatística aplicou-se o teste de pseudo-significância com $p<0,05$.

O índice global de autocorrelação de Moran (I) exposto por Bailey e Gatrell (1995) descreve o arranjo espacial dos objetos dado pela Equação 6:

$$I = \frac{n}{W} \left(\frac{\sum_i \sum_j w_{ij} z_i z_j}{\sum_i z_i^2} \right) \forall i \neq j \quad (6)$$

em que:

n- número de observações

w_{ij} - elemento da matriz de vizinhança para o par i e j

W- soma dos ponderados da matriz

z_i e z_j - desvios em relação à média ($z_i - z$), ($z_j - z$)

z- média

Segundo Ponciano e Scalon (2010), o índice de Moran varia de 0 a 1 indicando autocorrelação direta positiva, e de 0 a -1 indicando autocorrelação indireta e negativa.

4 RESULTADOS E DISCUSSÃO

4.1 Estimativa da altura e diâmetro de copa dos cafeeiros

Inicialmente realizou-se análise exploratória das variáveis envolvidas (altura de planta medida em campo - A_c , altura de planta estimada pela RPA - A_a , diâmetro de copa medido em campo - D_c e diâmetro de copa estimado pela RPA - D_a). Os resultados da análise pode ser observadas na Tabela 2 e Tabela 3

Tabela 2 – Análise exploratória dos dados dos meses de Junho a Dezembro de 2017.

Meses	Estatística	Ac	Aa	Dc	Da
Junho	Mínimo	1,84	1,67	0,83	0,8
	1º Quartil	1,84	1,67	1,17	1,13
	Mediana	2,07	1,97	1,31	1,23
	Média	2,08	1,96	1,31	1,25
	3º Quartil	2,15	2,04	1,43	1,36
	Máximo	2,42	2,23	1,86	1,77
Julho	Mínimo	1,81	1,71	0,42	0,44
	1º Quartil	1,81	1,71	1,15	1,1
	Mediana	2,09	1,98	1,28	1,21
	Média	2,1	1,99	1,27	1,2
	3º Quartil	2,19	2,06	1,4	1,34
	Máximo	2,42	2,28	1,91	1,81
Agosto	Mínimo	1,77	1,56	0,6	0,57
	1º Quartil	1,77	1,56	1,2	1,16
	Mediana	2,1	1,92	1,32	1,3
	Média	2,09	1,94	1,3	1,27
	3º Quartil	2,2	2,03	1,45	1,41
	Máximo	2,45	2,32	1,89	1,7
Setembro	Mínimo	1,78	1,58	0,68	0,67
	1º Quartil	2,03	1,86	1,26	1,18
	Mediana	2,1	1,96	1,37	1,3
	Média	2,11	1,97	1,36	1,28
	3º Quartil	2,2	2,07	1,51	1,42
	Máximo	2,45	2,29	1,84	1,77
Outubro	Mínimo	1,82	1,66	0,68	0,59
	1º Quartil	2,04	1,85	1,28	1,19
	Mediana	2,13	1,95	1,42	1,31
	Média	2,13	1,95	1,4	1,3
	3º Quartil	2,23	2,05	1,53	1,46
	Máximo	2,44	2,32	1,94	1,82
Novembro	Mínimo	1,79	1,8	0,53	0,49
	1º Quartil	2,05	2,05	1,3	1,32
	Mediana	2,14	2,16	1,47	1,47
	Média	2,14	2,15	1,44	1,43
	3º Quartil	2,23	2,24	1,6	1,58
	Máximo	2,48	2,47	2	2
Dezembro	Mínimo	1,84	1,76	0,85	0,9
	1º Quartil	2,06	1,92	1,36	1,34
	Mediana	2,14	2,01	1,53	1,48
	Média	2,15	2,02	1,51	1,47
	3º Quartil	2,23	2,12	1,65	1,61
	Máximo	2,48	2,32	2,18	2,17

Fonte: Da autora (2018).

Tabela 3 – Análise exploratória dos dados dos meses de Janeiro a Março de 2018.

Meses	Estatística	Ac	Aa	Dc	Da
Janeiro	Mínimo	1,89	1,76	0,5	0,52
	1º Quartil	2,09	2,02	1,39	1,35
	Mediana	2,18	2,1	1,55	1,49
	Média	2,18	2,09	1,53	1,48
	3º Quartil	2,26	2,18	1,7	1,64
	Máximo	2,45	2,37	2,04	2,04
Fevereiro	Mínimo	1,9	1,76	0,6	0,5
	1º Quartil	2,09	2,02	1,44	1,35
	Mediana	2,17	2,09	1,57	1,53
	Média	2,18	2,09	1,56	1,5
	3º Quartil	2,27	2,18	1,7	1,64
	Máximo	2,47	2,41	2,09	2,09
Março	Mínimo	1,91	1,85	0,6	0,6
	1º Quartil	2,11	2,11	1,36	1,33
	Mediana	2,2	2,2	1,53	1,5
	Média	2,21	2,2	1,51	1,48
	3º Quartil	2,3	2,3	1,65	1,61
	Máximo	2,53	2,63	2,07	2,00

Fonte: Da autora (2018).

Na maioria dos meses, as medidas da RPA, tanto para altura de planta quanto para diâmetro de copa, subestimaram as medidas de campo, portanto, no geral os dados de campo foram maiores que os dados obtidos pela RPA. Estudos realizados por Panagiotidis et al. (2016) na qual os autores estudaram a determinação de altura e diâmetro de copa de árvores florestais por meio de RPA também obtiveram como resultado a subestimativas da altura por meio da imagem, já para o diâmetro, os valores obtidos por meio da imagem foram superestimadas quando comparada com dados medidos.

Moorthy et al. (2011) estudaram a obtenção de parâmetros biofísicos de árvores de Oliveiras com sensor ativo (*Light Detection And Ranging* - LiDaR), e encontraram uma subestimação de altura por meio do LiDAR, principalmente para árvores que tinham diâmetro maior que 2 m, os autores atribuíram esta subestimação ao efeito de sombreamento, na qual obstruía a captação de dados pelo sensor.

A sombras nas imagens, ou as variações de luminosidade podem interferir e causar estas subestimativas, no entanto, os dados de altura dos cafeeiros, medidos em campo e estimados pela RPA, para cada mês apresentaram um Coeficiente de Determinação (R^2) superior a 0,78 nos 10 meses analisados (TABELA 4). O coeficiente de determinação,

informa sobre o ajuste do modelo aos dados. Destes resultados, no mês de outubro e para valores de diâmetro, por exemplo, pode-se inferir que 92% dos valores medidos em campo está relacionado com os valores obtidos por meio da imagem da RPA, em outras palavras, 92% das variações de y (valores de campo) são explicadas por variações em x (valores da aeronave - RPA), os outros 8% não estão relacionados devido à outras causas e/ou erros.

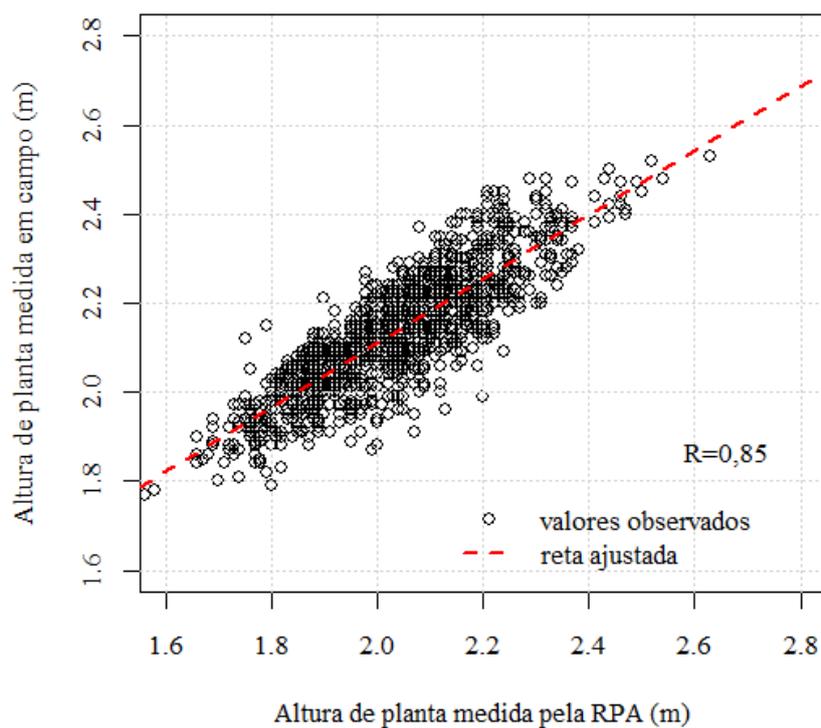
Tabela 4 - Coeficientes de Determinação obtidos nos meses em estudo.

Meses	R² Altura de planta	R² Diâmetro de copa
Junho	0,82	0,89
Julho	0,78	0,90
Agosto	0,88	0,91
Setembro	0,78	0,90
Outubro	0,81	0,92
Novembro	0,80	0,83
Dezembro	0,79	0,90
Janeiro	0,82	0,90
Fevereiro	0,80	0,91
Março	0,82	0,86

Fonte: Da autora (2018).

Diante do bom ajuste do modelo linear aos dados em cada mês, pode-se fazer uma análise com todos os dados e propor uma única equação de estimação. Para os dados de altura resultaram em 1179 pares de observações (dados imagem da RPA x dados de campo) ao longo dos 10 meses de acompanhamento que foram correlacionados. A regressão linear (FIGURA 10) evidenciou forte relação entre os valores de altura obtidas nas imagens provindas da RPA e os valores observados em campo, demonstrada por meio do forte Coeficiente de Correlação de Pearson com R igual a 0,85. Para Moore (2007), a correlação mensura a direção e o grau da relação linear entre duas variáveis quantitativas e para quantificar esta relação Dancey e Reidy (2006) descrevem uma classificação: R igual a 0,10 até 0,30 (fraco); R igual a 0,40 até 0,6 (moderado); R igual a 0,70 até 1 (forte).

Figura 10 - Regressão Linear entre dados de altura de campo e dados da RPA.



Fonte: Da autora (2018).

Panagiotidis et al. (2016) obtiveram forte correlação em estudos realizados em duas áreas florestais, uma contendo 49 árvores e a outra contendo 39 árvores, os autores estimaram altura das árvores por meio de imagem provindas de RPA e correlacionaram com dados medidos em campo, o R^2 encontrado para os lote 1 e 2 de altura foram de 0,75 e 0,72 respectivamente.

Por meio da regressão linear obtém-se a Equação ((7) que descreve o relacionamento em termos matemáticos, que pressupõe alguma relação de causa e efeito entre as variáveis, no caso a variável de altura de planta obtida por meio de imagem provindas da RPA assimila com variável de altura de planta medida em campo.

$$A_m = 0,7213 \times A_a - 0,6678 \quad (7)$$

em que:

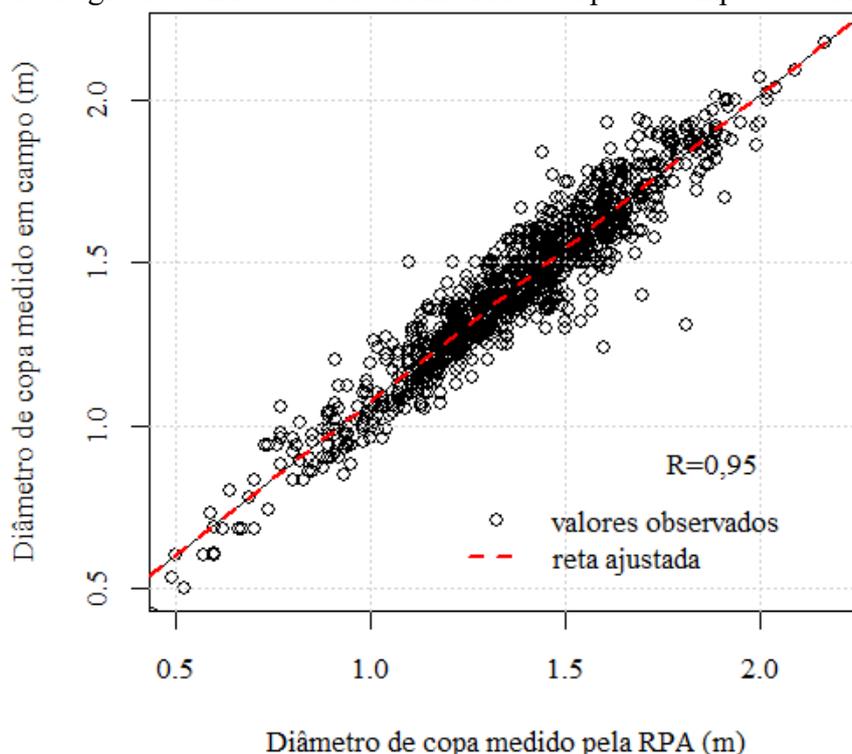
A_m - altura de planta estimada pelo modelo (m) e

A_a - altura de planta medida pela RPA (m).

A equação é proposta para corrigir os dados obtidos com a imagem provinda da RPA. A obtenção deste tipo de equação apresenta uma importância prática, pois facilita a obtenção de dados de forma indireta de lavouras. Neste caso, a equação facilitará a determinação de parâmetros biofísicos do cafeeiro tais como a altura e o diâmetro de copa. Assim pode-se inferir sobre o crescimento e desenvolvimento da cultura sem a necessidade de realização de amostragem diretamente no campo, obtendo uma amostragem remota, na qual se torna mais ágil intervenções na lavoura. Além disso, segundo Bendig et al. (2014) medições indiretas utilizando RPA permite acompanhamento da variação espacial de altura de plantas, crescimento, estimativa de biomassa e rendimento de culturas.

Assim como os valores de altura, correlacionou-se os valores de diâmetro de copa medidos em campo com os diâmetros de copa obtidos por meio da imagem provinda da RPA, ao total foram 1164 pares de observações correlacionados (FIGURA 11).

Figura 11 - Regressão entre dados de diâmetros de copa de campo e dados de RPA.



Fonte: Da autora (2018).

Panagiotidis et al. (2016) estimaram diâmetro de copa das árvores por meio de imagem de RPA em duas áreas florestais, uma contendo 49 árvores e a outra contendo 39 árvores. Os autores correlacionaram os dados de diâmetro provindo da imagem com

dados medidos em campo, e obtiveram forte correlação com valores de R^2 no lote 1 e 2 de 0,63 e 0,85 respectivamente. Eles encontraram uma correlação moderada no lote 1, tais resultados podem ser atribuídos ao procedimento de obtenção de dados e o processamento utilizado.

No caso da obtenção de imagens, sobreposições baixas podem interferir na precisão e qualidade do produto final (MESAS-CARRASCOSA et al., 2016). Assim como a qualidade do processamento, uma vez que processamentos da nuvem de pontos de baixa qualidade podem diminuir a precisão e conseqüentemente os valores de alturas estimadas. Outro fator importante são os pontos de controles, pois estes fazem a correção do georreferenciamento dos ortomosaicos, sendo assim tem-se a posição correta das plantas amostradas e comparada nos estudos, os autores Panagiotidis et al. (2016) utilizaram somente 4 pontos de controle na área.

No caso do processamento e obtenção do MDS e MDT, e conseqüentemente valores de CHM (*Canopy Height Model*), pode-se utilizar filtros ou realizar a classificação de nuvens de pontos de forma automática como o estudo de Panagiotidis et al. (2016) e Surovy et al. (2018), em que deve-se definir parmetros como: tamanho da clula, ngulo mximo e distncia mxima, apesar dos autores terem utilizado esta metodologia, tais parmetros no foram descritos.

Iizuka et al. (2017), testou combinaes destes parmentos para obteno de altura de rvores florestais e pontuaram que reas com topografia plana, menor valor de ngulo e distncia so adequados, ratificando os resultados encontrados neste estudo.

A partir da regresso linear,  proposto a Equao (8). As estimativas do dimetro de copa do cafeeiro apresentaram forte correlao entre os dados estimados e os observados, com valor de R igual a 0,95.

$$D_m = 0,9434 \times D_a + 0,1287 \quad (8)$$

em que:

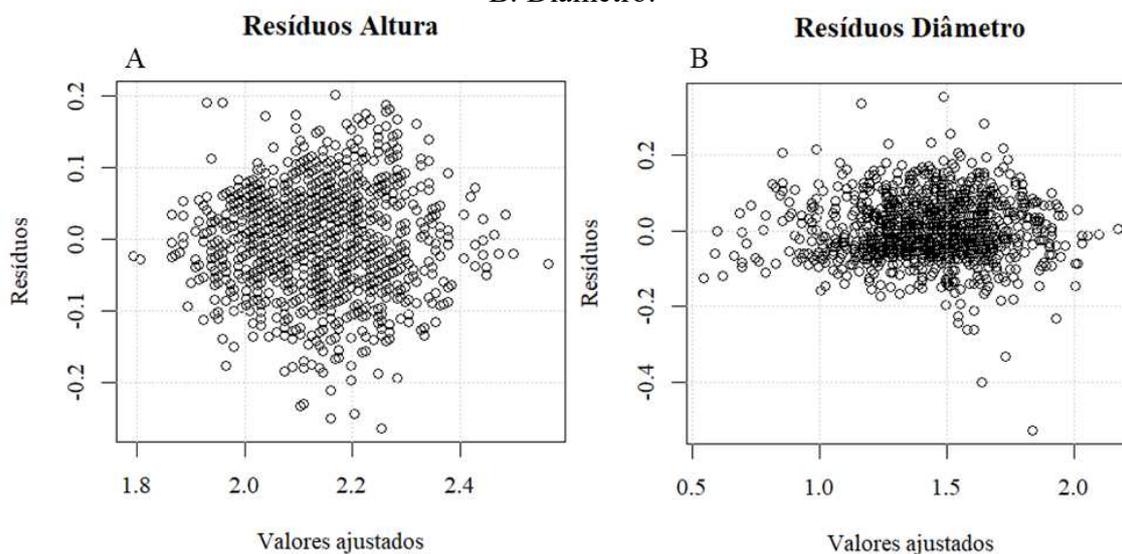
D_m - dimetro de copa estimado pelo modelo (m) e

D_a - dimetro de copa medido pela RPA (m).

Para avaliar o modelo da regresso, calculou-se o erro ou os rsduos (valor observado/campo - valor predito/aeronave) para cada ponto dos dados de altura de planta

e diâmetro. Na Figura 12 tem-se o gráfico de dispersão dos resíduos, tanto da altura de planta quanto do diâmetro, que estão de acordo com os pressupostos da regressão, na qual os resíduos devem ser distribuídos aleatoriamente em torno de zero.

Figura 12 - Resíduos dos valores estimados pela RPA e medidos em campo. A. Altura. B. Diâmetro.



Fonte: Da autora (2018).

A precisão da análise de altura e diâmetro de copa dos cafeeiros apresentaram valores baixos de erro Média Absoluta do Erro (MAE) e Raiz Quadrada do Erro Médio (RMSE) indicando que os modelos tiveram um bom ajuste, para altura a MAE foi de 0,07 m e a RMSE foi de 0,06 m, já para as estimativas de diâmetro de copa, obteve-se um MAE igual a 0,06 m e RMSE igual a 0,08 m (TABELA 5), estes valores representam a precisão do modelo estimado, quanto menor os valores melhor a precisão, tais valores da análise foram satisfatórios, já que Panagiotidis et al. (2016), encontraram MAE de altura de árvores florestais de 2,62 m e MAE de diâmetro de árvores florestais de 0,73 m. Árvores florestais tem uma densidade maior que lavouras cafeeiras, são maiores, e tem mais interferência de sombreamento, isso justifica os valores altos de MAE encontrado pelos autores do estudo citado.

Tabela 5 – Resumo da estatística da altura e diâmetro.

Parâmetros	RMSE (m)	MAE (m)	p-valor	Graus de Liberdade (df)	R ²
Altura	0,073	0,058	2,20E-16	1177	0,718
Diâmetro	0,081	0,062	2,20E-16	1162	0,899

Fonte: Da autora (2018).

4.2 Porcentagem de cobertura do terreno obtida pela aeronave

A porcentagem de cobertura do terreno obtida no período estudado, demonstrou a evolução e a ocupação de plantas de cafeeiros na área. A lavoura foi esqueletada na terceira semana de julho de 2016, sendo assim, foi possível acompanhar remotamente seu crescimento e desenvolvimento ao longo do estudo.

A porcentagem de cobertura foi proposta e classificada em proporções que permitiram acompanhar seu desenvolvimento, podendo ser observada na Tabela 6.

Tabela 6 - Escala da Porcentagem de Cobertura (%COB) do terreno pelas plantas de café.

	% cobertura	Cobertura
	< 20	Baixa
Classes	20 – 39	Notável
	40 – 60	Moderada
	61 – 80	Alta
	>80	Volumosa

Fonte: Da autora (2018).

Pela análise da Figura 13 é possível observar a porcentagem de cobertura ao longo dos 10 meses de estudo. No mês de junho de 2017 a lavoura estava se recuperando do esqueletamento, a maioria dos blocos, ou seja, 29 blocos apresentaram %COB moderada, o índice de Moran calculado apresentou autocorrelação espacial positiva, porém uma autocorrelação fraca de 0,0082. Neste mês a variável não foi estatisticamente significativa, aceitando a hipótese nula com nível de significância de 0,05, ou seja, não houve autocorrelação espacial para a variável %COB no mês de junho de 2017.

Para os meses de julho, agosto, setembro e outubro cujos índices de Moran foram 0,0084; 0,0214; 0,0911 e 0,0466 respectivamente, a %COB prevaleceu moderada na maioria dos blocos, e para estes meses não apresentou autocorrelação espacial, este período corresponde a meses mais secos e de menor temperatura o que resulta em menor desenvolvimento da cultura.

Para os meses de novembro e dezembro o índice Moran foi de 0,0227 e 0,0896 respectivamente e a porcentagem de cobertura passou a ser alta, porém ainda nestes meses não houve autocorrelação espacial significativa. A não correlação espacial pode ser explicada pela variabilidade forçada na área devido aos tratamentos impostos no experimento anteriormente e o seu residual, porém ao longo do estudo, por não proceder

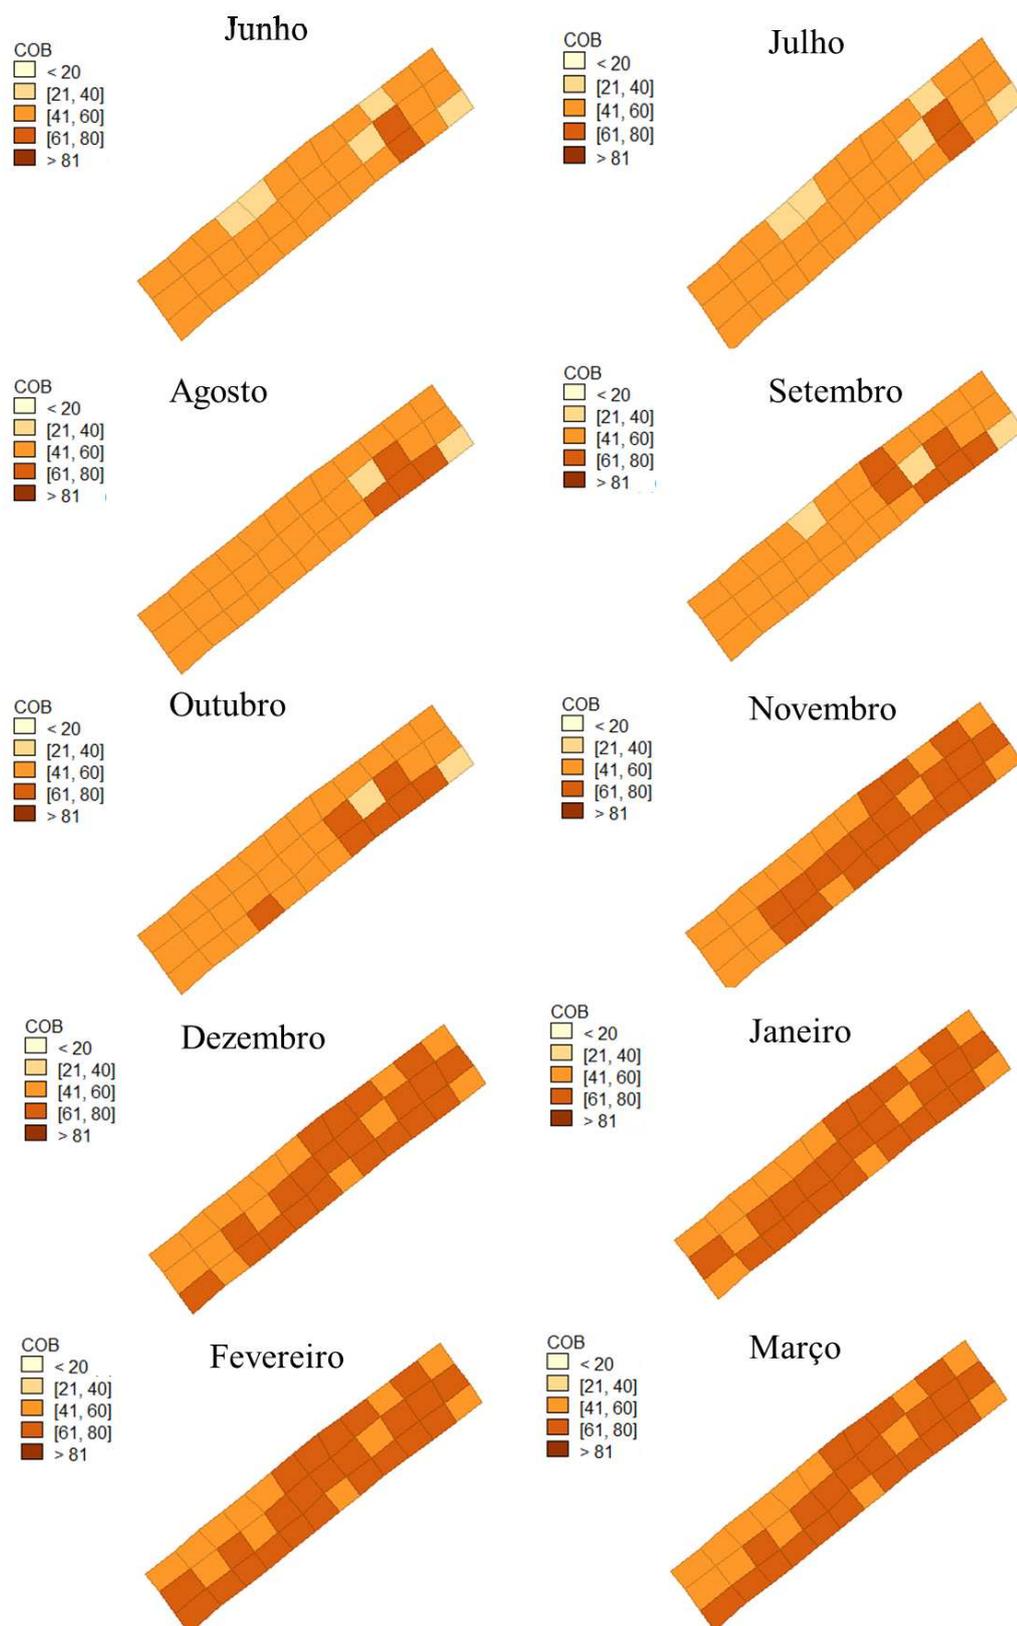
com os tratamentos, esta variabilidade tendeu a diminuir, a área tendeu a ser mais estável e com vizinhos mais semelhantes, como pode-se observar nos meses subsequentes.

Nos meses de janeiro, fevereiro e março o índice de Moran aumentou com relação aos meses anteriores, tendo como valor 0,134; 0,133 e 0,206 respectivamente. Já para estes meses o teste de pseudo-significância foi significativo, passando a ter autocorrelação espacial. Pode-se dizer que os tratamentos já não fazem efeito sobre os blocos, sendo assim a área tendeu a ser mais uniforme, resultando na maioria dos blocos com porcentagem de cobertura alta, além disso, pode-se considerar que o espaço tem mais influência no desenvolvimento das plantas, assim plantas vizinhas tendem a ser parecida devido a sua localização espacial.

Como pode ser observado na Figura 13, houve um aumento na porcentagem de cobertura do terreno nos meses em estudo, passando de porcentagem de cobertura moderada para alta.

A porcentagem de cobertura do terreno de cafeeiros é um parâmetro biofísico que permite acompanhar o desenvolvimento da lavoura, podendo subsidiar, dentre outros manejos, a mecanização, pois lavouras com cobertura volumosa podem dificultar a entrada de máquinas para manejos mecanizados. No estudo, a lavoura ainda permite tratos mecanizados por apresentar cobertura alta.

Figura 13 - Distribuição espacial da porcentagem de cobertura de terreno dos cafeeiros ao longo dos meses em estudo.



Fonte: Da autora (2018).

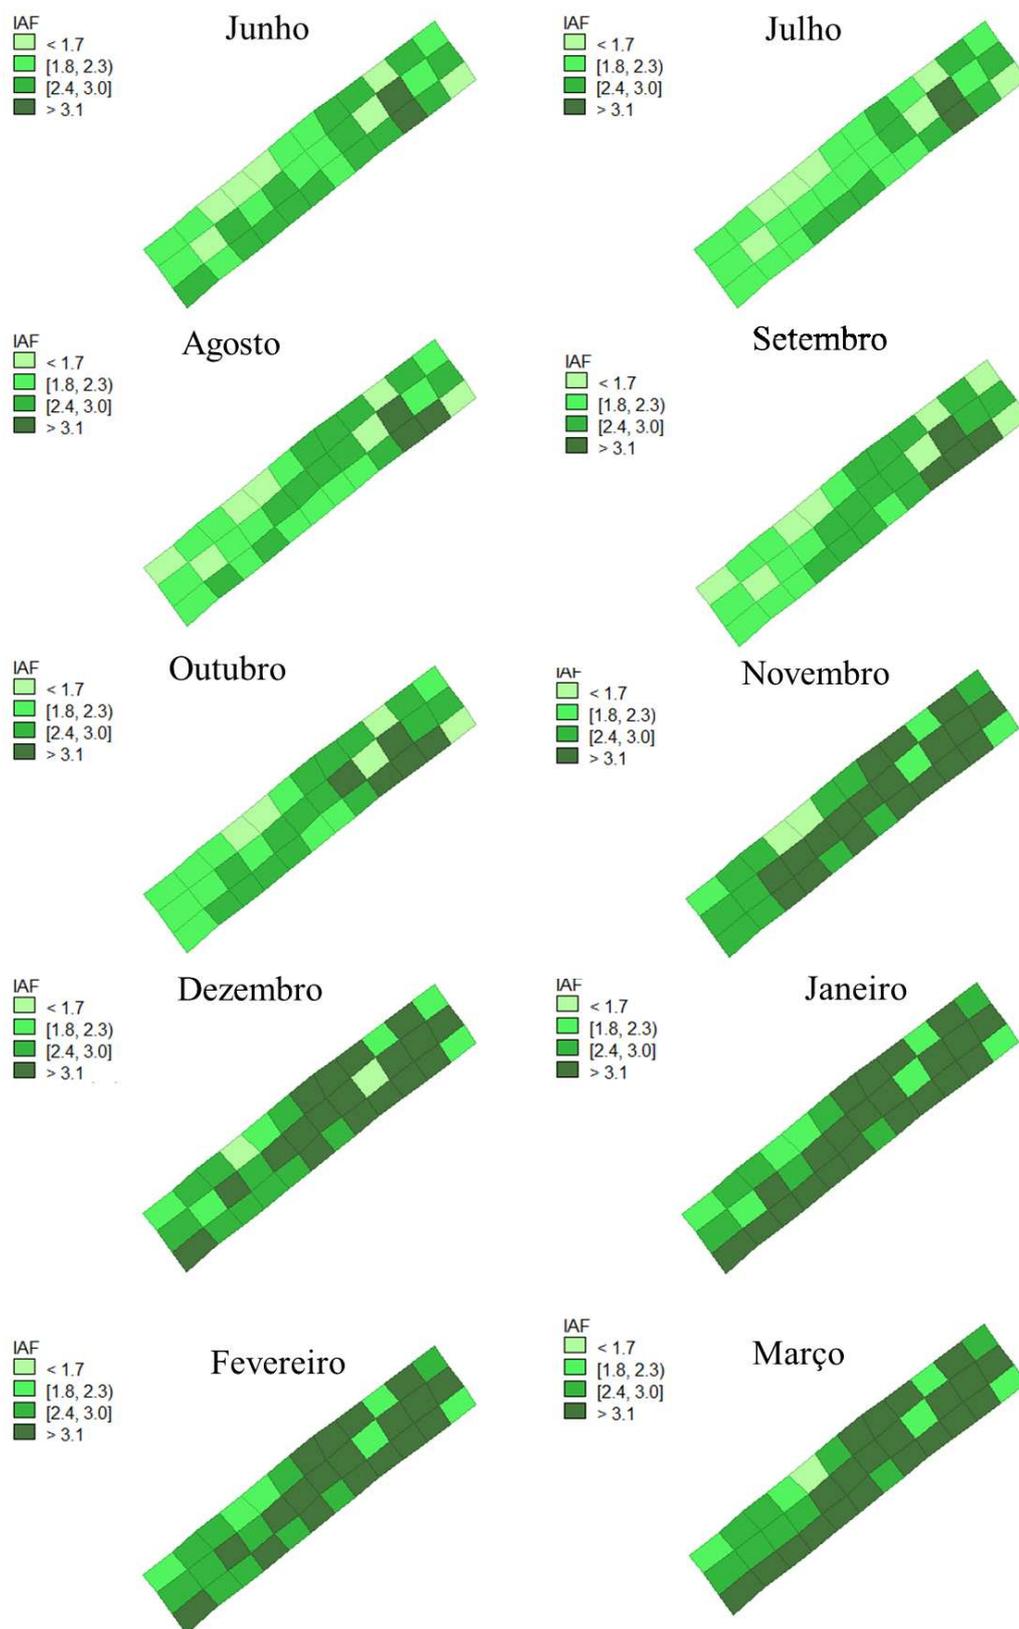
4.3 Índice de Área Foliar obtido pela aeronave

Na Figura 14 observa-se a evolução do Índice de área foliar (IAF) calculado para os meses de estudo. Os meses de junho, julho e agosto o Índice de Moran variou de 0,05 a 0,08, neste meses não houve autocorrelação espacial, pois a variável IAF não foi estatisticamente significativa, aceitando a hipótese nula com nível de significância de 0,05, este motivo deve-se à variabilidade espacial provinda dos tratamentos anteriormente impostos. Ao longo dos meses observa-se um aumento no Índice de Moran, assumindo valores de 0,134 para o mês de dezembro; 0,163 para janeiro; 0,168 para fevereiro e 0,278 para o mês de março. Assim para os meses de setembro a março, houve autocorrelação significativa e conseqüentemente os valores de IAF são influenciados pelo espaço, ou seja, os valores de IAF observado numa região é dependente dos valores de IAF nas localizações vizinhas, como observa-se na Figura 14, em que a maioria dos blocos das regiões centro e centro-oeste apresentam valores de $IAF > 3,1$, representado pela coloração mais forte de verde.

Estudos realizados por Favarin et al. (2002) observaram valores semelhantes utilizando a mesma metodologia para obter IAF de cafeeiros com idades diferentes, os autores encontraram valores de IAF igual a 2,34 para cafeeiros com 30 meses após o plantio e IAF igual a 3,41 para cafeeiros com 35 meses após o plantio. Devido a poda realizada no final do ano de 2016, ocorreu diminuição considerável da área foliar dos cafeeiros em estudo, mas de junho de 2017 a março de 2018 foi possível observar que houve uma recuperação da lavoura e um aumento da relação entre a área foliar e a área do terreno ocupada pelos cafeeiros, podendo acompanhar esta evolução ao longo do estudo. Os valores encontrados no estudo de Favarin et al. (2002) estão próximos do encontrado neste estudo, apesar de não ter a mesma idade, mas deve-se levar em consideração que a poda proporcionou a redução das folhas e conseqüentemente redução do IAF.

O conhecimento da variação temporal do Índice de Área Foliar, segundo Rezende et al. (2014), é importante para definir estratégias melhores de manejos de irrigação além do seu potencial de produção. A produtividade pode ser acompanhada pelo IAF, pois qualquer variação do índice causada por geadas, tempestades, desfolhas, seca, práticas de manejo, etc., pode alterar a produtividade (BRÉDA, 2003). Neste estudo, em geral, o IAF apresentou um comportamento crescente não sendo possível observar uma queda, em que segundo Bréda et al. (2003), o IAF é variável ao longo do ano e sofre forte influência da colheita e da ocorrência de pragas e doenças.

Figura 14 - Índice de Área Foliar dos cafeeiros ao longo dos meses de estudo.



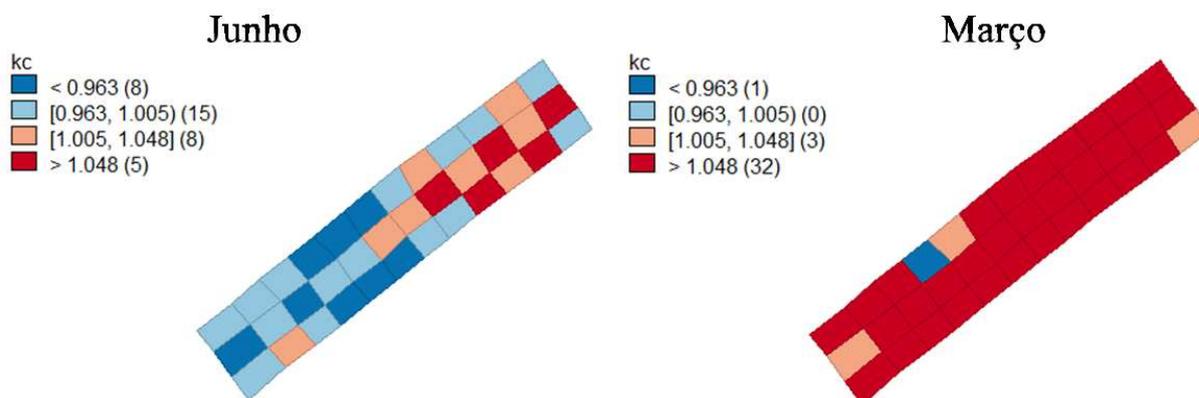
Fonte: Da autora (2018).

4.4 Coeficiente de Cultura obtido pela aeronave

O coeficiente de cultura (K_c) é constituído pelas características do clima local e da cultura (DOORENBOS; PRUITT, 1977), além de ser um indicador de grande significado físico e biológico, dado que depende da arquitetura e da transpiração da planta (JENSEN, 1969; ALLEN et al., 1998; OLIVEIRA et al., 2007). Sendo assim, foi proposto um mapa de K_c (FIGURA 15), baseado nas características biofísicas dos cafeeiros, seguindo a metodologia proposto por Villa Nova et al. (2002).

Como observa-se na Figura 15 ambos os meses apresentaram significância estatística, ou seja, rejeitou-se a hipótese nula podendo considerar a autocorrelação espacial do K_c nos blocos e que esta autocorrelação aumenta com o tempo. Em junho de 2017 observou-se um Índice de Moran de (I) 0,228 e no mês de março de 2018 $I=0,286$. Como observado na Figura 15 a maioria dos blocos no início do experimento apresentaram valores de K_c entre 0,963 e 1,005. Já para o mês de março os valores de K_c foi de 1,05 para 32 blocos, percebe-se uma uniformidade do K_c . Segundo Oliveira et al. (2007), no período de estabelecimento da cultura, a curva de K_c apresenta valores baixos, e quando a cultura atinge um dossel máximo, a curva tende a se estabilizar com valores próximos.

Figura 15 - Mapa do K_c dos meses de junho de 2017 e março de 2018.



Fonte: Da autora (2018).

Alguns estudos sobre K_c recomendam valores de acordo com o desenvolvimento do cafeeiro, como Doorenbos e Pruitt (1977) propõem valor médio de K_c entre 0,9 a 1,1 para cafeeiros adultos em todas as fases de desenvolvimento, sem especificar local e condições em que tais valores foram obtidos. Arruda et al. (2000) apresentaram valores

de Kc iguais a 0,73 e 0,75 nos primeiros anos de idade dos cafeeiros, e valores de Kc de 0,87 e 0,93 para cafeeiros com sete e oito anos de idade respectivamente. Sato et al. (2007) encontraram valores de Kc variando de 0,59 a 1,16 para a cultivar Catuaí em Lavras-MG, quatro anos após a realização de recepa baixa à altura de 40 cm da superfície do solo, utilizando-se do método do balanço hídrico.

Como visto, os valores de Kc apresentado pelo estudo se mostram coerentes com a literatura, além disso, o método utilizado para obtenção dos valores de Kc leva em consideração características biofísicas da planta, na qual mostram a sensibilidade e coerência dos dados, ratificando sua eficiência e adoção para manejos de irrigação do cafeeiro de maneira racional (VILLA NOVA et al., 2002).

Vale salientar que o mapa de Kc gerado é dependente da equação proposta por Villa Nova et al. (2002), e que a mesma foi desenvolvida para uma determinada variedade. Existe a possibilidade desta equação não representar o Kc para todas as variedades, no entanto esta metodologia é viável para geração de mapas de Kc utilizando dados biofísicos de cultura obtidos remotamente, o que seria muito útil no manejo da irrigação.

5 CONCLUSÃO

Foi possível a obtenção de medidas indiretas de altura e diâmetro de copa de uma lavoura cafeeira por meio de Aeronave Remotamente Pilotada (RPA), assim como propor modelo de estimação de dados de altura e diâmetro.

Com base nos dados extraídos das imagens ao longo dos 10 meses de estudo, foi possível calcular e analisar espacialmente a porcentagem de cobertura do terreno da área bem como o Índice de Área Foliar (IAF).

Foi possível propor mapas de coeficiente de cultura (Kc) dos meses de junho de 2017 e março de 2018, início e fim, respectivamente, do acompanhamento da lavoura.

REFERÊNCIAS

ABER, J. S.; AAVIKSOO, K.; KAROFELD, E.; ABER, S. W. Patterns in Estonian bogs as depicted in color kite aerial photographs. **Suo**, Helsinki, v.53, p.1–15, jan.2002.

ABER, J. S.; ABER, S. W.; BUSTER, L.; JENSEN, W. E.; SLEEZER, R. O. Challenge of infrared kite aerial photography: A digital update. **Kansas Academy of Science Transactions**, Washington, v.112, p.31–39, jan. 2009.

AGISOFT. Software Agisoft PhotoScan. 2017. Disponível em: <http://www.agisoft.ru/products/photoscan/professional/buy/educational/>. Acesso em: Agosto 2017.

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration-Guidelines for computing crop water requirements**. FAO, Rome, v.300, n.9, jan. 1998.

ALVES, E. A.; QUEIROZ, D. M. DE; PINTO, F.A.C. Cafeicultura de precisão. **Boas práticas**, Viçosa, p. 189-223, jan.2006.

ALVES, M.D.C; SA ILVA, F. M.; POZZA, E. A.; OLIVEIRA, M. S.D. Modeling spatial variability and pattern of rust and brown eye spot in coffee agroecosystem. **Journal of pest science**, [s.l.], v. 82, n. 2, p. 137, mai. 2009.

ANSELIN, L.; SYABRI, I.; KHO, Y. GeoDa: An Introduction to Spatial Data Analysis. **Geographical Analysis**, [s.l.], v. 38, n. 1, p.5-22, jan. 2006.

ARRUDA, F.B.; IAFFE, A.; SAKAI, E.; CALHEIROS, R.O. Resultados anuais do coeficiente de cultura do cafeeiro em um ensaio em Pindorama - SP. In: SIMPÓSIO DE PESQUISAS DOS CAFÉS DO BRASIL, 1, 2000, Poços de Caldas. *Resumos expandidos...* Brasília: EMBRAPA Café/MINASPLAN, 2000. v.2, p.790.

BAILEY, T. C.; GATRELL, A. C. **Interactive spatial data analysis**. Essex: Longman Scientific, p.413, 1995.

BALASTREIRE, L. A. et al. Agricultura de precisão: mapeamento da produtividade de uma cultura de café. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 30. Foz do Iguaçu. Anais... Jaboticabal: SBEA, 2001. 1 CD-ROM. 2001.

BARROS, M. M. D.; VOLPATO, C. E. S.; SILVA, F. C.; PALMA, M. A. Z.; SPAGNOLO, R. T. Avaliação de um sistema de aplicação de fertilizantes a taxa variável adaptado à cultura cafeeira. **Coffee Science**, Lavras, v. 10, n. 2, p. 223-232, abr. 2015.

BATER, C. W.; COOPS, N. C.; WULDER, M. A.; HILKER, T.; NIELSEN, S. E.; MCDERMID, G.; STENHOUSE, G. B. Using digital time-lapse cameras to monitor species-specific understorey and overstorey phenology in support of wildlife habitat assessment. **Environmental monitoring and assessment**, [s.l.], v. 180, n. 1, p. 1-13, set. 2011.

BATTE, M.T.; EHSANI, M.R. The economics of precision guidance with auto-boom control for farmer-owned agricultural sprayers. **Computers and Electronics in Agriculture**, New York, v.53, n.1, p.28-44, ago. 2006.

BENDIG, J.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; EICHFUSS, S.; BARETH, G. Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. **Remote Sensing**, [s.l.], v. 6, n.11, p.10395-10412, out. 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.

BRÉDA, N. J. J. Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. **Journal of Experimental Botany**, Oxford, v. 54, n. 392, p. 2403-2417, nov. 2003.

CALDAS, A. L. D.; LIMA, E. M. C.; REZENDE, F. C.; FARIA, M. A. D.; DIOTTO, A. V.; JÚNIOR, M. C. R. L. Produtividade e qualidade de café cv travessia em resposta à irrigação e adubação fosfatada. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v. 12, n. 1, p. 2357, jan. 2018.

CANDIAGO, S.; REMONDINO, F.; DE GIGLIO, M.; DUBBINI, M.; GATTELLI, M. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. **Remote Sensing**, Basel, v.7, n.4, p.4026-4047, abr. 2015.

CRISTEA, L.; LUCULESCU, M. C.; ZAMFIRA, S. C.; BOER, A. L.; POP, S. Multiple criteria analysis of remotely piloted aircraft systems for monitoring the crops vegetation status. **In IOP Conference Series: Materials Science and Engineering**, [s.l.], v.147, n.1, jan. 2016.

CUNHA, A. C.; FLORENTINO, L. A.; SILVA, A. B. D.; FILHO, L. R. A. G.; PUTTI, F. F. Sistema computacional web para controle de gestão da produção de café. **Coffee Science**, Lavras, v. 12, n. 3, p. 344 – 354, abr. 2017.

DANCEY, C.; REIDY, J. **Estatística Sem Matemática para Psicologia: Usando SPSS para Windows**. Porto Alegre, Artmed, 2006.

DANTAS, A. A. A.; CARVALHO, L. G.; FERREIRA, E. Classificação e tendências climáticas em Lavras, MG. **Ciência e Agrotecnologia**, Lavras, v. 31, n. 6, p. 1862-1866, dez. 2007.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA). Portaria DECEA No 282/DGCEA, DE 22 DE DEZEMBRO DE 2016. Disponível em: <https://publicacoes.decea.gov.br/?i=publicacao&id=4510>. Acessado em: agosto de 2017.

DOORENBOS, J.; PRUITT, O. **Guidelines for predicting crop water requirements**. FAO, Rome. 179 p., 1977.

DRONEDEPLOY. Disponível em: <https://www.dronedeploy.com/> Acessado em: agosto de 2016.

ESRI. ArcGIS para Windows Versão 10.5. Licence type ArcInfo [S.I]: ESRI – Environmental Systems Research Institute, 2017.

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

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

FERRAZ, G. A. S.; DA SILVA, F. M.; DE OLIVEIRA, M. S.; CUSTÓDIO, A. A.; FERRAZ, P. F. Variabilidade espacial dos atributos da planta de uma lavoura cafeeira. **Revista Ciência Agronômica**, Ceará, v. 48, n. 1, p. 81, jan. 2017.

FERRAZ, G. A. S.; DA SILVA, F. M.; DE OLIVEIRA, M. S.; DA SILVA, F. C.; CARVALHO, L. C. C. Comparativo entre os atributos químicos do solo amostrados de forma convencional e em malha. **Coffee Science**, Lavras, v. 12, n. 1, p. 17-29, jan. 2017a.

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

FONSECA, A. S.; LIMA, J. S. D. S.; SILVA, S. D. A.; XAVIER, A. C.; NETO, A. P. D. Variabilidade espacial da produtividade e do estado nutricional do cafeeiro *Canephora*. **Coffee Science**, Lavras, v. 10, n. 4, p. 420-428, dez. 2015

FONSTAD, M.A.; DIETRICH, J.T.; COURVILLE, B.C.; JENSEN, J.L.; CARBONNEAU, P.E. Topographic structure from motion: a new development in photogrammetric measurement. **Earth Surface Processes and Landforms**, [s.l.], v. 38, n. 4, p. 421-430, 2013.

GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. **Science**, New York, v. 327,n. 5967, p. 828-831, fev. 2010.

GETZIN S.; WIEGAND K.; SCHÖNING I. Assessing biodiversity in forests using very high-resolution images and unmanned aerial vehicles. **Methods in Ecology and Evolution**, London, v. 3, n. 2, p. 397-404, jan. 2012.

GRENZDÖRFFER, G. J.; ENGEL, A.; TEICHERT, B. The photogrammetric potential of low-cost UAVs in forestry and agriculture. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Beijing, v. 31, n. 3, p. 1207-1214, jan. 2008.

GILES, D. K. Use of Remotely Piloted Aircraft for Pesticide Applications: Issues and Outlook. **Outlooks on Pest Management**, Saffron Walden, v. 27, n. 5, p. 213-216, out. 2016.

GÓMEZ-CANDÓN, D.; VIRLET, N.; LABBÉ, S.; JOLIVOT, A.; REGNARD, J. L. Field phenotyping of water stress at tree scale by UAV-sensed imagery: new insights for thermal acquisition and calibration. **Precision Agriculture**, [s.l.], v.17, n.6, p.786-800, dez. 2016.

GRANER, E. A.; GODOY JUNIOR, C. **Manual do cafeicultor**. São Paulo: USP. 320p. 1967.

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

HARDIN, P. J.; HARDIN, T. J. Small-scale remotely piloted vehicles in environmental research. **Geography Compass**, [s.l.], v.4, n.9, p.1297–1311, set. 2010.

HERNANDEZ-LOPEZ, D.; FELIPE-GARCIA, B.; GONZALEZ-AGUILERA, D.; ARIAS-PEREZ, B. An automatic approach to UAV flight planning and control for photogrammetric applications. **Photogrammetric Engineering & Remote Sensing**, [s.l.], v.79, n.1, p.87-98, jan. 2013.

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

HONKAVAARA, E. et al. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, Basel, v. 5, n. 10, p. 5006-5039, out. 2013.

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

INTERNATIONAL CIVIL AVIATION ORGANIZATION (ICAO). Circular 328. Unmanned Aircraft Systems (UAS). Technical Report. International Civil Aviation Authority. Montreal, Canada. Disponível em: <https://www.icao.int/Meetings/UAS/Documents/Circular%20328_en.pdf>. Acesso em: Setembro de 2016.

INAMASU, R. Y.; BERNARDI, A. C. de C. **Agricultura de precisão**. Agricultura de precisão: resultados de um novo olhar. São Carlos (SP): Embrapa Instrumentação, 2014.

INOUE, Y.; MORINAGA, S.; TOMITA, A. A blimp-based remote sensing system for low-altitude monitoring of plant variables: A preliminary experiment for agricultural and ecological applications. **International Journal of Remote Sensing**, [s.l.], v.21, n.2, p.379–385, nov. 2010.

IIZUKA, K.; YONEHARA, T.; ITOH, M.; KOSUGI, Y. Estimating Tree Height and Diameter at Breast Height (DBH) from Digital Surface Models and Orthophotos Obtained with an Unmanned Aerial System for a Japanese Cypress (*Chamaecyparis obtusa*) Forest. **Remote Sensing**, [s.l.], v. 10, n. 1, p. 13, dez. 2017.

JENSEN, M. E. **Water consumption by agricultural plants**. Academic Press, New York, 1969.

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

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

LELONG, C. C. D.; PINET, P. C.; POILVE', H. Hyperspectral imaging and stress mapping in agriculture: A case study on wheat in Beauce (France). **Remote Sensing of Environment**, [s.l.], v.66, p.179–191, nov. 1998.

LÓPEZ-GRANADOS, F., TORRES-SÁNCHEZ, J., DE CASTRO, A. I., SERRANO-PÉREZ, A., MESAS-CARRASCOSA, F. J., E PEÑA, J. M. Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery. **Agronomy for Sustainable Development**, [s.l.], v.36, n.4, p.67, dez. 2016.

MAIA, E.; SIQUEIRA, D. L.; SILVA, F. F.; PETERNELLI, L. A.; SALOMÃO, L. C. C. Método de comparação de modelos de regressão não-lineares em bananeiras. **Ciência Rural**, Santa Maria, v. 39, n. 5, p. 1380-1386, ago. 2009.

MEDEIROS, F. A.; ALONÇO, A. D. S.; BALESTRA, M. R. G.; DIAS, V. D. O.; LANDERHAL JÚNIOR, M. L. Utilização de um veículo aéreo não-tripulado em atividades de imageamento georeferenciado. **Ciência rural**, Santa Maria, v. 38, p.2375-2378, nov. 2008.

MENDES, A. N. G.; GUIMARÃES, R. J. **Economia cafeeira: o agrobusiness**. Lavras: UFLA/faepe, 1997.

MESAS-CARRASCOSA, F. J.; NOTARIO GARCÍA, M. D.; MEROÑO DE LARRIVA, J. E.; GARCÍA-FERRER, A. An Analysis of the Influence of Flight Parameters in the Generation of Unmanned Aerial Vehicle (UAV) Orthomosaicks to Survey Archaeological Areas. **Sensors**, [s.l.], v.16, n.11, p.1838, nov. 2016.

MOLIN, J. P. et al. Test procedure for variable rate fertilizer on coffee. **Acta Scientiarum. Agronomy**, Maringá, v. 32, n. 4, p. 569-575, dez. 2010.

MOORE, D. S. **The Basic Practice of Statistics**. New York: Freeman, 2007.

MOORTHY, I.; MILLER, J. R.; BERNI, J. A. J.; ZARCO-TEJADA, P.; HU, B.; CHEN, J. Field characterization of olive (*Olea europaea* L.) tree crown architecture using terrestrial laser scanning data. **Agricultural and Forest Meteorology**, [s.l.], v. 151, n.2, p. 204-214, fev. 2011.

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.

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*, [s.l.], v.37, p.1193–1200, jan. 2008.

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

OLIVEIRA, P. M. DE; SILVA, A. M. DA; CASTRO NETO, P. Estimativa da evapotranspiração e do coeficiente de cultura do cafeeiro (*coffea arabica* l.). *Irriga, Botucatu*, v.8, p.273-282, dez. 2003.

OLIVEIRA, L. F. C. D.; OLIVEIRA, R. Z.; BORGES, L. B.; WEHR, T. R.; BONOMO, R. Coeficiente de cultura e relações hídricas do cafeeiro, cultivar catucaí, sob dois sistemas de manejo da irrigação. *Pesquisa Agropecuária Tropical*, Goiânia, v. 37, n. 3, set. 2007.

PANAGIOTIDIS, D.; ABDOLLAHNEJAD, A.; SUROVÝ, P.; CHITECULO, V. Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing*, [s.l.], v.3, p.2392-2410, dez. 2016.

PEÑA, J. M., TORRES-SÁNCHEZ, J., DE CASTRO, A. I., KELLY, M., E LÓPEZ-GRANADOS, F. Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (UAV) images. *PloS one*, [s.l.], v.8, n.10, p.77151, out. 2013.

PONCIANO, P. F.; SCALON, J. D. Análise espacial da produção leiteira usando um modelo autoregressivo condicional. *Semina: Ciências Agrárias*, Londrina, v. 31, n. 2, jun. 2010.

PRIMICERIO, J; DI GENNARO, S. F.; FIORILLO, E.; GENESIO, L.; LUGATO, E.; MATESE, A.; VACCARI, F. P. A flexible unmanned aerial vehicle for precision agriculture. *Precision Agriculture*, [s.l.], v. 13, n. 4, p. 517-523, ago. 2012.

QUEIROZ-VOLTAN, R. B.; PEROSIN CABRAL, L.; PARADELA FILHO, O.; FAZUOLI, L. C. Eficiência da poda em cafeeiros no controle da *Xylella fastidiosa*. *Bragantia*, Campinas, v. 65, n.3, p.433-440, jun. 2006.

R DEVELOPMENT CORE TEAM. R: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing. 2008. Disponível em: <<http://www.r-project.org>>. Acesso em: Jan. 2018.

RAMIREZ, G. M.; JÚNIOR J. Z. Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial. *Engenharia Agrícola*, Jaboticabal, v.30, n.3, p.468-479, mai/jun. 2010.

RANGO, A.; LALIBERTE, A.; STEELE, C.; HERRICK, J. E.; BESTELMEYER, B.; SCHMUGGE, T.; JENKINS, V. Using unmanned aerial vehicles for rangelands: current applications and future potentials. *Environmental Practice*, [s.l.], v. 8, n. 03, p. 159-168, jun. 2006.

RANGO, A., LALIBERTE, A. S., HERRICK, J. E., WINTERS, C., HAVSTAD, K., STEELE, C. Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. **Journal of Applied Remote Sensing**, [s.l.], v. 3, n. 1, p. 033542, Ago. 2009.

REZENDE, F. C.; CALDAS, A. L. D.; SCALCO, M. S.; DE FARIA, M. A. Índice de área foliar, densidade de plantio e manejo de irrigação do cafeeiro. **Coffee Science**, Lavras, v. 9, n.3, p.374-384, jul/set. 2014.

ROMERO, V. R.; VILLAREAL, A. M.; LEÓN, J. L. T.; HERNÁNDEZ, A. H. Perspectivas de la tecnología VANT en el cultivo de palma de aceite: monitorización del cultivo mediante imágenes aéreas de alta resolución. **Revista Palmas**, Bogotá, v. 36, n. 3, p. 25-41, jun. 2015.

SATO, F. A.; SILVA, A. M. D.; COELHO, G.; SILVA, A. C. D.; CARVALHO, L. G. D. Coeficiente de cultura (Kc) do cafeeiro (coffea arabica l.) No período de outono-inverno na região de Lavras-MG. **Engenharia Agrícola**, Jaboticabal, v.27, n.2, p. 383-391, jan. 2007.

SEELAN, S. K.; LAGUETTE, S.; CASADY, G. M.; SEIELSTAD, G. A. Remote sensing applications for precision agriculture: a learning community approach. **Remote Sensing of Environment**, [s.l.], v.88, n. 88, p. 157-169, nov. 2003.

SEVERTSON, D.; CALLOW, N.; FLOWER, K.; NEUHAUS, A.; OLEJNIK, M.; NANSEN, C. Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola. **Precision Agriculture**, [s.l.], v. 17, n. 6, p. 659-677, dez. 2016.

SIEBERT, S.; TEIZER, J. Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system. **Automation in Construction**, [s.l.], v.41, p.1-14, mai. 2014.

STAFFORD, J. V. Implementing Precision Agriculture in the 21st Century. **Journal of Agricultural Engineering Research**, [s.l.], v. 76, p. 267-275, jul.2000.

STONE, L.F.; P.M. SILVEIRA. Determinação da evapotranspiração para fins de irrigação. **Embrapa- CNPAF**, Santo Antônio de Goiás, p. 49, 1995.

SUROVÝ, P.; RIBEIRO, N. A.; PANAGIOTIDIS, D. Estimation of positions and heights from UAV-sensed imagery in tree plantations in agrosilvopastoral systems. **International Journal of Remote Sensing**, [s.l.], v.39, n.14, p.4786-4800, fev. 2018.

TOKEKAR, P.; VANDER HOOK, J.; MULLA, D.; ISLER, V. Sensor planning for a symbiotic UAV and UGV system for precision agriculture. **IEEE Transactions on Robotics**, [s.l.], v. 32, n. 6, p. 1498-1511, dez.2016.

TORRES-SÁNCHEZ, J.; PEÑA, J. M.; CASTRO, A. I. D.; LÓPEZ-GRANADOS, F. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using

images from UAV. **Computers and Electronics in Agriculture**, [s.l.], v. 103, p. 104-113, abr. 2014.

TURNER, D.; LUCIEER, A.; WALLACE, L. Direct georeferencing of ultrahigh-resolution UAV imagery. **Remote Sensing**, Basel, v.52, n.5, p.2738–2745, mai. 2014.

TURNER, D., LUCIEER, A.; DE JONG, S. M. Time series analysis of landslide dynamics using an unmanned aerial vehicle (UAV). **Remote Sensing**, Basel, v.7, n.2, p.1736-1757, fev. 2015.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Disponível em:<<http://usda.mannlib.cornell.edu/MannUsda/viewDocumentInfo.do?documentID=1801>> Acesso em: Março de 2018.

UYSAL, M.; TOPRAK, A. S.; POLAT, N. DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hill. **Measurement**, [s.l.], v.73, p.539-543, set. 2015.

VERICAT, D.; BRASINGTON, J.; WHEATON, J.; COWIE, M. Accuracy assessment of aerial photographs acquired using lighter-than-air blimps: Low-cost tools for mapping river corridors. **River Research and Applications**, [s.l.], v.25, p.985–1000, out. 2008.

VIERLING, L.A., FERSDAHL, M., CHEN, X., LI, Z., AND ZIMMERMAN, P. The short wave aerostat-mounted imager (SWAMI): a novel platform for acquiring remotely sensed data from a tethered balloon. **Remote Sensing**, Basel, v.103, n.3, p.255–264, ago. 2006.

VILLA NOVA, N. A.; FAVARIN, J. L.; ANGELOCCI, L. R.; DOURADO NETO, D. Estimativa do coeficiente de cultura (Kc) do cafeeiro em função de variáveis climatológicas e fitotécnicas. **Bragantina**, Campinas, v.61, n.1, p.81-88, mar. 2002.

WALLACE, L.; LUCIEER, A.; MALENOVSKÝ, Z.; TURNER, D.; VOPĚNKA, P. Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. **Forests**, [s.l.], v.7, n.3, p. 1-16, mar. 2016.

WANG, J.; GE, Y.; HEUVELINK, G. B.; ZHOU, C.; BRUS, D. Effect of the sampling design of ground control points on the geometric correction of remotely sensed imagery. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v.18, p.91-100, ago. 2012.

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

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

ZAJKOWSKI, T. J.; DICKINSON, M. B.; HIERS, J. K.; HOLLEY, W.; WILLIAMS, B. W.; PAXTON, A.; WALKER, G. W. Evaluation and use of remotely piloted aircraft

systems for operations and research–RxCADRE 2012. **International Journal of Wildland Fire**, [s.l.], v.25, n.1, p.114-128, jan. 2016.

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