



Unimontes

Programa de Pós-Graduação em Produção Vegetal no Semiárido

**ANÁLISE DE ATRIBUTOS BIOMÉTRICOS DE PLANTAS CULTIVADAS
POR MEIO DE SENSOR RGB EMBARCADO EM VEÍCULO AÉREO NÃO
TRIPULADO**

WILLER FAGUNDES DE OLIVEIRA

2020

WILLER FAGUNDES DE OLIVEIRA

**ANÁLISE DE ATRIBUTOS BIOMÉTRICOS DE PLANTAS CULTIVADAS POR
MEIO DE SENSOR RGB EMBARCADO EM VEÍCULO AÉREO NÃO
TRIPULADO**

Tese apresentada à Universidade Estadual de Montes Claros como parte das exigências do Programa de Pós-Graduação em Produção Vegetal no Semiárido, área de concentração em Produção Vegetal, para obtenção do título de Doutor.

Orientador

Prof. Dr. Silvânio Rodrigues dos Santos

**JANAÚBA-MG
2020**

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

Oliveira, Willer Fagundes de
O48a Análise de atributos biométricos de plantas cultivadas por meio de sensor RGB embarcado em veículo aéreo não tripulado [manuscrito] / Willer Fagundes de Oliveira – 2020.
70 p.

Tese (Doutorado) – Programa de Pós-Graduação em Produção Vegetal no Semiárido, Universidade Estadual de Montes Claros – Janaúba, 2020.

Orientador: Prof. D. Sc. Silvânio Rodrigues dos Santos.

1. Drone. 2. Plantas cultivadas. 3. Sensoriamento remoto. I. Santos, Silvânio Rodrigues dos. II. Universidade Estadual de Montes Claros. III. Título.

CDD. 621.3678

Catálogo: Joyce Aparecida Rodrigues de Castro Bibliotecária CRB6/2445



GOVERNO DO ESTADO DE MINAS GERAIS

Universidade Estadual de Montes Claros

Docentes do Departamento de Ciências Agrárias

Anexo nº 0002/UNIMONTES/CCET/DCA/PROF/2020

PROCESSO Nº 2310.01.0016067/2020-46

WILLER FAGUNDES DE OLIVEIRA

**ANÁLISE DE ATRIBUTOS BIOMÉTRICOS DE PLANTAS CULTIVADAS POR MEIO DE SENSOR
RGB EMBARCADO EM VEÍCULO AÉREO NÃO TRIPULADO**

Tese apresentada à Universidade Estadual de Montes Claros, como parte das exigências do Programa de Pós-Graduação em Produção Vegetal no Semiárido, área de concentração em Produção Vegetal, para obtenção do título de Doutor.

APROVADA em 28 de outubro de 2020.

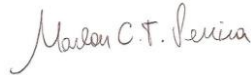
Eu, **Silvânio Rodrigues dos Santos**, subscrito abaixo, orientador do Sr. **Willer Fagundes de Oliveira**, declaro que este trabalho de conclusão foi aprovado na data acima indicada, pela Comissão Julgadora abaixo nomeada. Declaro também que as assinaturas digitalizadas são autênticas, conforme a Lei 13726, de 8 de outubro de 2018.

A handwritten signature in blue ink that reads "Silvano Rodrigues dos Santos".

Prof. Dr. Silvânio Rodrigues dos Santos
Unimontes (Orientador)

A handwritten signature in blue ink that reads "Marcos Koiti Kondo".

Prof. Dr. Marcos Koiti Kondo
Unimontes (Conselheiro)



Prof. Dr. Marlon Cristian Toledo Pereira
Unimontes (Conselheiro)



Prof. Dr. Samuel de Assis Silva
Ufes (Conselheiro)



Dr. Filipe Inácio Matias
University of Wisconsin (Conselheiro)

Janaúba
2020



Documento assinado eletronicamente por **Silvanio Rodrigues dos Santos, Professor(a)**, em 29/10/2020, às 15:18, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



Documento assinado eletronicamente por **Marcos Koiti Kondo, Professor(a)**, em 30/10/2020, às 08:45, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



Documento assinado eletronicamente **Marlon Cristian Toledo Pereira, Professor de Educação Superior**, em 06/01/2021, às 20:28, conforme horário oficial de Brasília,, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



A autenticidade deste documento pode ser conferida no site http://sei.mg.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **20853255** e o código CRC **ECBFD051**.

Ao Norte de Minas Gerais, em especial à cidade de Janaúba, que bem me acolheu.

Dedico

AGRADECIMENTOS

A Deus, amor imensurável, presença essencial na minha vida. Obrigado por me conceder condições físicas e espirituais para realização de mais um sonho. Obrigado, Senhor!

À Universidade Estadual de Montes Claros, em especial ao Departamento de Ciências Agrárias (DCA), pelos momentos que me ausentei para realização deste trabalho. É uma honra fazer parte desse time!

Ao Programa de Pós-Graduação em Produção Vegetal no Semiárido (PPGPVS), em especial aos professores Dra. Adelica, Dra. Camila, Dr. Marlon e Dr. Victor, suas aulas foram inesquecíveis!

Ao querido professor e orientador Dr. Silvânio. Obrigado pela receptividade, confiança, incentivo, parceria e apoio para realizar este trabalho. Obrigado por tudo!

Aos professores Dr. Antônio e Dr. Renato, ambos do Programa de Pós-Graduação em Modelagem Computacional e Sistemas (PPGMCS), pelos conhecimentos (teóricos e práticos) compartilhados. Vocês foram fundamentais neste trabalho!

À minha linda e amável esposa Maria Luísa (Malu), por me incentivar e apoiar, incondicionalmente, na minha vida pessoal e profissional. Agradeço também pela paciência e compreensão. Muito Obrigado!

Aos meus queridos filhos Maria Clara e João Pedro, por me receberem todos os dias em casa com um belo sorriso, muita alegria e amor. Peço-lhes desculpas pelo tempo que me ausentei para realização deste trabalho. Vocês são a razão e o motivo da minha batalha. Papai ama muito vocês!

Aos meus pais João Batista e Solange, eternos apoiadores do meu projeto de vida. À minha irmã Amanda. Vocês terão sempre o meu amor!

Também ao meu grande amigo Prof. Dr. Lucas Alves da Silva. Obrigado irmão!

Mais uma vez, obrigado a TODOS!

SUMÁRIO

RESUMO GERAL	viii
GENERAL ABSTRACT	x
INTRODUÇÃO GERAL.....	11
REFERÊNCIAS	13
CAPÍTULO 1	15
QUALIDADE DE PLANTIOS DE EUCALIPTO POR MEIO DE IMAGENS AÉREAS E TÉCNICAS DE VISÃO COMPUTACIONAL	15
1. INTRODUÇÃO	18
2. MATERIAL E MÉTODOS	20
3. RESULTADOS E DISCUSSÃO	27
4. CONCLUSÕES.....	34
5. AGRADECIMENTOS	34
REFERÊNCIAS.....	34
CAPÍTULO 2.....	37
POMAR CÍTRICO EM FORMAÇÃO AVALIADO MEDIANTE IMAGENS AÉREAS OBTIDAS COM VANT E TÉCNICAS DE VISÃO COMPUTACIONAL.....	37
1. INTRODUÇÃO	39
2. MATERIAL E MÉTODOS	42
3. RESULTADOS E DISCUSSÃO	51
4. CONCLUSÕES	64
5. AGRADECIMENTOS	65
REFERÊNCIAS.....	65
CONCLUSÕES GERAIS E CONSIDERAÇÕES FINAIS	70

RESUMO GERAL

OLIVEIRA, Willer Fagundes de. **Análise de atributos biométricos de plantas cultivadas por meio de sensor RGB embarcado em Veículo Aéreo Não Tripulado**. 2020. 70p. Tese (Doutorado em Produção Vegetal no Semiárido) - Universidade Estadual de Montes Claros, Janaúba, MG¹.

As geotecnologias fornecem diversas técnicas e ferramentas que viabilizam as análises da variabilidade espacial e temporal, dos solos e das plantas, consolidando assim, a prática da Agricultura de Precisão. Os Veículos Aéreos Não Tripulados (VANTs) têm papel relevante no mapeamento aéreo de alta resolução espacial. Embora as atividades aerofotogramétricas, por meio de VANTs, tenham avançado nas ciências agrárias, a geração de produtos técnicos aplicados e automatizados não avançou com a mesma rapidez, permanecendo, assim, a necessidade de inúmeras pesquisas. Neste sentido, objetivou-se desenvolver métodos de análise de ortofotomosaico e modelos digitais de elevação (oriundos de sensor RGB embarcado em VANT), por meio de rotinas automatizadas, para avaliar a qualidade de plantios florestais de eucalipto (*Eucalyptus* ssp.) e pomar de lima ácida ‘Tahiti’- (*Citrus latifolia* Tanaka) em fase de formação. Dessa forma, pretendeu-se, também, desenvolver um fluxo de trabalho, contendo um conjunto de parâmetros aerofotogramétricos que possam ser utilizados de forma rápida, fácil e confiável, nas avaliações biométricas dessas culturas. Para tanto, utilizou-se um VANT, do tipo multirotor, DJI Phantom 4 Adv, equipado com um sensor RGB de 20 Megapixels. As rotinas computacionais foram desenvolvidas em ambientes de código aberto (*Open Source*), constituídas, por três fases de processamento: i) Estimativa dos Atributos Biométricos da Planta; ii) Análise Estatística e iii) Relatório Estatístico de Mapas (REM). As rotinas apresentaram acurácia elevada na estimativa de parâmetros biométricos das plantas (acima de 93%) e boa velocidade de processamento. Também, são capazes de identificar e contar as plantas, estimar os espaçamentos médios entre plantas e linhas de plantio, identificar e quantificar as falhas de plantio, determinar a densidade de plantio, delimitar e calcular a área da copa projetada, altura e volume de cada planta. Todas as análises são apresentadas de forma simples e intuitiva por meio do REM. Os resultados foram suficientes para definir um método de obtenção de dados aerofotogramétricos que podem ser utilizados para estimar e avaliar a qualidade dos atributos biométricos dos plantios supracitados, com flexibilidade de adaptação para outras culturas perenes.

¹**Banca Examinadora:** Prof. Dr. Silvano Rodrigues dos Santos - UNIMONTES (Orientador); Prof. Dr. Marlon Cristian Toledo Pereira - UNIMONTES (Conselheiro); Dr. Filipe Inácio Matias - University of Wisconsin (Conselheiro); Prof. Dr. Samuel de Assis Silva - UFES (Conselheiro); Prof. Dr. Marcos Koiti Kondo-UNIMONTES (Conselheiro).

Palavras-chave: Sensoriamento Remoto. Drone. Visão Computacional. Python.

GENERAL ABSTRACT

OLIVEIRA, Willer Fagundes de. **Analysis of biometric attributes of plants cultivated through a RGB sensor carried on Unmanned Aerial Vehicle**. 2020. 70 p. Thesis (Doctor's Degree in Plant Production in Semi-Arid) - Universidade Estadual de Montes Claros, Janaúba, MG².

Geotechnologies provides several techniques and tools that enable the analysis of spatial and temporal variability, of soils and plants, thus consolidating the practice of Precision Agriculture. Unmanned Aerial Vehicles (UAVs) play an important role in high spatial resolution aerial mapping. Although aerophotogrammetric activities, through UAVs, has advanced in the agricultural sciences, the generation of applied and automated technical products has not progressed as quickly, thus, the need for countless research remains. In this sense, the aim was to develop methods of analysis of orthophotomosaic and digital elevation models (from a RGB sensor embedded in UAV), through automated routines, to evaluate the quality of eucalyptus forest plantations (*Eucalyptus* ssp.) and 'Tahiti' acid lime orchard - (*Citrus latifolia* Tanaka) in the formation stage. Thus, it was also intended to develop a workflow, containing a set of aerophotogrammetric parameters that can be used, quickly, easily and reliably, in the biometric assessments of these cultures. For this purpose, an UAV, multirotor type, DJI Phantom 4 Adv, was used, equipped with a 20 Megapixel RGB sensor. The computational routines were developed in open source environments, consisting of three processing phases: i) Estimation of the Biometric Attributes of the Plant; ii) Statistical Analysis and iii) Statistical Map Report (SMR). The routines showed high accuracy in estimating the biometric parameters of the plants (above 93%) and good processing speed. Also, they are able to identify and count the plants, estimate the average spacing between plants and between rows, identify and quantify the planting failures, planting density, delimit and calculate the projected canopy area, height and volume of each plant. All analyzes are presented in a simple and intuitive way through SMR. The results were sufficient to define a method of obtaining aerophotogrammetric data that can be used to estimate and evaluate the quality of the biometric attributes of the aforementioned plantations, with the flexibility to adapt to other perennial crops.

Keywords: Remote Sensing. Drone. Computer vision. Python.

²**Guidance Committee:** Prof. Dr. Silvânio Rodrigues dos Santos - UNIMONTES (Advisor); Prof. Dr. Marlon Cristian Toledo Pereira - UNIMONTES (Counselor); Filipe Inácio Matias - University of Wisconsin (Counselor); Prof.^a Dr. Samuel de Assis Silva - UFES (Counselor); Dr. Prof. Dr. Marcos Koiti Kondo-UNIMONTES (Counselor).

INTRODUÇÃO GERAL

O aumento da produção de alimentos deve ser acompanhado por uma gestão sustentável que possa, pelo menos, minimizar o uso desordenado dos recursos naturais (WEISS *et al.*, 2020) e garantir a segurança alimentar em curto e médio prazo (PARK *et al.*, 2017). O desenvolvimento de tecnologias que aperfeiçoem as operações de monitoramento das lavouras também faz parte desse tipo de gestão (BURKART *et al.*, 2018).

Em vista deste cenário, princípios básicos de manejo que consideram a variabilidade dos solos e das plantas, no espaço e tempo, podem auxiliar os produtores rurais nas tomadas de decisão em diversos sistemas de cultivo (ARTUR *et al.*, 2014). Considerar a variabilidade no planejamento da produção agrícola pode aumentar a eficiência das aplicações dos insumos agrícolas (corretivos, fertilizantes e defensivos), com possível aumento da produtividade (BERNARDI *et al.*, 2014).

As geotecnologias, por meio do *Global Navigation Satellite System* (GNSS), Sensoriamento Remoto, Aerofotogrametria e o Sistema de Informação Geográfica (SIG), trouxeram a viabilidade operacional para tratar a variabilidade espacial e temporal, consolidando assim, a prática da Agricultura de Precisão (AP) (QUEIRÓS *et al.*, 2014). Os referidos autores afirmam que a AP inseriu uma concepção baseada no desenvolvimento e aplicação das tecnologias de informação e comunicação no campo que, certamente, aumentou os ganhos econômicos e benefícios ambientais.

Em linhas gerais, a AP é baseada na variabilidade espacial e temporal do solo e das plantas (MAHLEIN, 2016), ao contrário das práticas tradicionais de manejo agrícola, as quais assumem que os atributos no campo são homogêneos, ou simplesmente, são avaliados por meio da média dos atributos amostrados (HILLNHÜTTER; MAHLEIN, 2008). Atualmente, utiliza-se o termo Agricultura 4.0 para os conceitos já preconizados na AP, com a incorporação de tecnologias como Internet das Coisas, *Big Data*, Inteligência Artificial e Computação em Nuvem (ROSE;CHILVERS, 2018; ZHAI *et al.*, 2020).

A Agricultura 4.0 quando praticada em grandes áreas, inviáveis para serem cobertas ou manejadas pelo trabalho de campo manual, é viabilizada pelas técnicas de Sensoriamento Remoto, as quais são utilizadas para reunir informações necessárias (BURKART *et al.*, 2018), de forma rápida e precisa (VECCHIO *et al.*, 2020). Neste sentido, o Sensoriamento Remoto surge como uma ferramenta essencial, uma vez que se apresenta como um meio não destrutivo e sistemático de obter informações da planta e do solo, em diferentes escalas, além de possibilitar a caracterização das variabilidades supracitadas, representando-as em um

mapa. Em se tratando de mapeamento em maiores escalas, os Veículos Aéreos Não Tripulados (VANTs) têm se destacado.

Com o desenvolvimento da robótica avançada, os VANTs têm sido amplamente utilizados como uma das principais plataformas de aquisição de dados do SR. Em comparação com os dados oriundos dos sensores acoplados em satélites (orbital e suborbital), os VANTs apresentam-se mais flexíveis, especialmente em termos de frequência de revisita, operação e custo relativamente baixo (WEISS *et al.*, 2020), principalmente, quando se utiliza sensor RGB. Esse sensor possibilita diversas aplicações, mas inicialmente, por meio da aerofotogrametria digital e técnica de geoprocessamento avançada (como o *structure from motion-SfM*), obtêm-se três produtos triviais: o modelo digital de superfície (MDS) e modelo digital de terreno (MDT) e o ortofotomosaico.

A partir dos produtos supracitados é possível desenvolver soluções ou aplicações que poderão ser representadas em diversos mapas temáticos, tais como: classificação do relevo, estimativas de atributos biométricos (contagem de plantas, espaçamentos, altura e área da copa, volume, etc), identificação de pragas, doenças, plantas daninhas e, até mesmo, auxílio do manejo da irrigação. Embora haja avanços nas aplicações da aerofotogrametria digital, dois grandes desafios ainda permanecem, conforme apontado por Pathak *et al.* (2020): i) desenvolvimento de plataformas mais intuitivas e rápidas para processamento de imagens e ii) capacitação do usuário final (agricultores, consultores, pesquisadores, etc).

Conforme discutido por Mahlein (2016), as análises de dados de monitoramento da lavoura devem ser desenvolvidas a partir de diferentes perspectivas. Para a autora, é necessário vincular pesquisas complementares entre a produção vegetal e os diferentes tipos de plataformas e sensores, pois só assim, será possível atingir soluções práticas, exequíveis e poderosas para estimar as condições reais das plantas.

Com relação aos algoritmos e métodos de obtenção de dados por meio de VANT, a comunidade do Sensoriamento Remoto, no momento, enfrenta a era do *big data*, onde as máquinas (plataforma e sensor) e algoritmos de aprendizagem estão avançando cada vez mais, com aplicações bem específicas, para diferentes tipos de cultura e/ou cultivar, estágio fenológico e região (quando se trata de comportamento espectral). Para Vecchio *et al.* (2020), o desenvolvimento de soluções agrícolas, na óptica da Agricultura 4.0, é de fundamental importância para assegurar ao consultor agrícola, ferramentas que possibilitam sistematizar e otimizar as análises de campo.

Park *et al.* (2017) e Ok e Ozdarici-Ok (2018) ressaltam a importância de desenvolver soluções exequíveis que possam dar suporte à tomada de decisão e, ao mesmo tempo,

conforme apontado por Zhai *et al.* (2020), que tais soluções tenham acessibilidade, escalabilidade, interoperabilidade, conhecimento especializado e capacidade de análise de série histórica rápida e precisa.

Logo, algumas indagações na óptica das ciências agrárias precisam ser respondidas, tais como: a) Há necessidade de estabelecer um fluxo de trabalho para obtenção e processamento de dados aerofotogramétricos oriundos de VANT?; b) Qual é o efeito da variação da escala do mapeamento (ou *ground sample distance*-GSD) na estimativa dos atributos biométricos da planta?; c) É possível desenvolver soluções ou rotinas computacionais automatizadas para análise de ortofotomosaico, de baixo custo e exequíveis para o usuário final?

Neste sentido, objetivou-se desenvolver métodos, por meio de técnicas de visão computacional e rotinas automatizadas, de análises de ortofotomosaico RGB (obtidos com VANT) para avaliar a qualidade de plantios florestais de eucalipto (*Eucalyptus* spp.) e pomar cítrico de lima ácida ‘Tahiti’ (*Citrus latifolia* Tanaka), ainda em fase de formação. Objetivou-se, também, desenvolver um fluxo de trabalho, contendo um conjunto de parâmetros aerofotogramétricos que possam ser utilizados, de forma rápida, fácil e confiável, nas avaliações biométricas das referidas culturas.

REFERÊNCIAS

- ARTUR, A. G.; OLIVEIRA, D. P.; COSTA, M. C. G.; ROMERO, R. E.; SILVA, M. V. C.; FERREIRA, T. O. Variabilidade espacial dos atributos químicos do solo, associada ao microrrelevo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n. 2, p. 141-149, 2014.
- BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa Informação Tecnológica, 2014.
- BURKART, A.; HECHT, V. L.; KRASKA, T.; RASCHER, U. Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution. **Precision Agriculture**, Dordrecht, v. 19, n. 1, p. 134-146, 2018.
- HILLNHÜTTER, C.; MAHLEIN, A.K. Early detection and localisation of sugar beet diseases: new approaches. **Gesunde Pflanzen**, Berlin, v. 60, n. 4, p. 143-149, 2008.
- MAHLEIN, A.-K. Plant Disease Detection by Imaging Sensors: Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. **Plant Disease**, Saint Paul, v. 100, n. 2, p. 241-251, 2016.

OK, A. O.; OZDARICI-OK, A. 2-D delineation of individual citrus trees from UAV-based dense photogrammetric surface models. **International Journal of Digital Earth**, v. 11, n. 6, p. 583-608, 2018.

PARK, S.; RYU, D.; FUENTES, S.; CHUNG, H.; HERNÁNDEZ-MONTES, E.; O'CONNELL, M. Adaptive Estimation of Crop Water Stress in Nectarine and Peach Orchards Using High-Resolution Imagery from an Unmanned Aerial Vehicle (UAV). **Remote Sensing**, Chur, v. 9, n. 8, p. 828, 2017.

PATHAK, S. V.; MOHOD, A. G.; SAWANT, A. A. Review on effective role of UAV in precision farming. **Journal of Pharmacognosy and Phytochemistry**, v. 9, n. 4, p. 463-467, 2020.

QUEIRÓS, L. R.; LUCHIARI JUNIOR, A.; CAMARGO NETO, J.; MASSRUHÁ, S. M. F. S.; INAMASU, R. Y.; SPERANZA, E. A.; EVANGELISTA, S. R. M. Análise das possibilidades e tendências do uso das tecnologias da informação e comunicação em agricultura de precisão. *In*: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa Informação Tecnológica, 2014. p. 197-108.

ROSE, D. C.; CHILVERS, J. Agriculture 4.0: broadening responsible innovation in an era of smart farming. **Frontiers in Sustainable Food Systems**, v. 2, p. 87, 2018.

VECCHIO, Y.; DE ROSA, M.; ADINOLFI, F.; BARTOLI, L.; MASI, M. Adoption of precision farming tools: A context-related analysis. **Land Use Policy**, Guildford, v. 94, p. 104481, 2020.

WEISS, M.; JACOB, F.; DUVEILLER BOGDAN, G. H. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, New York, v. 236, p. 111402, 2020.

ZHAI, Z.; MARTÍNEZ, J. F.; BELTRAN, V.; MARTÍNEZ, N. L. Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, New York, v. 170, p. 1-16, 2020.

CAPÍTULO 1
QUALIDADE DE PLANTIOS DE EUCALIPTO POR MEIO DE IMAGENS AÉREAS E
TÉCNICAS DE VISÃO COMPUTACIONAL
(Artigo formatado de acordo com as normas de Revista Ciência Agrônômica)

Quality of eucalyptus plantations through aerial images and computer vision techniques

ABSTRACT- The major challenge for studies using embedded sensors in Unmanned Aerial Vehicles (UAV) is the high dimensionality of the data to be interpreted, since most sensors do not directly measure the plant's biometric parameters. Hence, the present work has the objective to develop a method for using digital images, obtained from an airborne RGB sensor in UAV, for the quality control (survival inventory, average spacing between plants, between rows and spatial distribution of planting density) of eucalyptus (*Eucalyptus* spp.), implanted in a commercial area. A multicopter type UAV, model Phantom 4 Pro was used, equipped with a 20 Megapixel RGB sensor, programmed to capture images with 80% and 60%, longitudinal and lateral overlap, respectively. From the generated orthomosaic, a test area was clipped to be used in the development of the processing routine based on computer vision techniques. The developed method makes a mapping of the individual location of each plant in the orthomosaic, through image segmentation and object detection technique (Template Matching), followed by a Delaunay triangulation and Voronoi diagram. The resulting in a mesh that allows for the automatic generation of Maps-Reports of some silvicultural variables, such as plant counting, planting failures, spacing distribution between rows and between plants. In addition to the high computational performance, the methodology showed high accuracy by correctly identifying more than 93% of the plants in an area with more than 3,000 plants.

Keywords: Remote Sensing. Vegetation Index. Drone. Python. Eucalyptus.

RESUMO- O grande desafio para estudos que utilizam sensores embarcados em Veículos Aéreos Não Tripulados (VANTs) está na interpretação dos dados de alta dimensionalidade, pois a maioria dos sensores não mensuram diretamente os parâmetros biométricos da planta. Neste sentido, objetivou-se com o presente trabalho, desenvolver um método de utilização de imagens digitais, obtidas por meio de sensor RGB aerotransportado em VANT, para o controle de qualidade (inventário de sobrevivência, espaçamento médio entre plantas, entrelinas e distribuição espacial da

densidade de plantio) de eucalipto (*Eucalyptus* spp.), implantado em área comercial. Utilizou-se um VANT, do tipo multirotor, do modelo DJI Phantom 4 Pro, equipado com um sensor RGB de 20 Megapixels, programado para capturar imagens com 80% e 60% de sobreposição longitudinal e lateral, respectivamente. Após a geração do ortomosaico, recortou-se uma área teste, a qual foi usada no desenvolvimento da rotina de processamento baseada em técnicas de visão computacional. O método desenvolvido faz um mapeamento da localização individual de cada planta no ortomosaico, por meio de segmentação de imagem e técnica de detecção de objetos (*Template Matching*), seguida de uma triangulação Delaunay e diagrama de Voronoi. O resultado é uma malha que automatiza a geração de Mapas-Relatório de algumas variáveis silviculturais, como contagem de plantas, falhas de plantio, distribuição de espaçamentos entrelinhas e entre plantas. Além de alto desempenho computacional, a metodologia apresenta acurácia elevada, identificando corretamente mais de 93% das plantas de uma área com mais de 3 mil plantas.

Palavras-chave: Sensoriamento Remoto. Índice de Vegetação. Drone. *Python*. *Eucalyptus*.

1. INTRODUÇÃO

Princípios básicos de manejo que consideram a variabilidade dos solos e das plantas, no espaço e tempo, podem auxiliar os gestores rurais nas tomadas de decisão em diversos sistemas de produção agrícola (ARTUR *et al.*, 2014). Considerar a variabilidade no planejamento da produção agrícola pode aumentar a eficiência das aplicações dos insumos agrícolas (corretivos, fertilizantes e defensivos), com possível aumento da produtividade (BERNARDI *et al.*, 2014).

As imagens digitais utilizadas na agricultura podem ser obtidas por meio de diversas plataformas, especificamente, em três níveis de aquisição: (a) orbital (Satélites), (b) aéreo [Aeronaves Tripuláveis (AT) e Veículos Aéreos Não Tripulados (VANTs)] e (c) terrestre (sensores portáteis) (SHIRATSUCHI *et al.*, 2014). Entre os produtos derivados dessas imagens estão: estimativa da biomassa, avaliação do estresse hídrico, severidade de doenças, identificação e contagem de plantas, falhas de plantio, entre outras.

Durante a etapa de coleta de dados aerofotogramétricos, algumas variações locais devem ser levadas em consideração, tais como: o relevo (MANCONI *et al.*, 2019) e a iluminação (SHI, Yeyin *et al.*, 2016). Recomenda-se planejar e executar a operação dentro da janela de voo (meio-dia solar verdadeiro, com intervalo de duas horas para mais ou para menos), levando sempre em consideração as configurações do sensor (ISO, tempo de exposição e abertura), conforme apontado por Wang *et al.* (2019).

O grande desafio para os estudos que utilizam sensores em VANT está na interpretação dos dados de alta dimensionalidade, pois a maioria dos sensores não mensura diretamente os parâmetros físicos e morfo-fisiológicos das plantas (DUARTE; SILVA; TEODORO, 2018) o que requer processamento das imagens por software especializados. Há muitas áreas de pesquisa que precisam ser mais detalhadas, em especial os modelos de monitoramento (até então, em grande parte, avaliados manualmente) e previsão da produção agrícola (BALLESTEROS *et al.*, 2014; BORGOGNO-MONDINO *et al.*, 2018; KOH *et al.*, 2019; POBLETE-ECHEVERRÍA *et al.*, 2017).

Ruza *et al.* (2017) afirmam que, embora as atividades aerofotogramétricas com VANT tenham avançado no setor florestal, a geração de produtos técnicos aplicados e automatizados não avançou com a mesma rapidez, permanecendo, assim, a necessidade de inúmeras pesquisas. Özcan *et al.* (2017) e Park *et al.* (2017) também ressaltam a importância de novos estudos que explorem e apresentem métodos mais exequíveis utilizando imagens oriundas de sensores em VANTs.

Para Yao (2019), com o desenvolvimento dos VANTs, juntamente com os sensores embarcados, o processamento digital de imagem, na sua tarefa mais trivial, que consiste em segmentar e classificar imagens em duas e/ou em três dimensões, também teve grandes avanços, permitindo detectar e rastrear objetos em escalas temporal e espacial mais precisas. Os referidos autores reafirmam que isso só foi possível por meio da utilização de técnicas de visão computacional e aprendizado de máquina, proporcionando ganhos significativos na capacidade de análise automatizada dos dados.

Neste sentido, desenvolver e validar metodologias que possibilitam extrair e visualizar a variabilidade espacial de alguns atributos da planta, com acurácia e rapidez, são ações que irão contribuir para o monitoramento e controle da qualidade de sistemas agrícolas e florestais (FAN *et al.*, 2018; GUERRA-HERNÁNDE *et al.*, 2018), ou seja, estimativa do inventário de sobrevivência, espaçamento médio entre plantas, entrelinhas e distribuição espacial da densidade de plantio, identificação de falhas e estimativa de mudas para o replantio.

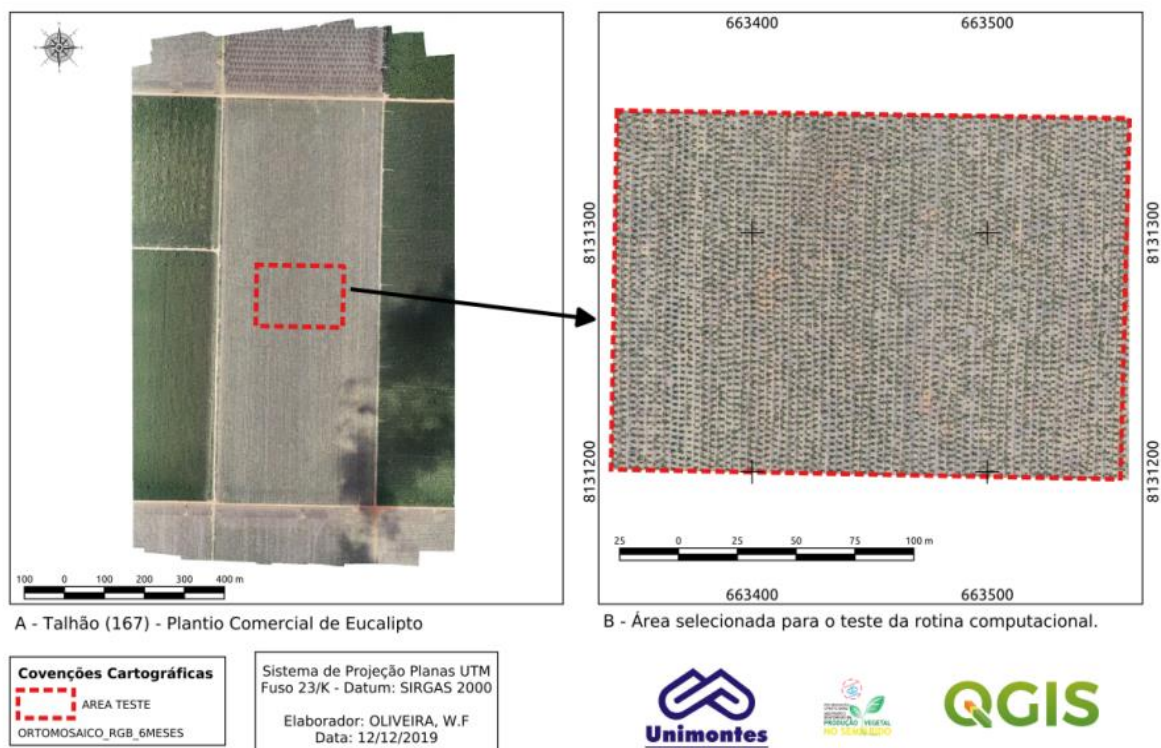
Instigado por esses desafios, objetivou-se desenvolver um método (por meio de rotinas automatizadas) de utilização de imagens aéreas (obtidas por meio de sensor RGB embarcado em VANT) para o controle de qualidade da cultura do eucalipto (*Eucalyptus ssp.*), utilizando-se técnicas de visão computacional.

2. MATERIAL E MÉTODOS

Área de estudo

Selecionou-se uma área de plantio comercial (39,5 ha) de eucalipto (*Eucalyptus urophylla* x *E. Grandis*), com espaçamento 3 m x 3 m e 180 dias após o plantio, município de Juramento, MG.

Figura 1- Localização da área de estudo, Juramento, MG.



Contudo, para o desenvolvimento da rotina computacional, recortou-se um retângulo envolvente (área teste: 3,3 ha), cujas coordenadas centrais UTM são: E 663.461, N 8.131.368 e h = 1210 m (SIRGAS 2000, 23-K) (Figura 1).

Coleta dos dados aerofotogramétricos

A coleta dos dados aerofotogramétricos foi realizada no dia 23/11/2018, por meio de um VANT, do tipo multirrotor, modelo Phantom 4 Pro, equipado com um sensor RGB de 20 Megapixels, 13,2 mm x 8,8 mm, distância focal de 9,1561 mm. Para a construção do ortomosaico, o plano de voo foi elaborado no aplicativo Drone Deploy[®], com sobreposição longitudinal e lateral de 80% e 60%, respectivamente. Já a altura de voo foi programada para 250 m, com velocidade máxima de 15 m.s⁻¹ e *Ground Sample Distance* (GSD) de 7,0 cm (8 bits de resolução radiométrica). Vale ressaltar que o voo foi planejado para cobrir um talhão de 396 m x 997 m, sem pontos de controle. Por fim, executou-se a missão às 11:00 h (visando minimizar o efeito de sombreamento), finalizando-a com 62 imagens coletadas.

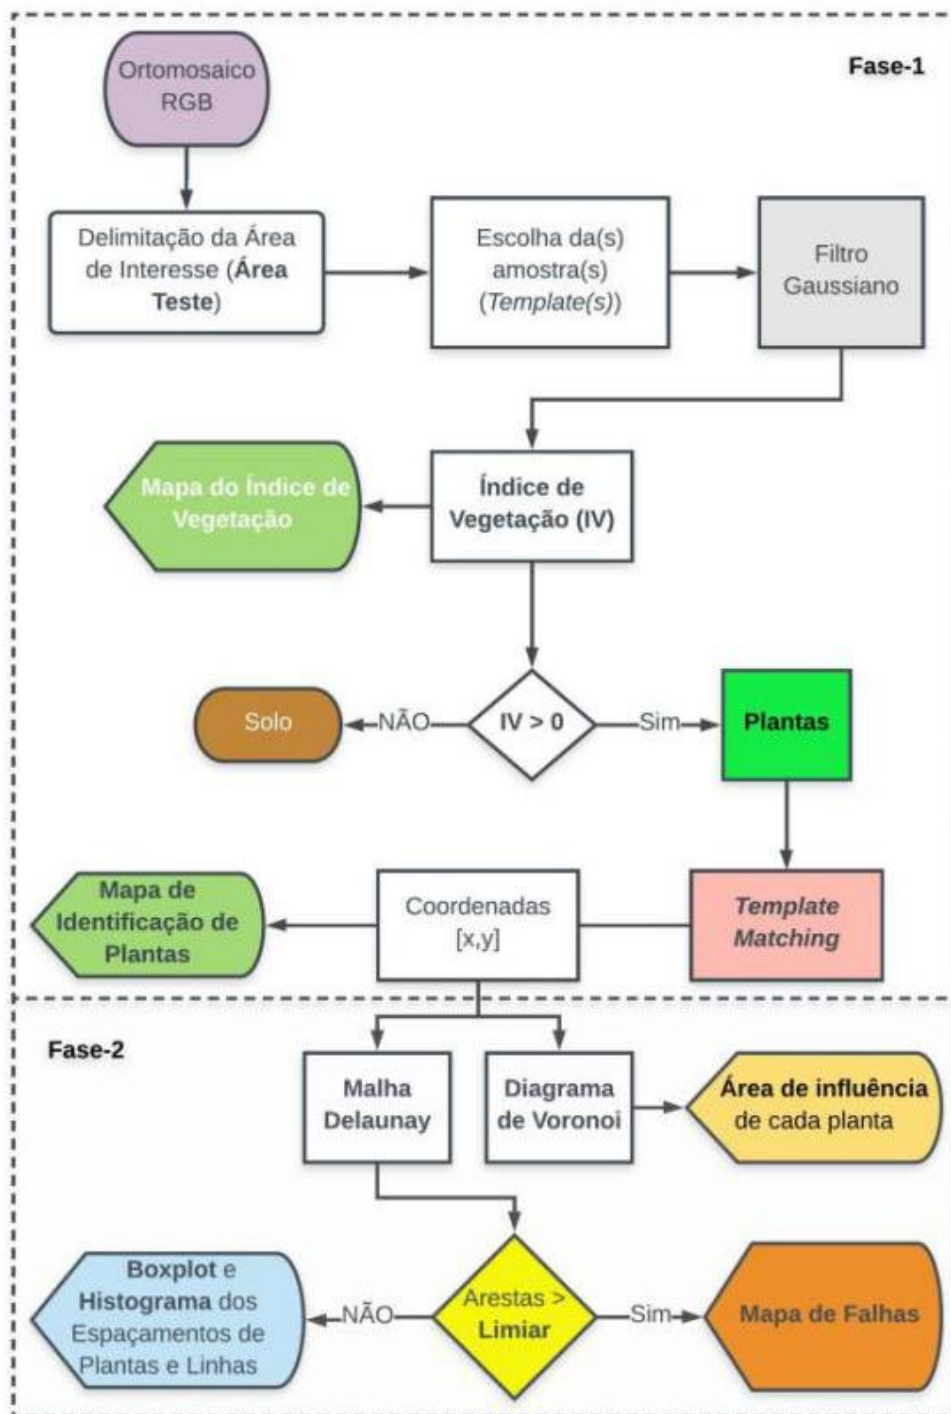
Após a execução do voo, as imagens foram importadas para o *software* Agisoft Metashape[®], sendo geoprocessadas (parâmetros *default*) e, conseqüentemente, gerado o ortomosaico. O recorte da área teste e a fotointerpretação foram realizados no *software* QGIS 3.14.

Implementação da rotina automatizada

A rotina foi implementada usando o ambiente de desenvolvimento *Spyder*, em linguagem *Python* 3.6, com a utilização das bibliotecas *OpenCV*, *Numpy*, *Pandas*, *Math*, *Matplotlib* e *Scipy*. A estrutura do algoritmo foi dividida em duas fases principais. A primeira fase consistiu em abrir a imagem da área de teste e segmentar, por meio do índice de vegetação (IV), o solo e a vegetação, bem como identificar o centro dos dosséis das plantas para a contagem dos indivíduos. Já a segunda fase consistiu em construir uma malha triangular usando os vértices obtidos como centros dos dosséis de cada uma das plantas identificadas, bem como o correspondente diagrama de ocupação. A partir da malha e do diagrama, foram gerados os seguintes Mapas-Relatórios (MR): a) área de influência de cada planta; b) identificação de falhas, linhas e entrelinhas de plantio; c) boxplot dos

espaçamentos entre plantas e linhas; d) distribuição dos espaçamentos entre plantas e entrelinhas. Todos os MR foram acompanhados por uma estatística descritiva e área euclidiana (ha) do polígono selecionado. Em síntese, o *workflow* da implementação da rotina para o controle de qualidade de plantios de eucalipto proposta pode ser observado no diagrama da Figura 2.

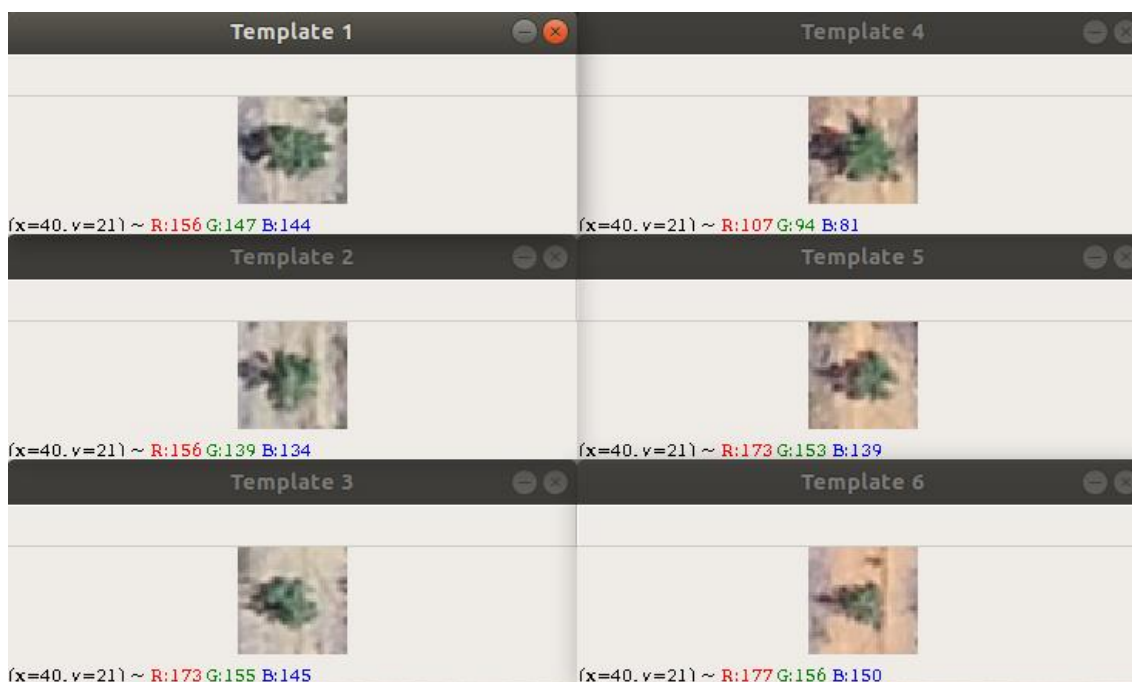
Figura 2- Diagrama da implementação da rotina automatizada para o controle de qualidade de plantios de eucalipto.



Em relação à primeira fase da rotina, uma vez importada a imagem (área teste), definiu-se, após a fotointerpretação, a quantidade de classes, ou padrões de contraste, de acordo com as variações de características predominantes da cobertura do solo. Em seguida, definiu-se a quantidade de amostras (*template*) por classe. Neste estudo, realizaram-se testes com duas classes: 1) planta em solo com cobertura (SC), predominante na área de estudo; 2) planta em solo exposto (SE). Ambas foram combinadas com até três amostras. Procurou-se diversificar as características físicas como cor, textura, tamanho do dossel e sombreamento de cada amostra, visando representar a variabilidade.

Foram realizados seis testes, com as seguintes combinações: 1) uma amostra em SC; 2) duas amostras em SC; 3) três amostras em SC; 4) três amostras em SC + uma amostra em SE; 5) três amostras em SC + duas amostras em SE; 6) três amostras em SC + três amostras em SE (Figura 3). A captura e exibição automática de cada *template* foi possível por meio de função de controle de evento do *mouse*, bastando o usuário, apenas, posicionar o cursor do *mouse* na planta desejada e, com *double click* seguido de *enter*, seleciona-se e exibe-se o *template*.

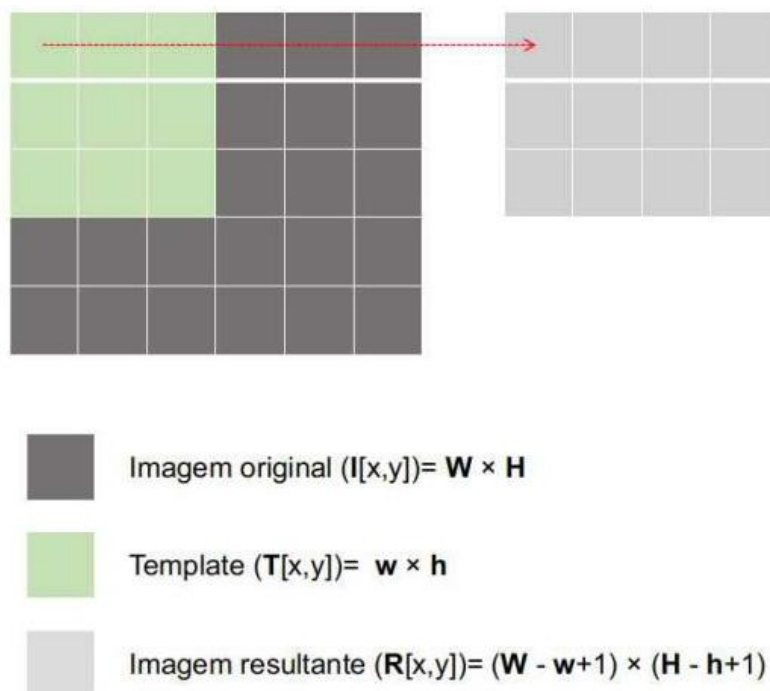
Figura 3- Exemplo de amostras (*templates*) selecionadas, com variação de solo.



Na sequência foi realizada a separação (*split*) das bandas RGB, da área teste e do(s) *template(s)*. Tal procedimento se faz necessário para aplicação do filtro gaussiano para remoção dos ruídos da imagem e, conseqüentemente, estimativa do IV. Para segmentar a região de solo e planta, foi definido, um limiar com valor 0 na escala de resposta do IV, com valores inferiores sendo considerados como solo, caso contrário, plantas (eucalipto). Esse resultado foi considerado como *input* da próxima etapa da primeira fase, o *template matching*. Ressalta-se que, o IV foi estimado por meio da métrica VARIgreen, proposta por Gitelson *et al.* (2002), a qual utiliza apenas os canais do espectro visível (RGB).

O *template matching* foi aplicado por meio da biblioteca *OpenCV*. A referida técnica é muito utilizada, na Visão Computacional, para localizar regiões de uma imagem que correspondem (são semelhantes) a uma imagem modelo (*template*) (BRADSKI, 2000). Uma máscara [*template* (T)] percorre sobre uma imagem (I) comparando cada posição [x,y] pelo processo de convolução. O resultado da comparação é armazenado em numa matriz R[x,y] (Figura 4).

Figura 4- Processo de convolução - *Template Matching*.



Neste estudo, (I) e (T) correspondem, respectivamente, IV oriundo da área teste e a(s) amostra(s). Ressalta-se que, cada uma das seis amostras (*templates*) foi processada, separadamente

no *template matching* e, em seguida, quando combinada, o valor final de (R) foi obtido por meio da média aritmética.

A técnica do *template matching*, implementada na biblioteca *OpenCV*, oferece diversas métricas para se calcular a resposta e, neste trabalho, adotou-se como métrica o "*TM-CCOEFF-NORMED*", dada pela expressão matemática da Equação 1.

$$R_{(x,y)} = \frac{\sum_{x',y'} (T'(x',y') \times I'(x+x',y+y'))}{\sqrt{\sum_{x',y'} T'(x',y')^2 \times \sum_{x',y'} I'(x+x',y+y')^2}} \quad (1)$$

Nessa métrica, para I com tamanho (W×H), tem-se: $x_0 = 0 \dots w$, e, $y_0 = 0 \dots (h-1)$. Para cada posição de T[x,y] sobre I[x,y], armazena-se um resultado da métrica na matriz de resultado R[x,y]. O resultado desse procedimento será uma matriz com valores em [x,y], que variam de -1 a +1, ou seja, baixa a alta correlação, respectivamente. Após testes iniciais, conglomerados de pixels que apresentaram valores acima de 0,3 foram marcados como dosséis das plantas e os máximos valores foram considerados como centro de cada dossel. O primeiro estágio encerrou-se com a localização [x,y] de cada pixel, centro de dossel, e geração (*output*) do Mapa de Identificação de Plantas de Eucalipto.

A segunda fase iniciou-se a partir das coordenadas [x,y] de cada pixel da fase anterior, ou seja, conjunto de vértices com a localização de cada planta. Com o conjunto dos referidos vértices, construiu-se uma malha triangular Delaunay e o Diagrama de Voronoi, obtendo-se, respectivamente: malha de arestas dos triângulos (a qual permitiu estimar os espaçamentos entre plantas e entrelinhas) e área de influência (diagrama) de cada planta. Para identificar as falhas de plantio, identificaram-se as arestas fora da normalidade dos espaçamentos entre plantas. Por fim, foram obtidos os seguintes MR: a) Área de influência de cada planta; b) Identificação de falhas, linhas e entrelinhas de plantio; c) Estatísticas descritivas.

O tempo de processamento computacional foi de 96 segundos com 25% da RAM utilizando uma máquina com sistema operacional Linux (Ubuntu 18.04), CPU Intel® Core (TM) i7-4500U (4

núcleos, 1.80GHz, L2 cache de 4096 KB), RAM 16 GB, armazenamento SSD e GPU (GeForce GT 740M).

Análise dos dados

O desempenho da rotina implementada foi avaliado por meio da comparação da quantidade de plantas identificadas e contadas manualmente (fotointerpretação da área teste). Em seguida, três métricas (Equação 2, 3 e 4) de medidas de desempenho foram aplicadas, apresentada por Fan *et al.* (2018).

$$S_b = \frac{VP}{VP + FN} \quad (2)$$

$$S_p = \frac{VN}{VN + FP} \quad (3)$$

$$A_c = \frac{VP + VN}{VP + VN + FP + FN} \quad (4)$$

As medidas de desempenho usam as contagens de: (VP) verdadeiro positivo, ou o número de plantas de eucalipto corretamente identificadas; (VN) verdadeiro negativo, ou o número de falhas de plantio corretamente identificadas; (FP) falso positivo, ou o número de pontos identificados incorretamente como eucalipto, mas sendo plantas daninhas e/ou sombra; e (FN) falso negativo, ou o número de plantas de eucalipto não identificadas.

A medida sensibilidade (S_b) reflete a capacidade do algoritmo para detectar plantas de eucalipto, enquanto a especificidade (S_p) é uma medida da eficácia do algoritmo na identificação de "plantas não-eucalipto". Já a acurácia geral (A_c) é uma medida global do desempenho do método proposto.

A fim de aumentar o rigor da avaliação do algoritmo, mais duas métricas de avaliação foram empregadas neste estudo. A primeira, *producer's accuracy* (P_{acc}), é recomendada por Lavrač, Flach e Zupan (1999) e Moranduzzo e Melgani (2013), a qual representa a percentagem de plantas de eucalipto identificadas corretamente, Equação 5.

$$P_{acc} = \frac{VP}{N} \times 100 \quad (5)$$

Na medida *Pacc*, (N) indica o número real de plantas de eucalipto na área teste. A segunda medida, recomendada por Armstrong e Collopy (1992) e Stine *et al.* (2004), é o erro relativo (Er), pelo qual, também, determinou-se o desempenho do método proposto. Na referida medida, usa-se $N_p = VP + FP$, que é o número de plantas de eucalipto detectadas pela rotina automatizada, Equação 6.

$$Er = \frac{|N_p - N|}{N} \times 100 \quad (6)$$

3. RESULTADOS E DISCUSSÃO

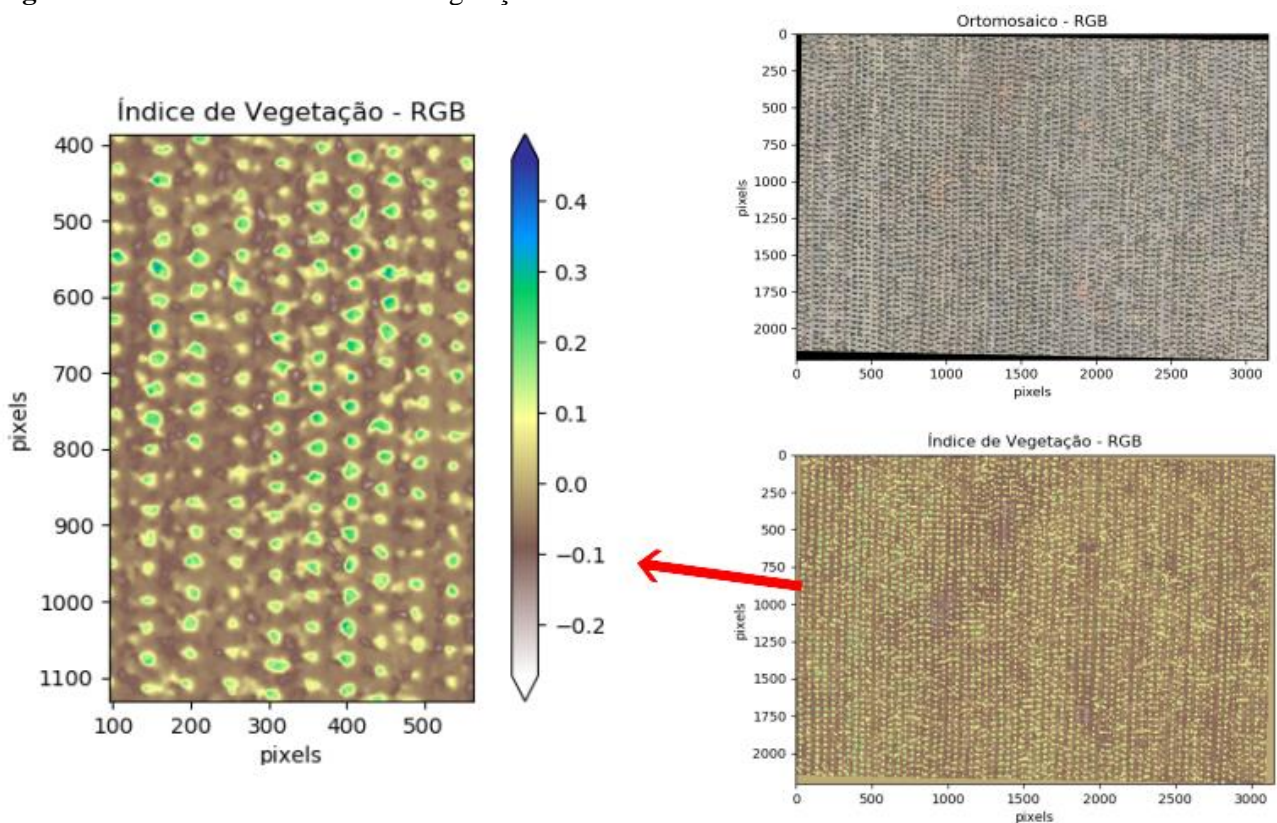
O estudo apresentou uma característica muito relevante, que é a aplicabilidade, considerando que a rotina foi desenvolvida e testada em condições práticas (plantio comercial) da cultura avaliada. Em termos de obtenção de dados aerofotogramétricos, o ortomosaico RGB, com GSD de 7 cm, permitiu discriminar os objetos em análises, planta e solo. Em imagens de alta resolução espacial, os padrões de plantio e solo tornam-se distinguíveis, proporcionando grande potencialidade de discriminação e caracterização (DELENNE *et al.*, 2010).

Com as características de voo adotadas, foi possível sobrevoar 39,5 ha em aproximadamente nove minutos. Para o modelo de VANT utilizado, representa rendimento operacional mínimo de 80 ha bateria⁻¹. O tempo do levantamento de tais informações, também, é de fundamental relevância para inventário florestal de sobrevivência, pois recomenda-se, quando necessário, realizar o replantio de 15 a 30 dias após o plantio. À medida que se estende tal intervalo, menor será o volume individual de cada árvore reposta e, conseqüentemente, menor será a contribuição para formação do volume total final do povoamento florestal (OLIVEIRA *et al.*, 2014). Para hortos florestais extensos, tal informação é de grande relevância.

Em relação à rotina desenvolvida, é importante ressaltar que o usuário possui apenas um momento de interferência manual, que é a escolha da(s) amostra(s) (*template*) que será(ão) utilizada(s) como entrada no *template matching*. Nessa etapa, o usuário deve levar em consideração, quando necessário, a diversidade das características (cor, textura, forma e tamanho) do *template*, pois *templates* diferentes poderão contribuir no resultado final do *matching*. Dentre as combinações

propostas e testadas, de maneira geral, não houve diferença significativa nas métricas de desempenho, especificamente para combinações de duas classes. Isso confirma que o valor do limiar zero, definido para segmentar planta e solo, por meio do Índice de Vegetação (IV), foi eficiente (Figura 5). O cálculo do IV, seguido de um processo de remoção de ruídos (aplicação de filtro Gaussiano), possibilitou segmentar as plantas e o solo, aumentar o ganho no processo de correlação do *template matching* e, conseqüentemente, contribuiu para identificar maiores quantidades de plantas de eucalipto corretamente identificadas (VP) e o número de falhas de plantio corretamente identificadas (VN), bem como a reduzir o número de pontos identificados incorretamente como eucalipto (FP) e o número de plantas de eucalipto não identificadas (FN).

Figura 5- Ortomosaico e Índice de Vegetação - RGB.




O IV calculado (oriundo de canais RGB) dispensa a utilização do canal infravermelho. Na prática, isso representa economia para o usuário, pois dispensa a utilização de um segundo sensor (RGB modificado, multiespectral ou até mesmo hiperespectral). Embora o sensor RGB não tenha a capacidade de decifrar as características espectrais estreitas, pois tem apenas três bandas espectrais

de largura, este permite bons resultados na obtenção de referências de características de crescimento das plantas (forma, cor e tamanho do dossel) e identificação de plantas daninhas (BALLESTEROS *et al.*, 2014; BURKART *et al.*, 2018).

A imagem (R), resultado da correlação da área teste (I), neste caso o Mapa do IV-RGB, com o(s) *template(s)* (T), foi submetida ao processo de identificação dos valores máximos de cada agrupamento de pixels (dossel), permanecendo o de maior valor (centro do dossel), Figura 6.

Figura 6- Imagem (R) resultante da correlação da área teste (I) e *template* (T).

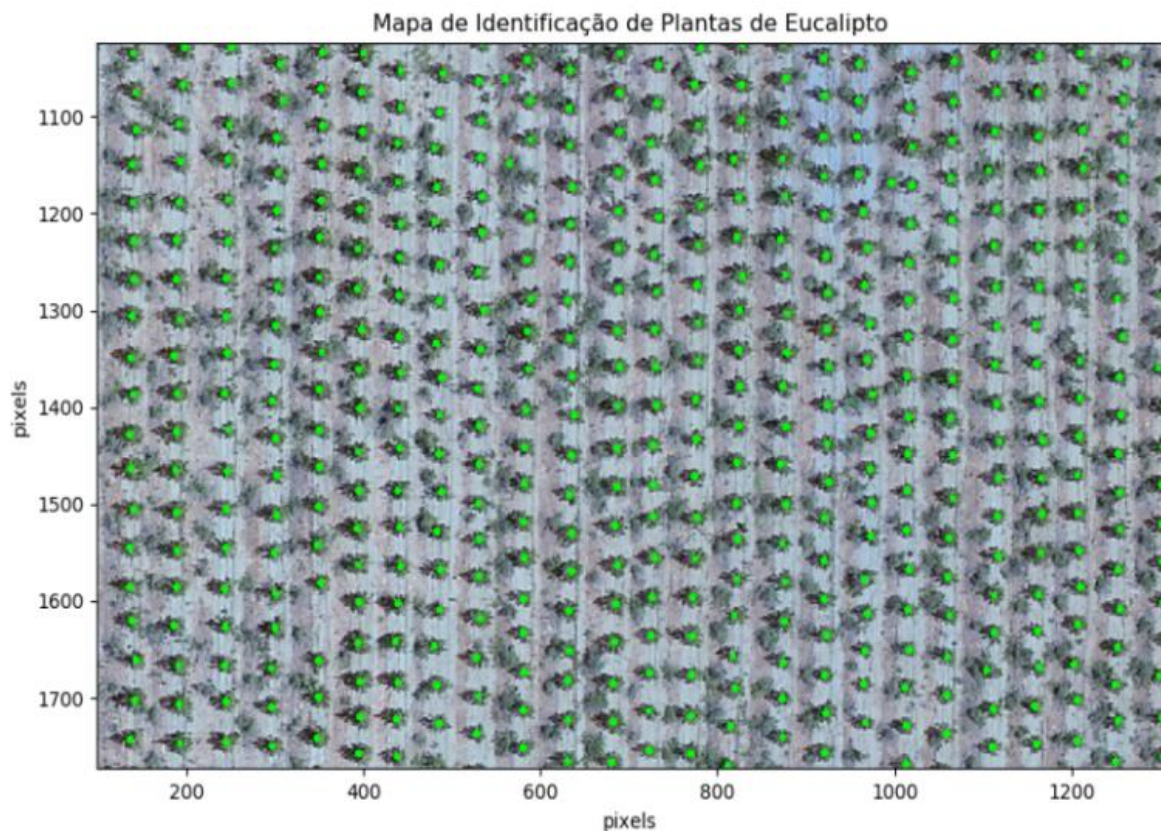


Cada agrupamento (que representa o dossel de cada planta) é constituído de um valor mínimo da magnitude da correlação da amostra (*template*) e a imagem original (ortomosaico), sendo conhecido como limiar de corte. A definição do referido limiar representa a magnitude mínima aceitável, definida pelo usuário, para correlacionar (I) e (T). Conforme apresentado por Koh *et al.* (2019), baixos valores de limiar de corte podem resultar em superestimativas na identificação e contagem das plantas. Já altos valores, poderão resultar em subestimativas.

O processo de definição do valor ideal do limiar de corte é iterativo e, muitas das vezes, exaustivo. Faz parte do processo da calibração da rotina computacional definir o valor que permita obter a maior quantidade de correspondência do *template*, ou seja, maior acurácia global do algoritmo. Koh *et al.* (2019) utilizaram-se do *template matching* para identificar e contar açafão (*Carthamus tinctorius*) nos estágios iniciais de desenvolvimento, por meio de imagens obtidas com VANT. Para tanto, definiu-se 0,5 para o valor do limiar de corte. No presente trabalho utilizou-se limiar de 0,3. No entanto, é válido ressaltar que, além do valor do limiar de corte está diretamente relacionado com o desempenho final do algoritmo, o referido valor pode variar para diferentes culturas, época do ano, estágio fenológico e, até mesmo, horário de voo. Sendo assim, compete ao usuário, ajustar o referido parâmetro para as condições intrínsecas da área e cultura de interesse.

Uma vez definido o limiar de corte, identificou-se a posição [x,y] de cada pixel com maior valor, de um agrupamento de pixels com valores acima de 0,3. Em seguida, obteve-se o Mapa de Identificação de Plantas de Eucalipto (Figura 7).


Figura 7- Mapa de Identificação de Plantas de Eucalipto.



Em termos de acurácia global para Identificação e Contagem de Plantas, a rotina desenvolvida apresentou valor médio de 0,9353, com Pacc de 0,9489. Já o erro relativo (médio) foi de 0,11%. Utilizando redes neurais artificiais profundas para avaliar o desempenho da detecção de plantas de tabaco, por meio de imagens (GSD de 3,5 cm e 12 MP) oriundas de sensor RGB, acoplado em VANT do tipo multirrotor, e rotinas automatizadas, Fan *et al.* (2018) apresentaram um algoritmo com acurácia global de 0,9370 e erro relativo de 3,94%, para um plantio adensado com linhas de plantio em diferentes ângulos de orientação geográfica.

A rotina apresentou alta capacidade para detectar plantas de eucalipto, com Sb (médio) de 0,9856. No entanto, a eficácia para identificação de "plantas não-eucalipto", ou seja, o valor (médio) de Sp, ficou comprometido, em função da quantidade FP apresentada. Os valores elevados dos FP são devido às ocorrências de plantas daninhas ou até mesmo sombras das plantas de eucalipto que apresentaram comportamento espectral semelhantes ao da referida cultura (Figura 8).

Figura 8-Identificação de verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN) em plantas de eucalipto.



Percebeu-se que, quando utilizada apenas uma única amostra, houve subestimativa na quantidade total de plantas, diferentemente das demais combinações. Contudo, apresentou-se acurácia global de maior valor. Abstraindo-se às métricas Pacc e Er, quando utilizada a segunda combinação (dois *templates* em SC), chegou-se na melhor estimativa de VP. No entanto, os valores de FN aumentaram (Tabela 1). Já as estimativas dos VN mantiveram-se constantes para todas as combinações.

Tabela 1- Desempenho da rotina proposta para o controle de qualidade de plantio florestais por meio de aéreas obtidas com VANT. Combinações das amostras (Cb), número real de plantas de eucalipto no ortomosaico RGB (N), número de plantas detectadas pela rotina automatizada (Np), verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP), falso negativo (FN), sensibilidade (Sb), especificidade (Sp), acurácia global (Ac), *producer's accuracy* (Pacc) e erro relativo (Er).

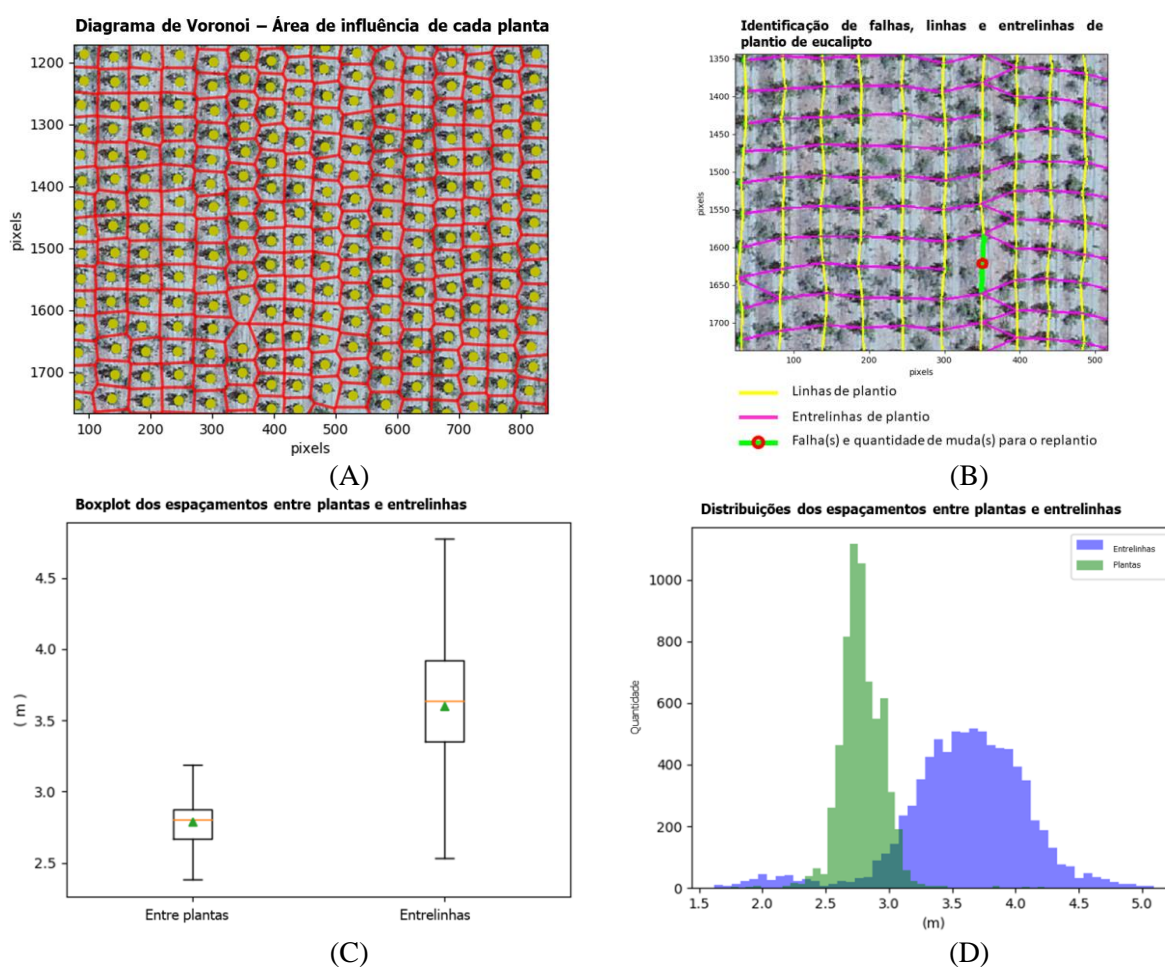
Cb	N	Np	VP	VN	FP	FN	Sb	Sp	Ac	Pacc	Er (%)
1	3327	3316	3155	14	161	48	0,9850	0,080	0,9381	0,9483	-0,33
2	3327	3332	3167	14	165	51	0,9842	0,078	0,9364	0,9519	0,15
3	3327	3336	3160	14	176	41	0,9872	0,074	0,9360	0,9498	0,27
4	3327	3337	3155	14	182	41	0,9872	0,071	0,9343	0,9483	0,30
5	3327	3331	3153	14	178	48	0,9850	0,073	0,9334	0,9477	0,12
6	3327	3332	3153	14	179	47	0,9853	0,073	0,9334	0,9477	0,15

A segunda fase do algoritmo consistiu em gerar a malha triangular Delaunay, a qual permitiu estimar os espaçamentos entre plantas e entrelinhas. Já o diagrama de Voronoi, permitiu identificar e estimar a área de influência de cada planta (Figura 9A). Utilizando-se a primeira combinação, uma amostra em solo composto (SC), com 3316 plantas detectadas (NP), estimou-se uma área de ocupação média de $9,46 \text{ m}^2 \text{ planta}^{-1}$ e coeficiente de variação de 12,88%, ou seja, ocupação média de 5,11% acima do planejado. Embora o projeto de plantio fosse planejado em 3 m x 3 m (estande final teórico de 3454 plantas), o levantamento de campo, seguido pelas análises, apresentou uma subutilização da gleba, ou seja, espaçamento médio entre plantas e entrelinhas de, respectivamente, 2,79 m e 3,6 m.

As informações geradas pela rotina automatizada são úteis para o monitoramento do plantio de áreas como eucalipto e passíveis de adaptação para outras espécies florestais e não florestais. Percebe-se, pelos MR, as variações que ocorrem no espaçamento entre plantas (CV de 6,73%) e, principalmente, entrelinhas (CV de 13,73%). Já a quantidade de plantas estimada para o replantio foi 23, ou seja, o índice de sobrevivência de 99,31%.

As informações contidas na estatística descritiva (Figura 9 C e D) também permitiram definir o limiar de corte (estabelecendo um intervalo de confiança baseado na média e desvio-padrão), para identificar as arestas que apresentam as falhas de plantio. Uma vez definido o limiar, o desenho das linhas de plantio, entrelinhas e até mesmo das falhas, foi realizado por meio do controle da orientação geográfica de cada aresta, pertencente à malha triangular Delaunay.

Figura 9- Mapas-Relatórios (MR): A) Área de influência de cada planta; B) Identificação de falhas (linha verde), linhas (cor amarela) e entrelinhas (cor magenta) de plantio; C) Boxplot dos espaçamentos entre plantas e entrelinhas; D) Distribuições dos espaçamentos entre plantas e entrelinhas.



Alguns avanços e inovações destacaram-se neste trabalho: (i) apresentou uma rotina automatizada, que fornece parâmetros referentes ao controle de qualidade de plantios de eucalipto, (ii) a rotina exige mínima intervenção do usuário, bastando selecionar alguma(s) amostra(s) da área de interesse, (iii) a rotina foi desenvolvida em plataformas *open source* e linguagem *Python* (licença

livre), (iv) a rotina apresenta excelente desempenho em ortomosaico oriundo de canais RGB, de baixo custo.

4. CONCLUSÕES

1. A metodologia proposta pode ser aplicada em imagens aéreas, obtidas por meio de sensores aerotransportados em plataforma VANT, para o controle de qualidade de plantios em início de formação na cultura do eucalipto, com flexibilidade de adaptação para outras espécies;
2. A rotina apresenta acurácia elevada, com 0,9353 e erro relativo médio de 0,11%, na identificação e contagem de plantas de eucalipto em ortomosaico oriundo de sensor de baixo custo (RGB), além de um excelente desempenho computacional.

5. AGRADECIMENTOS

Os autores agradecem à Plantar Siderúrgica S/A, pela disponibilização das imagens aéreas, ao Programa de Pós-Graduação em Produção Vegetal no Semiárido (PPGPVS) e ao Programa de Pós-Graduação em Modelagem Computacional e Sistemas (PPGMcS), bem como à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsas. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

ARMSTRONG, J. S.; COLLOPY, F. Error measures for generalizing about forecasting methods: Empirical comparisons. **International Journal of Forecasting**, v. 8, n. 1, p. 69-80, 1992.

ARTUR, A. G.; OLIVEIRA, D. P.; COSTA, M. C. G.; ROMERO, R. E.; SILVA, M. V. C.; FERREIRA, T. O. Variabilidade espacial dos atributos químicos do solo, associada ao microrrelevo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 2, p. 141-149, 2014.

BALLESTEROS, R.; ORTEGA, J. F.; HERNÁNDEZ, D.; MORENO, M. A. Applications of georeferenced high-resolution images obtained with unmanned aerial vehicles. Part I: Description of image acquisition and processing. **Precision Agriculture**, v. 15, n. 6, p. 579-592, 2014.

- BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa Informação Tecnológica, 2014.
- BORGOGNO-MONDINO, E. C.; LESSIO, A.; TARRICONE, L.; NOVELLO, V.; PALMA, L. A comparison between multispectral aerial and satellite imagery in precision viticulture. **Precision Agriculture**, v. 19, n. 2, p. 195-217, 2018.
- BRADSKI, G. The opencv library. **Dr Dobb's J. Software Tools**, v. 25, p. 120-125, 2000.
- BURKART, A.; HECHT, V. L.; KRASHA, T. RASCHER, U. Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution. **Precision Agriculture**, v. 19, n. 1, p. 134-146, 2018.
- DELENNE, C.; DURRIEU, S.; RABATEL, G.; DESHAYES, M. From pixel to vine parcel: A complete methodology for vineyard delineation and characterization using remote-sensing data. **Computers and Electronics in Agriculture**, v. 70, n. 1, p. 78-83, 2010.
- DUARTE, L.; SILVA, P.; TEODORO, A. Development of a QGIS Plugin to Obtain Parameters and Elements of Plantation Trees and Vineyards with Aerial Photographs. **ISPRS International Journal of Geo-Information**, v. 7, n. 3, p. 109, 2018.
- FAN, Z.; LU, J.; GONG, M.; XIE, H.; GOODMAN, E. D. Automatic tobacco plant detection in UAV images via deep neural networks. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 3, p. 876-887, 2018.
- GITELSON, A. A.; KAUFMAN, Y. F.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76-87, 2002.
- GUERRA, J.; GONZÁLEZ-FERREIRO, E.; MONLEÓN, V. J.; FAIAS, S. P.; TOMÉ, M.; VARELA, R. D. Use of multi-temporal UAV-derived imagery for estimating individual tree growth in *Pinus pinea* stands. **Forests**, v. 8, n. 8, p. 300, 2017.
- KOH, J. C. O.; HAYDEN, M.; DAETWYLER, H.; KANT, S. Estimation of crop plant density at early mixed growth stages using UAV imagery. **Plant Methods**, v. 15, n. 1, p. 64, 2019.
- LAVRAC, N.; FLACH, P.; ZUPAN, B. Rule evaluation measures: A unifying view. **Lecture Notes in Computer Science**, v. 1634, p. 174-185, 1999.
- MANCONI, A.; ZIEGLER, M.; BLOCHLIGER, T.; WOLTER, A. Technical note: optimization of unmanned aerial vehicles flight planning in steep terrains. **International Journal of Remote Sensing**, v. 40, n. 7, p. 2483-2492, 2019.
- MORANDUZZO, T.; MELGANI, F. Automatic car counting method for unmanned aerial vehicle images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 3, p. 1635-1647, 2013.
- OLIVEIRA, L. T.; CARVALHO, L. M. T.; FERREIRA, M. Z.; OLIVEIRA, T. C. A.; BATISTA, V. T. F. P. Influência da idade na contagem de árvores de *Eucalyptus* sp. com dados de lidar. **Cerne**, v. 20, n. 4, p. 557-565, 2014.

- ÖZCAN, A. H.; HISAR, D.; SAYAR, Y.; UNSALAN, C. Tree crown detection and delineation in satellite images using probabilistic voting. **Remote Sensing Letters**, v. 8, n. 8, p. 761-770, 2017.
- PARK, S.; RYU, D.; FUENTES, S.; CHUNG, H.; HERNÁNDEZ-MONTES, E.; O'CONNELL, M. Adaptive estimation of crop water stress in nectarine and peach orchards using high-resolution imagery from an unmanned aerial vehicle (UAV). **Remote Sensing**, v. 9, n. 8, p. 828, 2017.
- POBLETE-ECHEVERRÍA, C.; OLMEDO, G. F.; INGRAM, B.; BARDEEN, M. Detection and segmentation of vine canopy in ultra-high spatial resolution RGB imagery obtained from unmanned aerial vehicle (UAV): A case study in a commercial vineyard. **Remote Sensing**, v. 9, n. 3, p. 268, 2017.
- RUZA, M. S.; CORTE, A. P. D.; HENTZ, A. M. K.; SANQUETTA, C. R.; SILVA, C. R.; SCHOENINGER, E. R. Inventário de Sobrevivência de povoamento de Eucalyptus com uso de Redes Neurais Artificiais em Fotografias obtidas por VANTs. **Advances in Forestry Science**, v. 4, n. 1, p. 83-88, 2017.
- SHI, Y.; THOMASSON, J. A.; MURRAY, S. C.; PUGH, N. A.; ROONEY, W. L.; SHAFIAN, S.; RAJAN, N.; ROUZE, G.; MORGAN, C. L. S.; NEELY, H. L.; RANA, A.; BAGAVATHIANNAN, M. V.; HENRICKSON, J.; BOWDEN, E.; VALASEK, J.; OLSENHOLLER, J.; BISHOP, M. P.; SHERIDAN, R.; PUTMAN, E. B.; POPESCU, S.; BURKS, T.; COPE, D.; IBRAHIM, A.; McCUTCHEN, B. F.; BALTENSBERGER, D. D.; AVANT JR, R. V.; VIDRINE, M.; YANG, C. Unmanned aerial vehicles for high-throughput phenotyping and agronomic research. **PLoS one**, v. 11, n. 7, p. e0159781, 2016.
- SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICENTE, L. E.; VICTORIA, D. C.; DUCATI, J. R.; OLIVEIRA, R. P.; VILELA, M. F. Sensoriamento Remoto: conceitos básicos e aplicações na agricultura de precisão. In: BERNARDI, A. C. C. *et al.* **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014, cap. 4, p. 58-73.
- STINE, B. E.; HESS, C.; WEILAND, L. H.; CIPLIKA, D. J.; KIBARIAN, J. System and method for product yield prediction using a logic characterization vehicle. Depositante: Brian E. Stine et al. **U.S. Patent** 6834375B1. 21 dez. 2004.
- WANG, S.; BAUM, A.; ZARCO-TEJADA, P. J.; DAM-HANSEN, C.; THORSETH, A.; BAUER-GOTTWEIN, P.; BANDINI, F.; GARCIA, M. Unmanned Aerial System multispectral mapping for low and variable solar irradiance conditions: Potential of tensor decomposition. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 155, p. 58-71, 2019.
- YAO, H.; QIN, R.; CHEN, X. Unmanned aerial vehicle for remote sensing applications-A review. **Remote Sensing**, v. 11, n. 12, p. 1443, 2019.

CAPÍTULO 2

POMAR CÍTRICO EM FORMAÇÃO AVALIADO MEDIANTE IMAGENS AÉREAS OBTIDAS COM VANT E TÉCNICAS DE VISÃO COMPUTACIONAL

(Artigo formatado de acordo com as normas de Revista Acta Scientiarum. Agronomy)

Citrus orchard in formation evaluated by aerial images obtained with uav and computational vision techniques

ABSTRACT – Studies that analyze biometric attributes of young citrus orchards, using only RGB sensors embedded in unmanned aerial vehicles (UAVs) are rare and great are the challenges. In this sense, the objective was to develop and validate a method of using aerial images obtained with UAV, through of automated routines, to evaluate the biometric attributes of the planting of 'Tahiti' acid lime in phase of formation. For this purpose, an UAV, multirotor (DJI Phantom 4 Adv), programmed to capture images with 80% frontal and lateral overlap, at three scales mapping. Geoprocessing was performed with and without ground control points (GCP), for each scales mapping. Finally, an automated routine was developed, in an open source environment, consisting of three processing phases: i) Estimation of the Biometric Attributes of the Plant; ii) Statistical Analysis and iii) Statistical Map Report (SMR). Through the developed routine, it was possible to delimit and estimate the projected canopy area, with accuracy above 95%. The identification and counting of the plants presented accuracy greater than 97%. The use of GCP in the processing stage does not increase the accuracy in the process of estimating the obtained biometric attributes. The mapping scale, on the other hand, is strongly correlated with the quality of the estimated resources obtained, especially the plant height. The results are sufficient to define a method of acquisition and analysis of aerophotogrammetric survey, from UAV, that can be used to measure biometric attributes of the analyzed plants, in addition to the flexibility of adaptation for perennial crops.

Keywords: Citrus. Remote Sensing. Precision Agriculture. Image Segmentation. Python.

RESUMO - Trabalhos com atributos biométricos de pomares cítricos em formação utilizando apenas sensor RGB embarcado em veículos aéreos não tripulados (VANTs) são raros e grandes são os desafios. Neste sentido, objetivou-se desenvolver e validar um método de utilização de imagens aéreas obtidas com VANT, por meio de rotinas automatizadas, para avaliar os atributos biométricos do plantio de lima ácida 'Tahiti' em fase de formação. Para tanto, utilizou-se um VANT, multirotor

(DJI Phantom 4 Adv), programado para capturar imagens com 80% de sobreposição frontal e lateral, em três escalas de mapeamento. Foram realizados geoprocessamentos com e sem pontos de controle, para cada escala de mapeamento. Por fim, desenvolveu-se uma rotina automatizada em ambiente *open source*, constituída por três fases de processamento: i) Estimativa dos atributos biométricos de planta; ii) Análise estatística e iii) Relatório estatístico de mapas (REM). Por meio da rotina desenvolvida foi possível delimitar e estimar a área da copa projetada, com acurácia acima de 95%. Já a identificação e contagem das plantas apresentaram acurácia superior a 97%. A utilização dos pontos de controle, na etapa de processamento, não aumenta a acurácia no processo de estimativa dos atributos biométricos avaliados. Já a escala do mapeamento está fortemente correlacionada com a qualidade da estimativa dos atributos avaliados, em especial a altura da planta. Os resultados são suficientes para definir um método de aquisição e análises de dados aerofotogramétricos, por meio de VANT, que pode ser utilizado para mensurar atributos biométricos das plantas analisadas, além da flexibilidade de adaptação para culturas perenes.

Palavras-chave: Citros. Sensoriamento Remoto. Agricultura de Precisão. Segmentação de Imagem. Python.

1. INTRODUÇÃO

A citricultura é uma atividade agrícola de grande importância mundial (Donkersley, Silva, Carvalho, Al-Sadi & Elliot, 2019), com destaque entre as commodities do agronegócio brasileiro (Carvalho, Girardi, Mourão Filho, Ferrarezi & Coletta Filho, 2019). Dos diversos frutos cítricos, a lima ácida ‘Tahiti’ (*Citrus latifolia* Tanaka) ou limão-tahiti tem uma produção considerável no Estado de Minas Gerais, principalmente, no Projeto Jaíba, que concentra mais de 50% da produção do Estado (Castricini, Silva, Silva & Rodrigues 2017).

No Brasil, a expansão da referida atividade, quando aliada à sustentabilidade e alta produtividade, está associada à adoção de novas tecnologias de gerenciamento da lavoura (Carrer, Souza Filho & Batalha, 2017). De acordo com Shi et al. (2016), para continuarmos avançando no

aumento da produtividade e com preservação dos recursos naturais, duas tecnologias são relevantes: fenotipagem de alto rendimento e agricultura de precisão (AP). Esta última, se destaca por adotar os princípios da variabilidade espacial e temporal do solo e da planta (Ivushkin et al., 2019), permitindo otimizar os insumos, aumentar a produtividade e, conseqüentemente, o lucro (Dong, Zhang, Yu, Tian & Zhu, 2020). Neste sentido, o sensoriamento remoto é de fundamental importância (Ampatzidis, Partel & Costa, 2020; Fawcett, Kho, Hill, Azlan, Bennie & Anderson, 2019).

O veículo aéreo não tripulado (VANT) tem se tornado umas das principais fontes de dados do sensoriamento remoto, com aplicações encontradas em diversas áreas do conhecimento (Yao, Qin & Chen, 2019), especificamente na AP (Osco et al., 2020). Os VANTs criaram novas oportunidades e soluções (Maes & Steppe, 2019), alcançando novos usuários como pesquisadores, consultores agrícolas e produtores rurais (Shi et al., 2016). Adicionalmente, permitiram automatizar o processo de medição e análise dos atributos biométricos da planta, possibilitando economia de recursos, como tempo e mão-de-obra (Ampatzidis et al., 2020; Ok & Ozdarici-Ok, 2018).

Em citros, utilizam-se VANTs para contar plantas (Csillik, Cherbini, Johnson, Lyons & Kelly, 2018; Ok & Ozdarici-Ok, 2018; Osco et al., 2020), identificar doenças (Garcia-Ruiz et al, 2013), estimar o tamanho dos frutos e a produtividade (Apolo-Apolo, Martinez-Guanter, Egea, Raja & Pérez-Ruiz, 2020). Soluções mais completas podem ser encontradas em Ampatzidis, Partel, Meyering & Albrecht (2019), Ampatzidis *et al.* (2020) e Ampatzidis & Partel (2019), os quais apresentaram metodologias, baseadas em *convolutional neural network* (CNN), de extração de alguns atributos biométricos, alcançando, para alguns casos, acurácia de 99,9%. Recentemente, Osco et al. (2020) obtiveram grandes avanços (utilizando CNN) na contagem de plantas em um pomar comercial adensado de laranja ‘Valência’.

É importante ressaltar que, em trabalhos dessa natureza, aplicando *machine learning* em reconhecimento de objetos e classificação de imagens, utilizam-se métodos que exigem a construção de um massivo banco de dados para treinamento (Ma et al., 2019). Isso pode consumir

muito tempo (Dargan, Kumar, Ayyagari & Kumar, 2019) e recurso computacional (Yang et al., 2019), podendo dificultar, em algumas situações, a flexibilidade para outros tipos de planta (Dong et al., 2020). Outra observação importante é que o desempenho de tais métodos pode ser reduzido em objetos de grande heterogeneidade (em termos de tamanho) e, também, com a perda da resolução espacial da imagem (Kang, Ma & Chan, 2019).

Trabalhos que mensuram os atributos biométricos de pomares cítricos em formação, utilizando apenas sensor RGB embarcado em VANTs, são raros (Shi et al., 2016) e são grandes os desafios para o sensoriamento remoto (Ampatzidis & Partel, 2019) e para visão computacional (Ok & Ozdarici-Ok, 2018). Conforme apontado por Osco et al. (2020), nenhuma técnica de visão computacional é universalmente aplicável, e diferentes tipos de abordagens devem ser testadas para resolver problemas específicos. Apesar dos avanços científicos e comerciais, para Shi et al. (2016) e Yao et al. (2019) permanece a necessidade de estabelecer um fluxo de trabalho para a coleta e processamento de dados oriundos dos VANTs, na óptica das ciências agrárias e, principalmente, com soluções de baixo custo (Ampatzidis et al., 2020).

Neste sentido, padronizar processos e desenvolver soluções (algoritmos) para extrair atributos biométricos da planta é de fundamental importância para fazer uso de grande quantidade de dados oriundos de sensores acoplados em VANT (Aasen, Honkavaara, Lucieer & Zarco-Tejada, 2018; Tu, Phinn, Johansen, Robson & Wu, 2020). Conforme apontado por esses autores, diferentes combinações dos parâmetros de voo podem influenciar a qualidade e aplicação dos produtos finais. Trabalhos de otimização de parâmetros de voo com VANT, para medir a estrutura da planta, podem ser encontrados em Dandois, Olano & Ellis (2015), Fawcett et al. (2019), Torres-Sánchez, López-Granados, Borra-Serrano & Peña (2018) e Zarco-Tejada, Varela, Angileri & Loudjani (2014). Tu et al. (2020) apresentaram um estudo bem completo, com uma série de parâmetros de voo que devem ser adotados para medir a altura do abacateiro, porém apenas para câmera multiespectral. Já Seifert et al. (2019) analisaram alguns parâmetros, com sensor RGB para aplicações florestais.

Embora haja grandes avanços metodológicos na extração de atributos biométricos em citros, trabalhos que contemplam os efeitos das variações de alguns parâmetros aerofotogramétricos na qualidade da extração automática de tais atributos, utilizando sensor de baixo custo (RGB), ainda é desconhecido, principalmente, quando se trata de um pomar em formação, onde pode ocorrer maior variabilidade espacial.

Logo, algumas indagações precisam ser respondidas, quando se pretende estimar alguns atributos biométricos (inventário de sobrevivência, área da copa projetada, altura e volume da planta, falhas de plantio, espaçamento médio entre plantas e entrelinhas) por meio sensor embarado em VANT, tais como: a) há necessidade de utilizar pontos de controle na etapa de processamento de dados aerofotogramétricos?; b) qual é o efeito da escala do mapeamento (ou o tamanho do *ground sample distance*-GSD) na estimativa de tais atributos? c) é possível desenvolver rotinas computacionais automatizadas para análise de ortofotomosaico, de baixo custo e intuitiva para o usuário final?

Portanto, objetivou-se desenvolver e validar um método de utilização de imagens aéreas (obtidas com sensor RGB aerotransportado em VANT), por meio de rotinas automatizadas, para avaliar os atributos biométricos de um plantio de lima ácida ‘Tahiti’ em fase de formação. Também, pretende-se definir um fluxo de trabalho, contendo um conjunto de parâmetros aerofotogramétricos que possam ser utilizados, de forma rápida, fácil e confiável, nas avaliações.

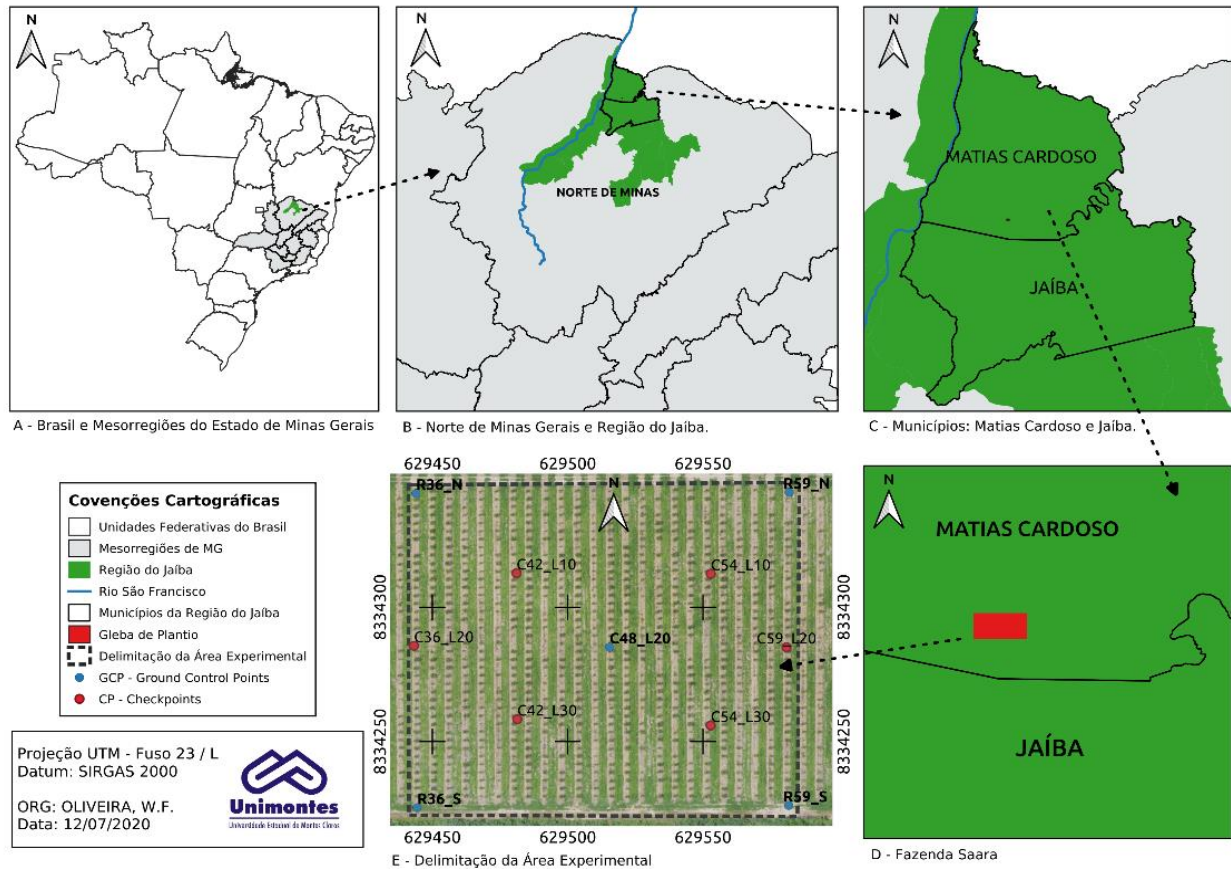
2. MATERIAL E MÉTODOS

2.1. Área de estudo

Selecionou-se um plantio comercial (8,96 ha) de lima ácida ‘Tahiti’ (*Citrus latifolia*, Tanaka., espaçamento: 3 m x 6 m, implantada em 15/01/2019), localizado na Fazenda Saara, Matias Cardoso, MG (Figura 1). Para o desenvolvimento da rotina computacional, recortou-se um retângulo envolvente (área teste: 1,68 ha e declividade média de 2,5%), cujas coordenadas centrais UTM são: E 629.515, N 8.334.285 e h = 459 m, Datum = SIRGAS 2000. Nas entrelinhas de plantio

havia uma camada de vegetação de aproximadamente 20 cm de altura, alternada com solo exposto. A área foi mantida com os devidos tratos culturais e irrigações regulares.

Figura 1- Localização da área experimental (Fazenda Saara, Matias Cardoso, MG).



2.2 Coleta dos atributos biométricos

A área experimental foi composta por 24 linhas de plantio, com 39 plantas linha⁻¹, totalizando 866 plantas e 70 falhas de plantio. As avaliações de campo ocorreram nos dias 14 e 15/05/2020, e foram mensurados os seguintes atributos biométricos da planta (*ground truth*): altura (hp), medindo-se a distância (perpendicular) da folha mais alta até o colo da planta rente ao solo, diâmetro da copa na mesma direção (DI) e perpendicular à linha de plantio (Dr), ambos obtidos por meio de uma trena milimetrada (posicionada na metade da altura da planta avaliada).

Para estimativa do volume, utilizou-se a fórmula apresentada por Rodrigues et al. (2019), Equação 1.

$$V = \frac{2}{3} \cdot \pi \cdot \frac{Dm^2}{4} \cdot hp \quad (1)$$

Em que V é volume (m³) da copa, Dm é o diâmetro médio (m) da copa obtido pela média aritmética de (Dl) e (Dr).

2.3 Coleta e processamento de dados geodésicos e aerofotogramétricos

Primeiramente, realizou-se a implantação de 11 pontos de apoio (marcos/alvos), subdivididos da seguinte forma: cinco pontos de controle ou *ground control points* (GCP) para orientação absoluta do bloco aerofotogramétrico e seis pontos de checagem ou *checkpoints* (CP), para controle da qualidade (acurácia), ambos distribuídos, sistematicamente, dentro da área de interesse (Figura 1-E), seguindo a recomendação de Aasen et al. (2018). Os respectivos pontos foram georreferenciados (posicionamento absoluto estático, com taxa de gravação de cinco segundos e tempo de ocupação mínimo de uma hora) com um Receptor Geodésico (L1/L2, modelo CHC 90D-OPUS) e pós-processados (com órbitas finais IGS) por meio do serviço *online* e gratuito do IBGE-PPP. Ressalta-se que a precisão posicional média (sigma 95%) do georreferenciamento ficou abaixo de 3 cm e 4 cm, para as coordenadas planimétrica e altimétrica, respectivamente.

O planejamento de voo foi realizado por meio do aplicativo DJI Pilot[®], com um VANT do tipo quadricóptero (DJI Phantom 4 *Advanced*), equipado com sensor RGB de 20 megapixels, tamanho 13,2 mm x 8,8 mm, distância focal de 9,1561 mm. Foram planejadas três alturas de voo [60 m (V60), 90 m (V90) e 120 m (V120)], a fim de obter as escalas de referência, ou seja, um *ground sample distance* (GSD) de 1,64 cm pixel⁻¹, 2,47 cm pixel⁻¹ e 3,83 cm pixel⁻¹, respectivamente.

O voo foi realizado considerando um acréscimo horizontal (*buffer*) de 60 m, 120 m e 180 m, no polígono envolvente da área teste, para os respectivos voos V60, V90 e V120. Esse procedimento garantiu uma sobreposição mínima de nove imagens ponto⁻¹, além de minimizar os efeitos de arrastamento e variação do ângulo *pitch* do VANT (Tu et al., 2020). Isso pode reduzir o

false matching e aumentar a qualidade (acurácia) da nuvem de pontos (AGISOT LLC, 2020) e, conseqüentemente, melhorar a qualidade do ortofotomosaico (Shi et al., 2016).

Os voos foram planejados na mesma orientação da linha de plantio, conforme recomendação de Tu et al. (2020). Por fim, realizou-se a calibração da bússola e executaram-se os voos em 19/05/2020, entre 11:00h e 12:00h, visando minimizar o efeito de sombreamento nas imagens, levando em consideração alguns parâmetros de voo e configurações do sensor RGB (Quadro 1), balizado por algumas recomendações de Fawcett et al. (2019), Seifert et al. (2019), Shi et al. (2016) e Wang et al. (2019). Ressalta-se que, durante o voo V120, as condições de iluminação permaneceram instáveis (parcialmente nublado).

Quadro 1. Parâmetros e configurações do planejamento de voo.

Parâmetros de Voo	V60	V90	V120
Altura de voo (Hv)	60 m	90 m	120 m
Ground Sample Distance (GSD)	1,64 cm	2,47 cm	3,83 cm
Sobreposição (Frontal/Lateral)	80% / 80%	80% / 80%	80% / 80%
Velocidade de Voo	4,7 m/s	7,1 m/s	9,5 m/s
Área sobrevoada (com <i>buffer</i>)	3,61 ha	6,49 ha	9,97 ha
Quantidade de imagens*	197	143	134
Quantidade de imagens**	217	165	162
Duração do voo**	9min40sec	7min35sec	7min23sec
Configurações do Sensor RGB***			
ISO	100	100	100
Diafragma	F/2.8	F/2.8	F/2.8
Tempo de Exposição	< 1/640	< 1/640	< 1/640

* Planejamento de Voo. **Executado em campo. *** Ev:-0,3; **Phto**: *single shot*; **White Balance**: *sunny*; **Style**: *landscape*; **Image Size**: 3/2; **Mechanical Shutter**: *on*; **Camera Focus**: ∞ ; **Peaking Threshold**: *standard*.

Após a execução dos voos, as imagens foram importadas no Agisoft Metashape[®], para o geoprocessamento (*Structure from Motion-SfM*) e, conseqüentemente, geração do Modelo Digital de Superfície (MDS), Modelo Digital do Terreno (MDT) e Ortofotomosaico Clássico (OMC-RGB). Foram realizados dois processamentos para cada voo, com e sem pontos de controle.

Ressalta-se que o processamento SfM foi realizado seguindo algumas recomendações de AGISOFT LLC (2020) e Tu et al. (2020): a) importação de máscaras; b) estimativa da qualidade; c)

1° alinhamento; d) apontaria dos pontos de apoio; e) 2° alinhamento (*Accuracy: high; Key Points: 4000; Tie Point: 20000*); f) seleção gradual (*Reprojection Error: 10% dos pontos, Reconstruction Uncertainty: 10% dos pontos; Image Count: > 3 e Projection Accuracy: 25*); g) otimização da câmera (f, b1,b2, cx,cy,k1-K4,p1 e p2); h) recorte da área de interesse; i) geração da nuvem densa (*Quality: high, Depth filtering: Mild*) e MDS.

Com intuito de obter o MDT, foram aplicados dois filtros na nuvem densa [*Point spacing: 0,1 m; Filter by Confidence: 13(V60), 15(V90) e 17(V120)*]. Em seguida, classificou-se a nuvem de pontos [*Max angle: 1°; Max distance: 0,2 m; Cell size: 2 m (V60 e V90) e 3 m (V120)*] e, por fim, obteve-se OMC-RGB, ou seja, oriundo do MDT. Para os blocos aerofotogramétricos geoprocessados com pontos de controle, obteve-se a qualidade (RMSE-X,Y e Z) dos seis pontos de checagem e para cada altura de voo: a) V60: [X,Y] = 4,6 cm e [Z] = 6,2 cm; b) V90: [X,Y] = 4,9 cm e [Z] = 5,9 cm; c) V120: [X,Y] = 4,5 cm e [Z] = 6,0 cm.

2.4 Implementação da rotina automatizada

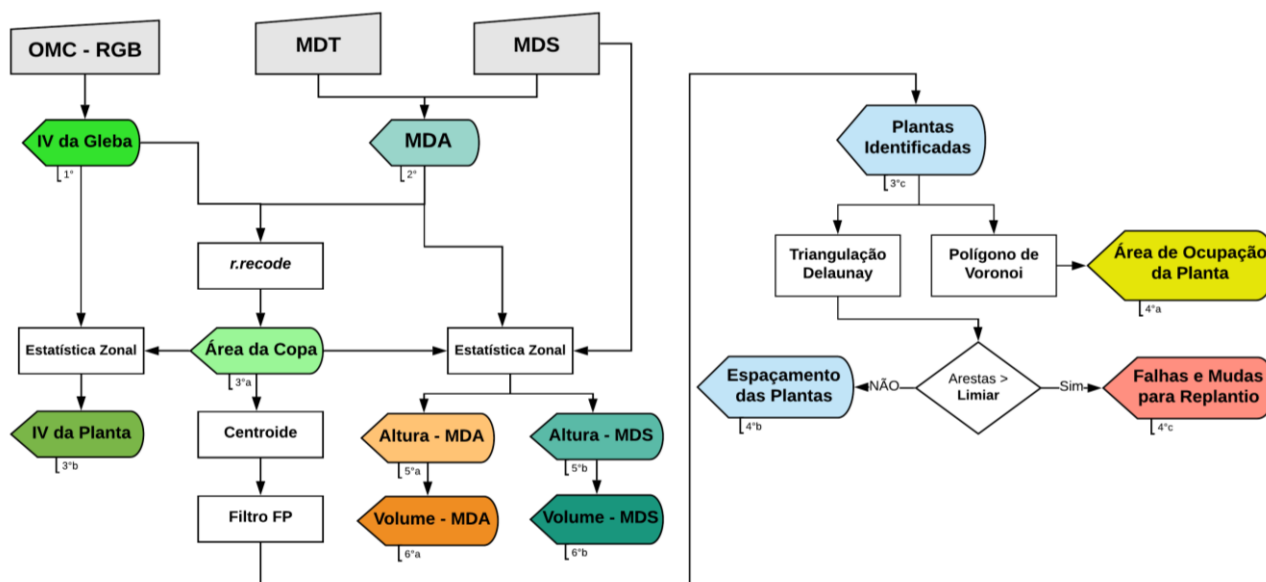
Para estimar os atributos biométricos da planta avaliada, por meio dos produtos aerofotogramétricos, desenvolveu-se uma rotina automatizada (FindCITRUS-V1), constituída por três fases de processamento: i) Estimativa dos Atributos Biométricos da Planta; ii) Análise Estatística e iii) Relatório Estatístico de Mapas (REM).

2.4.1 Estimativa dos Atributos Biométricos da Planta – Fase I

A primeira fase, implementada por meio do Modelador Gráfico do *software* QGIS 3.10.7-A, inicia-se com os *inputs* (obrigatórios) OMC-RGB, MDT e MDS e fornece (*outputs*) os seguintes produtos (atributos biométricos): 1°) Índice de Vegetação (IV) da Gleba de Interesse; 2°) Modelo Digital de Altura (MDA); 3°a) Área da Copa Projetada; 3°b) IV da Planta; 3°c) Plantas Identificadas; 4°a) Área de Ocupação da Planta; 4°b) Espaçamento das Plantas; 4°c) Falhas e Mudanças para Replanteio; 5°a) Altura das Plantas a partir do MDA; 5°b) Altura das Plantas a partir do MDS; 6°a) Volume das Plantas a partir do MDA e, 6°b) Volume das Plantas a partir do MDS (Figura 2).

Em relação à primeira fase, inicialmente, obtém-se o IV da Gleba, por meio da métrica VARI green, proposta por Gitelson, Kaufman, Stark & Rundquist (2002), que utiliza apenas as bandas do espectro visível (RGB). Em seguida, determina-se o MDA, obtido por meio da diferença entre MDS e MDT (ex., $MDA = MDS - MDT$), que representa a altura relativa (hr) de todos os objetos (elementos naturais e/ou artificiais) acima da superfície. Devido à presença de objetos (caixas e ferramentas) e da cobertura vegetal (nas entrelinhas de plantio), pixels com valores de hr abaixo de 45 cm foram considerados como zero.

Figura 2 - Workflow da primeira fase do FindCITRUS-V1. Os trapézios cinzas representam os *inputs*, os retângulos brancos representam algoritmos e os demais polígonos (coloridos) são os *outputs*, apresentados em números ordinais.



Em seguida, ocorre a combinação (multiplicação) com um produto (*outputs*) geométrico (MDA) e espectral (IV da Gleba), e o resultado é o *input* para o algoritmo *r.recode*, disponível no GRASS GIS 7. O *r.recode* é baseado em regras de classificação (segmentação) para converter os *pixels* da camada *raster* e, neste sentido, estabeleceu-se um limiar (após analisar o histograma) com valor zero, em que: valores abaixo são classificados (e vetorizados) como “não-área da copa” e valores acima como “provável-área da copa”. Na sequência, extraíram-se as áreas classificadas como “provável-área da copa”, permitindo suavizar e calcular as áreas (m²) dos polígonos irregulares. A extração final da área de copa só foi possível por meio de um limiar (podendo ser

alterado pelo usuário) para reduzir os polígonos indesejáveis (ruídos), para esse trabalho adotou-se um valor de 0,10 m². Uma vez delimitada a geometria da copa de cada planta, extraiu-se a estatística zonal (média aritmética) do *raster* IV da Gleba (1°), obtendo-se o IV da Planta (3°b).

O próximo processo consistiu em obter o centroide da copa de cada planta, seguido de um filtro que possibilita reduzir os Falsos Positivos (FP), quando necessário, obtendo-se assim a localização geográfica das plantas. Ressalta-se que o Filtro FP foi implementado por meio do algoritmo Delaunay (disponível no QGIS), calculando-se a área (m²) dos triângulos formados, o comprimento (m) e o azimute (°) de cada aresta da referida triangulação. Com tais informações, foi estabelecido um limiar de corte, filtrando-se as arestas indesejáveis e, conseqüentemente, a remoção dos pontos indesejáveis, ou seja, o FP.

Uma vez localizada [x,y] cada planta, criam-se os Polígonos de Voronoi, obtendo-se a distribuição espacial da área de ocupação (m² planta⁻¹). Novamente, outra Triangulação Delaunay foi implementada, seguindo a lógica supracitada. Porém, o limiar de corte filtra as arestas fora da normalidade dos espaçamentos entre plantas, ou seja, identifica as linhas que representam as falhas de plantio e, em seguida, estima-se a quantidade de mudas para replantio.

Ainda, com a localização da geometria que representa a Área da Copa de cada planta, aplica-se uma estatística zonal ao *raster* MDA e obtém-se o valor máximo das alturas relativas. O referido valor foi considerado como altura da planta (\hat{h}_{MDA} , 5°a) oriunda do MDA. Como alternativa, a rotina permite utilizar apenas o MDS para estimar altura da planta (\hat{h}_{MDS} , 5°b) oriunda do MDS. Nesse caso, determina-se o centroide da copa e estabelece-se uma máscara (raio com 50% do espaçamento entre plantas, ou seja, 1,5 m), seguido de uma estatística zonal, obtendo-se o valor máximo (\hat{H}_{max}) e mínimo (\hat{H}_{min}) das altitudes absolutas. O valor de \hat{h}_{MDS} é obtido pela diferença entre ambos os valores. Por último, estimam-se os respectivos volumes (V) oriundos do MDA (\hat{V}_{MDA} , 6°a) e MDS (\hat{V}_{MDS}).

2.4.2 Análise Estatística – Fase II

É constituída por uma Análise Estatística Descritiva de todos os atributos biométricos estimados anteriormente (Fase I). A rotina foi implementada (por meio de um *script*) no terminal *Python* 3.6 do próprio QGIS, utilizando as seguintes bibliotecas: *gdal*, *math*, *matplolib*, *numpy*, *pandas*, *seaborn* e *scipy*. A leitura das camadas (vetorial e *raster*) foi realizada por meio das classes *QgsVectorLayer* e *QgsRasterLayer*. Em seguida, realizou-se a extração dos valores das tabelas de atributos (camada vetorial) utilizando a instância *getFeatures()*. Por último, construíram-se os *dataframes* e, conseqüentemente, foram obtidas as estatísticas descritivas, tabelas, histogramas, *boxplot*, diagrama de dispersão ou de correlação (área da copa projetada e altura das plantas).

2.4.3 Relatório Estatístico de Mapas (REM) - Fase III

A última fase consistiu em desenvolver um relatório simples e intuitivo, nomeado como REM, contendo as seguintes informações: Cadastrais (Propriedade, Proprietário e Responsável Técnico), Cartográficas e Mapas dos Atributos Biométricos Geoespacializados (associados às Estatísticas Descritivas da Fase II). Para essa tarefa, desenvolveu-se outro *script*, novamente no terminal *Python* 3.6 do QGIS, utilizando as seguintes bibliotecas: *Reportlab*, *Matplotlib* e *Geopandas*.

2.5 Análise dos dados

A fim de se obter um fluxo de trabalho para aquisição dados aerofotogramétricos e validar a rotina FindCITRUS-V1, uma análise estatística foi realizada com os atributos biométricos medidos em campo (*ground truth*) e estimados (*predict value*). Também, utilizou-se o terminal *Python* 3.6 do QGIS para desenvolver as rotinas personalizadas, com as seguintes bibliotecas: *matplolib*, *numpy*, *pandas*, *sklearn*, *scipy.stats*, *seaborn* e *statsmodels*.

2.5.1 Delimitação e Estimativa da Área da Copa Projetada, Altura e Volume das Plantas

Em relação ao desempenho da identificação e delimitação da área da copa, utilizou-se a metodologia apresentada por Dong et al. (2020) e Jing, Hu, Noland & Li (2012). Primeiramente, delimitaram-se (fotointerpretação e vetorização manual no QGIS) as copas das plantas, obtendo-se assim uma geometria de referência (GR). Em seguida, foram extraídos, por meio da rotina

computacional, os polígonos que representam as copas das plantas, considerados aqui como Geometria Extraída (GE). Ambas foram analisadas em seis categorias (Ema: *number of matched tree-crowns*, Enm: *the number of near-matched tree-crowns*, Eme: *the number of merged tree-crowns*, Esp: *the number of split tree-crowns*, Emi: *the number of missed tree-crowns* e Ewr: *the number of wrong tree-crowns*). A acurácia (*Producer's Accuracy - PA*) foi estimada pela equação (2), em que E_{ma} representa o número total de *matched* da GE. E_e representa o número total da GE. E_{wr} representa o número errado de GE.

$$PA(\%) = \frac{E_{ma}}{E_e - E_{wr}} \times 100 \quad (2)$$

Para validar o tamanho da área (m^2) da copa projetada, foram consideradas apenas as classes Ema e Enm, como valores estimados (*predict value*), comparados com os valores mensurados (*ground truth*) em campo (área circular), ou seja, por meio dos diâmetros determinados na etapa 2.2. Os valores das alturas mensuradas em campo (hp) foram comparados com os valores estimados, ou seja, alturas oriundas do MDA (\hat{h}_{MDA}) e alturas oriundas do MDS (\hat{h}_{MDS}). Já os valores dos “volumes verdadeiros” (V) foram calculados pela Equação 1 e, posteriormente, comparados com os volumes (V) oriundos do MDA (\hat{V}_{MDA}) e MDS (\hat{V}_{MDS}). Os dados foram submetidos ao teste de normalidade Kolmogorov–Smirnov, seguido pela determinação *Root Mean Square Error* (RMSE) e *Mean Absolute Error* (MAE).

2.5.2 Identificação e contagem de indivíduos (Plantas e Falhas de Plantio)

O desempenho da rotina implementada foi avaliado por meio da comparação entre as plantas extraídas automaticamente pela rotina e a quantidade de plantas identificadas manualmente (*in loco*), seguido da fotointerpretação da área teste. Em seguida, aplicou-se três métricas (Equação 3, 4 e 5) de medidas de desempenho, apresentadas por Fan, Gong, Lu, Xie & Goodman (2018).

$$Sb = \frac{VP}{VP + FN} \quad (3)$$

$$Sp = \frac{VN}{VN + FP} \quad (4)$$

$$Ac = \frac{VP + VN}{VP + VN + FP + FN} \quad (5)$$

As medidas de desempenho usam as contagens de: (VP) verdadeiro positivo, ou o número de plantas de lima ácida corretamente identificadas; (VN) verdadeiro negativo, ou o número de falhas de plantio corretamente identificadas; (FP) falso positivo, ou o número de pontos identificados incorretamente como sendo lima ácida, mas sendo plantas daninhas, sombra ou outros objetos; e (FN) falso negativo, ou o número de plantas de lima ácida não identificadas.

A medida sensibilidade (Sb) reflete a capacidade do algoritmo para detectar plantas de lima ácida, enquanto a especificidade (Sp) é uma medida da eficácia do algoritmo na identificação de "plantas não-lima ácida". Já a acurácia geral (Ac) é uma medida global do desempenho do método proposto.

A fim de aumentar o rigor da avaliação do algoritmo em identificar e contar corretamente o número de plantas, mais duas métricas de avaliação foram empregadas neste estudo. A primeira, *producer's accuracy* (Pacc), é recomendada por Lavrač, Flach & Zupan (1999) e Moranduzzo & Melgani (2013), a qual representa a percentagem de plantas de lima ácida identificadas corretamente, Equação 6.

$$Pacc = \frac{VP}{N} \times 100 \quad (6)$$

Na medida *Pacc*, (N) indica o número real de plantas de lima ácida na área teste. A segunda medida, recomendada por Armstrong & Collopy (1992) e Stine et al. (2004), é o erro relativo (Er), pelo qual determinou-se o desempenho do método proposto, Equação 7.

$$Er = \frac{|Np - N|}{N} \times 100 \quad (7)$$


Em que $Np = VP + FP$, que é o número de plantas de lima ácida detectadas pelo algoritmo.

3. RESULTADOS E DISCUSSÃO

3.1. Delimitação e Estimativa da Área da Copa Projetada

Como resultado do geoprocessamento SfM, os *ground sample distances* (GSD) dos ortofotomosaicos clássicos (OMCs-*RGB*), para cada voo (V) e combinação [com e sem pontos de controle] foram de: V60 [1,59 cm e 1,57 cm], V90 [2,42 cm e 2,41 cm] e V120 [3,21 cm e 3,22 cm]. Já os GSD do modelo digital de superfície (MDS) e modelo digital do terreno (MDT) foram o dobro em relação aos GSD dos ortofotomosaicos. Os produtos aerofotogramétricos do V60 (sem pontos de controle) podem ser observados na Figura 3.

Figura 3. Produtos aerofotogramétricos do V60 (sem pontos de controle), *inputs* para a rotina FindCITRUS.



Percebe-se que os pontos de controle (PC) não aumentaram o valor da acurácia (PA) no processo de delimitação geométrica da copa das plantas avaliadas, cujas médias foram 92,04% e 92,62%, “Com PC” e “Sem PC”, respectivamente (Tabela 1). Diferenças significativas não foram encontradas e podem ser explicadas por meio da técnica de processamento SfM aplicada às imagens aéreas, visando a reconstrução da superfície 3D (nuvem de pontos) e, posteriormente, a geração dos modelos digitais de elevação (MDE) e Ortofotomosaico RGB. Conforme apontado por Snavely, Seitz & Szeliski (2008), inicialmente, o processo SfM estima a localização relativa dos objetos, sendo a localização absoluta (georreferenciamento), apenas uma opção nesse processo (Sanz-Ablanedo, Chandler, Rodriguez-Peréz & Ordóñez, 2018), para referenciar a um Datum.

Snavely, Seitz & Szeliski (2008) afirmam que a maioria dos problemas que visam a reconstrução 3D podem ser resolvidos apenas com a posição relativa dos objetos. Detalhes da modelagem matemática de reconstrução 3D podem ser encontrados em Szeliski (2010). O autor ressalta que desde o início dos anos 2000 houve um aumento exponencial na melhoria das técnicas

de processamento automático SfM sem a necessidade de quaisquer pontos de controle implantados no solo.

Atualmente, a maioria dos *softwares* usados para processar imagens adquiridas por UAV, são baseados em técnica SfM (Ferrer-González, Aguerva-Vega, Carvajal-Ramírez & Martínez-Carricondo, 2020). Esta abordagem, ao contrário da fotogrametria digital tradicional, resolve as equações de colinearidade sem a necessidade de qualquer ponto de controle, fornecendo uma nuvem de pontos esparsa em um sistema de coordenadas arbitrárias e uma calibração completa da câmera (AGISOFT LLC, 2020; Snavely; Seitz & Szeliski, 2008). Uma revisão mais completa, detalhada e atualizada, de soluções eficientes que foram incrementadas na técnica do SfM, em termos de seleção de pares de imagens, remoção de *outliers* dos pontos correspondentes iniciais e melhoria no *Bundle Adjustment* (BA), orientação de imagens, bem como os *softwares* e pacotes podem ser encontrado em Jiang, Jiang & Jiang (2020).

Já em relação à escala do mapeamento (ou GSD), menores valores de PA foram encontrados para GSD maiores, especificamente, oriundos do V120.

Tabela 1. Validação do processo de estimativa da área da copa projetada da lima ácida ‘Tahiti’ em formação sob diferentes alturas de voo e *ground sample distance* (GSD), com e sem pontos de controle (PC). Acurácia (*Producer’s Accuracy* - PA), *Root-Mean-Square-Error* (RMSE) e *Mean Absolute Error* (MAE) e Coeficiente de Correlação (R).

Voo	Área da Copa Projetada					
	Com PC			Sem PC		
	V60	V90	V120	V60	V90	V120
GSD (cm) OMC*_{RGB}	1,59	2,42	3,21	1,57	2,41	3,22
PA (%)	94,97	95,41	85,75	95,30	94,40	88,17
RMSE (m²)	1,54	1,51	1,30	1,59	1,52	1,29
MAE (m²)	1,40	1,365	1,14	1,45	1,37	1,13
R	0,87	0,85	0,83	0,87	0,85	0,83
P value	2E-256	5E-230	1E-192	1E-255	2E-230	6E-202

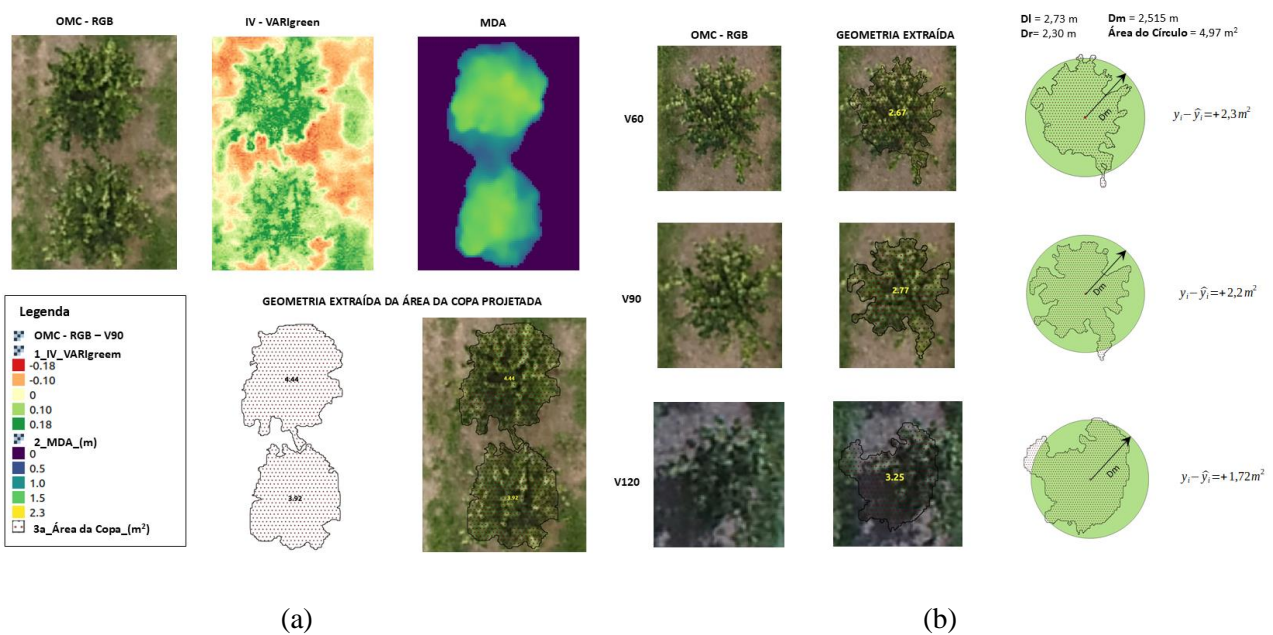
* Ortofotomosaico Clássico

É bom ressaltar que, no processo de delimitação da copa projetada, ocorre a combinação do produto geométrico com o produto espectral, sendo que este último foi, certamente, deteriorado pela variação das condições de iluminação durante o voo V120 (Figura 4B). Tal efeito colaborou para

reduzir a acurácia da delimitação, uma vez que o efeito de sombreamento pode causar ruídos na imagem (Yeom et al., 2019), diminuir o contraste entre os objetos (Tu et al., 2020) e, conseqüentemente, reduzir a acurácia da nuvem de pontos (Dandois et al., 2015).

Também é importante ressaltar que, para os voos V60 e V90, a combinação supracitada possibilitou ganhos no *matched* (Ema), reduziu a quantidade de *split* (Esp) e, principalmente, o *merged* (Eme) em áreas onde a seleção gradual da nuvem de pontos (uma das etapas do geoprocessamento SfM) não filtrou alguns ruídos (*error reprojection*, *reconstruction uncertainty* e *projection accuracy*) para remoção (Figura 4A - MDA). Independentemente da utilização dos PC, a redução da altura de voo (menor GSD) não foi suficiente para provocar diferenças significativas nas acurácias de V60 e V90, com média de 95,14% e 94,90%, respectivamente.

Figura 4 – Delimitação (a) e Cálculo (b) da Área da Copa Projetada.



Dong et al. (2020) também utilizaram um OMC-RGB (GSD = 1,14 cm e “Sem PC”) e MDE (GSD = 5,7 cm), oriundos de um voo de 50 m de altura, para delimitação da área da copa projetada. Combinaram MDA com IV (ExGR) e obtiveram acurácia de 97,4% e 98% para maçã e pera, respectivamente, ambas culturas com quatro anos de idade. Os referidos autores afirmaram que a

combinação também ajudou a minimizar os efeitos *background* da imagem e aumentar a acurácia na delimitação geométrica da copa da planta.

De maneira semelhante, a utilização de PC não provocou diferenças significativas no processo de estimativa da área (m^2) da copa projetada. Os seguintes valores médios foram obtidos: “Com PC” [RMSE ($1,45 m^2$) e MAE ($1,30 m^2$)] e “Sem PC” [RMSE ($1,47 m^2$) e MAE ($1,32 m^2$)]. Também, percebe-se que a magnitude da correlação permaneceu a mesma (“Com PC” ou “Sem PC”) (Tabela 1). Entretanto, abstraindo-se apenas nas alturas de voo, percebe-se uma redução nos valores das métricas RMSE, MAE e R, à medida que diminuiu a escala do mapeamento, ou seja, aumenta o GSD.

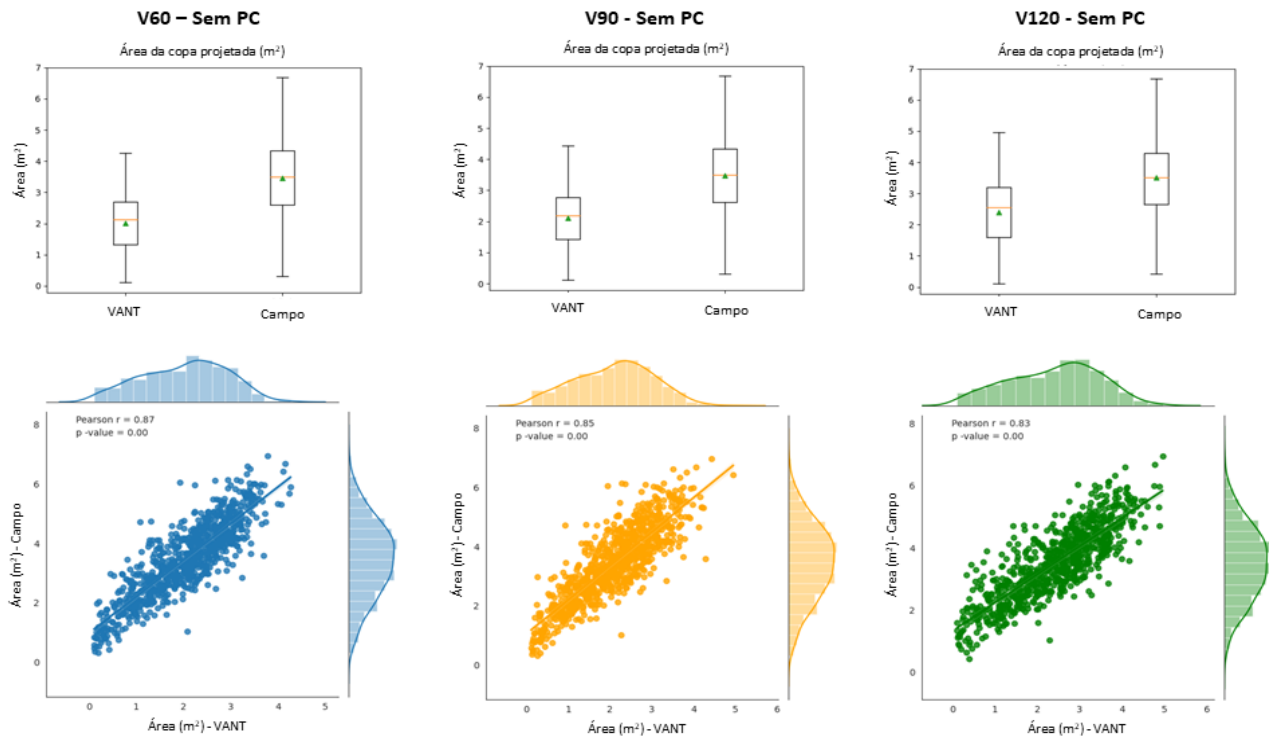
De maneira geral, os valores médios de RMSE e MAE podem ser compreendidos pelos métodos utilizados na estimativa da área (m^2), ou seja, geometria circular (*ground truth*) e polígono irregular (*predict value*) (Figura 4B). Quando se aumenta a escala do mapeamento, aumenta-se o detalhamento da imagem (Seifert et al., 2019) e, conseqüentemente, a descrição geométrica do real formato da copa projetada é melhorada, resultando em maiores diferenças (*ground truth - predict value*), ou seja, maiores valores de RMSE e MAE.

Nota-se que as medidas obtidas em campo (*ground truth*) para o cálculo da área da copa projetada levam em consideração apenas duas amostras de diâmetro (DI e Dr). Já por meio da metodologia proposta, obtêm-se polígonos irregulares mais condizentes à realidade e, teoricamente, mais acurados que os valores obtidos manualmente, os quais simplificam as geometrias das copas em formato circular.

Maiores detalhes da distribuição e dispersão dos dados oriundos da extração da área da copa projetada para voos sem pontos de controle e medidas de campo, no presente estudo, podem ser observados na Figura 5. De maneira geral, independentemente da utilização dos PC, os coeficientes de correlação ficaram acima de 0,83. Utilizando um VANT e uma câmera multiespectral, Ampatzidis et al. (2019) analisaram um pomar cítrico de quatro anos de idade e estimaram a área da

copa, por meio de segmentação NDVI e técnicas de CNN, obtendo uma correlação de 0,84, para uma altura de voo de 75 m (GSD = 5 cm) e sem PC.

Figura 5 - Estatística Descritiva da área da copa projetada pra voos “Sem PC”.



3.2. Identificação e Contagem de Indivíduos (Plantas e Falhas de Plantio)

É certo que a identificação do centro da copa de cada planta, por meio do algoritmo centroide, está diretamente relacionada com a acurácia da fase anterior (Delimitação da área da copa projetada), especificamente, com a quantidade de Ema e Enm, podendo, tal acurácia, ser degradada pela quantidade de Esp. Porém, essa situação foi consideravelmente minimizada por meio do Filtro FP, o qual reduziu a dupla identificação de uma única planta e, conseqüentemente, aumentou a acurácia no processo de identificação e contagem dos indivíduos. Esse procedimento reduziu a dependência da etapa anterior, no que se refere à acurácia, e pode ser utilizado quando necessário.

Dentre as combinações apresentadas, os PC não aumentaram, em média, o valor de Paac, “Com PC” (94,42%) e “Sem PC” (94,77%). Ainda que, analisando somente V60 e V90, os ganhos não foram significativos. É bom ressaltar que a acurácia e a qualidade dos produtos cartográficos obtidos com VANT não está restrita apenas à utilização dos pontos de controle e à acurácia do

georreferenciamento. Mas, conforme apontado por AGISOFT LLC (2020), Ferrer-González et al. (2020) e Sanz-Ablanedo et al. (2018), é resultado da escolha e ajustes de diversas variáveis, tais como: tipo de aeronave, tipo de sensor, planejamento de voo, taxa de sobreposição frontal e lateral, altura de voo, qualidade da imagem capturada, modelagem e calibração da câmera, algoritmos SfM, configuração dos parâmetros dos algoritmos, etc.

Outro fator importante e que tem muita relevância, é a característica das superfícies em termos de textura e variação de tonalidade. Superfícies que apresentam texturas aleatórias, sem padrões repetitivos ou coloração uniforme, podem facilitar a busca de pontos correspondentes nas imagens, melhorando a qualidade do processamento SfM (Remondino, Spera, Nocerino, Menna & Nex, 2014).

Já a redução da altura de voo (menor GSD) aumentou (para todas as combinações) a acurácia na identificação e contagem das plantas. O melhor desempenho (Tabela 2) foi para a combinação de V60 e “Sem PC”, ou seja, das 866 plantas a rotina identificou 843 plantas, culminando numa acurácia (Pacc) de 97,3%.

Tabela 2. Plantas corretamente identificadas (VP), falhas de plantio corretamente identificadas (VN), pontos identificados incorretamente como plantas (FP), plantas não identificadas (FN), sensibilidade na detecção de plantas (Sb), especificidade na identificação de plantas não lima ácida (Sp), acurácia (Ac), porcentagem de plantas identificadas corretamente (Paac) e erro relativo (Er) como medidas de desempenho em estudo com lima ácida ‘Tahiti’ a diferentes voos, com e sem pontos de controle (PC).

Voo	Com PC										Sem PC									
	VP	VN	FP	FN	Sb	Sp	Ac	Paac (%)	Er (%)	VP	VN	FP	FN	Sb	Sp	Ac	Paac (%)	Er (%)		
V60	841	70	3	25	0,97	0,96	0,97	97,11	-2,5	843	70	3	27	0,97	0,96	0,97	97,34	-2,3		
V90	840	70	0	31	0,96	1,00	0,97	97,00	-3,0	829	70	7	37	0,96	0,91	0,95	95,73	-3,5		
V120	772	70	17	95	0,89	0,80	0,88	89,15	-8,9	790	70	12	79	0,91	0,85	0,90	91,2	-7,4		

Conforme já mencionado na metodologia utilizada por Dong et al. (2020), os referidos autores também avaliaram a sensibilidade (Sb) do algoritmo para detectar plantas, e obtiveram valores de 98,3% (maçã) e 99,0% (pera). Já Ampatzidis & Partel (2019) apresentaram uma metodologia baseada em *Deep learning convolutional neural-networks* (DL-CNN), com câmera multiespectral, e

chegaram no Sb de 99,7%, para um pomar cítrico de quatro anos. Porém, é importante ressaltar que os referidos trabalhos foram realizados em plantas com idades avançadas, ou seja, com estruturas biométricas mais definidas.

O melhor resultado, aqui apresentado, foi de 97% (Sb) para V60, sem a utilização de PC. Porém, deve-se ressaltar que, como esperado, o principal erro na identificação das plantas foi devido aos FNs, que são as plantas com alturas e copas menores. Ressalta-se também a variabilidade dos dados (*ground truth*): a) altura média de 1,70 m (min = 0,54 m e max = 2,91 m) e CV de 21,98%; b) área (circular) da copa média de 3,40 m² (min = 0,11 m² e max = 6,95 m²) e CV de 39,12%.

O efeito da heterogeneidade na avaliação dos atributos biométricos, por meio sensor RGB acoplado em um VANT a 100 m de altura (GSD=2,52 cm), em plantios mais jovens, pode ser observado em Fawcett et al. (2019). Os autores estimaram a acurácia na identificação e contagem de plantas de palmeiras-de-óleo (*Elaeis guineensis*), com idades de dois, sete e 10 anos, e encontraram, respectivamente, 80,4%, 98,2% e 94,9%.

3.3 Estimativa da Altura e Volume das Plantas

Nota-se que os PC também não aumentaram a acurácia no processo de estimativa da altura da planta. Em geral, os valores de RMSE e MAE “Sem PC” ficaram menores que “Com PC” (Tabela 3). É válido ressaltar que, os MDE oriundos de processamento SfM, também, estão sujeitos à erros sistemáticos e aleatórios, introduzidos pelos PC (James, Robson, D’Oleire-Oltmanns & Niethammer, 2017). Durante o georreferenciamento da nuvem de pontos, ocorre a transformação de similaridade de alguns parâmetros (translação, rotação e escala) que podem compensar apenas modelos lineares (AGISOFT LLC, 2020). Os autores ressaltam que possíveis deformações não lineares podem ser removidas por meio da otimização dos parâmetros da edição da nuvem de pontos e calibração da câmera, com base nas coordenadas dos PC. Embora esse processo tenha sido realizado, o resultado não foi suficiente para elevar a acurácia, quando utilizado os PC.

Tabela 3. Validação da altura e volume das plantas de lima ácida ‘Tahiti’ em formação sob diferentes voos, com e sem pontos de controle (Pc), tanto no produto Modelo Digital de Altura (MDA) quanto no Modelo Digital de Superfície (MDS), *Root-Mean-Square-Error* (RMSE) e *Mean Absolute Error* (MAE) e Coeficiente de Correlação (R).

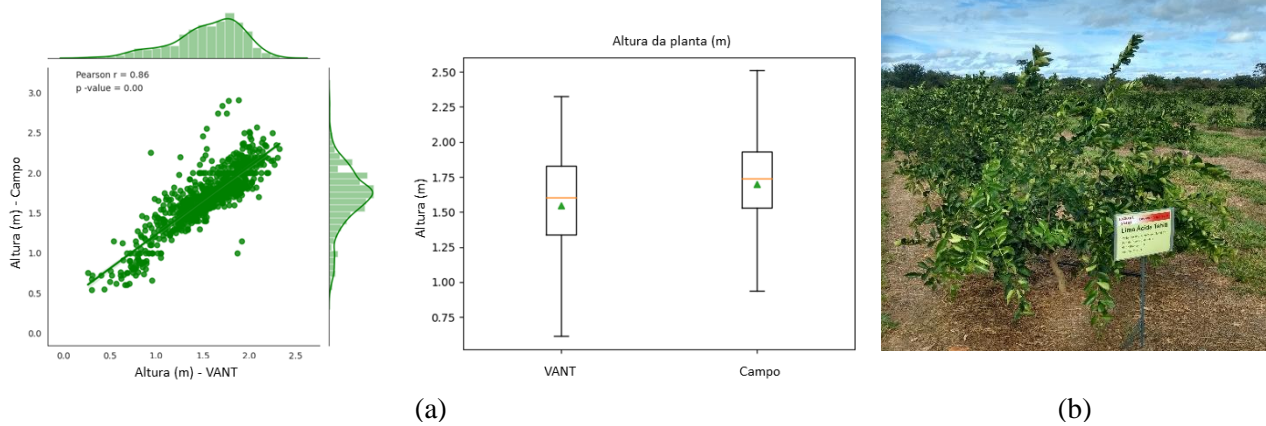
	MDA						MDS					
	Com PC			Sem PC			Com PC			Sem PC		
Altura da Planta												
Voo	V60	V90	V120	V60	V90	V120	V60	V90	V120	V60	V90	V120
RMSE (m²)	0,35	0,42	0,54	0,34	0,36	0,53	0,26	0,32	0,42	0,25	0,27	0,41
MAE (m)	0,29	0,36	0,48	0,28	0,29	0,46	0,19	0,25	0,36	0,18	0,20	0,35
R	0,86	0,85	0,82	0,86	0,84	0,83	0,86	0,84	0,81	0,86	0,84	0,82
P value	1E-254	6E-238	9E-208	3E-254	1E-236	9E-219	2E-258	4E-235	2E-201	1E-257	7E-237	2E-213
Volume da Planta												
Voo	V60	V90	V120	V60	V90	V120	V60	V90	V120	V60	V90	V120
RMSE (m³)	2,27	2,32	2,20	2,32	2,22	2,17	2,13	2,18	2,05	2,17	2,07	2,02
MAE (m³)	2,01	2,06	1,97	2,06	1,96	1,94	1,86	1,91	1,81	1,90	1,80	1,78
R	0,89	0,88	0,85	0,89	0,88	0,86	0,89	0,87	0,85	0,89	0,87	0,86
P value	2E-292	6E-265	4E-213	1E-291	3E-265	3E-228	5E-291	6E-263	2E-213	2E-290	4E-262	4E-229

Já a escala do mapeamento influenciou diretamente na estimativa da altura da planta, ou seja, menores valores de GSD proporcionaram melhores acurácias (menores RMSE e MAE) e maior magnitude de correlação. Voos com baixa altitude aumentam, significativamente, a densidade da nuvem de pontos, o que melhora a reconstrução do objeto (Seifert et al., 2019; Torres-Sánchez et al., 2018). Os valores de GSD dos MDS, para cada voo (V) e combinação de processamento [“Com PC” e “Sem PC”], foram de: V60 [3,18 cm e 3,14 cm], V90 [4,84 cm e 4,82 cm] e V120 [6,42 cm e 6,44 cm].

Melhores resultados foram alcançados com V60, especificamente, “Sem PC”. Observa-se que os dados oriundos do VANT e processamento SfM, tendem a subestimar os valores das alturas das plantas (Figura 6-A), conforme já relatado por Dandois et al. (2015). Alguns fatores, certamente, contribuíram nesta subestimativa: a) arquitetura irregular da copa (Figura 6-B), uma vez que a planta encontra-se em formação; b) resolução (GSD) do MDS não compatível com o tamanho dos objetos como galhos e folhas, maiores valores de GSD tendem a suavizar a superfície, reduz a

heterogeneidade da copa e, conseqüentemente, reduz a acurácia (Zarco-Tejada et al. 2014); c) a precisão da nuvem de pontos (oriunda do SfM), que é menor nas copas das plantas, quando comparada com à superfície do terreno (Fawcett et al., 2019); d) o movimento da planta durante a aquisição, provavelmente devido ao vento. Pela idade e estrutura da planta (Figura 6 - B), essa hipótese deve ser considerada.

Figura 6 - Estatística descritiva das alturas das plantas, estimadas a partir de imagens de sensor RGB em VANT a 60 m de altura (V60) no modelo digital de superfície (MDS) e sem pontos de controle e medidas de campo (*field*).



No que se refere aos modelos das alturas relativas (MDA) e altitudes absolutas (MDS), melhores resultados foram obtidos com MDS, ou seja, menores RMSE e MAE (Tabela 3). Quando se utiliza o MDA, por meio da metodologia utilizada nesse trabalho ($MDA = MDS - MDT$), o MDT é oriundo de dois filtros da nuvem densa, seguido de uma classificação, o que, certamente, suavizou os valores das alturas absolutas e, conseqüentemente, o MDA e os valores das alturas das plantas (\hat{h}_{MDA}). O processo de subtração do MDS pelo MDT é conhecido como normalização das alturas e pode causar subestimativas, não representando o ápice da planta (Holman et al., 2016). Essa situação é bastante comum em dados oriundos do processamento SfM e isso explica a subestimativa sistemática das alturas das plantas (Castro et al., 2019; Solvin, Puliti & Steffenrem, 2020). Baseado nessa tendência, o presente trabalho apresentou um procedimento alternativo, por meio da rotina desenvolvida, que conseguiu minimizar tal efeito, ou seja, utilizando apenas MDS os resultados foram mais satisfatórios.

O tamanho do GSD nos Modelos Digitais de Elevação (MDE) está fortemente correlacionado com a qualidade da estimativa da altura da planta. Reduzindo o valor do GSD (ou a altura de voo), aumentou o valor de R e diminuiu o valor de RMSE e MAE. Essa situação é desejável para estimar as alturas das plantas. No entanto, conforme apontado por Tu et al. (2020), em algumas situações, considerar a sobreposição frontal em função da altitude (até um certo limite), voar mais alto (alterando a distância focal para manter o mesmo GSD) pode melhorar a estimativa da altura das plantas, sendo equivalente ou ainda mais importante do que, simplesmente, diminuir o valor do GSD. É importante ressaltar que os referidos autores utilizaram uma câmera multiespectral, com alturas de voo de 25, 50, 75 e 100 m, na cultura do abacate, com 12 anos de idade.

Já em relação à estimativa do volume da planta, deve-se considerar, principalmente, os resultados supracitados, em especial os da seção 3.1, pois o valor da área da copa projetada tem peso maior (Equação 1) quando comparado à altura da planta (h_p), no que se refere à estimativa do volume (V). Portanto, embora os valores de RMSE e MAE (Tabela 3) tenham diminuído com o aumento do GSD, certamente, as referidas métricas não revelam diretamente, com exceção o coeficiente de correlação (R), a acurácia do método aqui proposto. Torres-Sánchez et al. (2018) analisaram o volume de um pomar de oliveiras, com voos de 50 m (GSD = 1,9 cm) e 100 m (GSD = 3,8 cm) de altura, utilizando um VANT do tipo quadricóptero, com sensor RGB de 12 megapixels, variando sobreposição frontal, e obtiveram melhores resultados para voos de 100 m de altura, com 95% de sobreposição frontal.

Os resultados apresentados no presente trabalho atendem as necessidades de estudos apontadas por Dong et al. (2020), em testar os efeitos de diferentes GSD e condições de iluminação nas estimativas dos atributos biométricos das plantas. Também complementam as recomendações de Tu et al. (2020), ou seja, testar diferentes combinações de parâmetros aerofotogramétricos (no caso Quadro 1) com outros sensores (no caso RGB), em diferentes culturas (no caso citros).

Quanto à utilização dos PC, somente é necessário quando pretende realizar uma análise temporal da cultura de interesse, pois os VANTs, com receptor de navegação, não têm um sistema

de correção diferencial que proporcionam correções submétricas. Por outro lado, em áreas com superfícies homogêneas, os PC podem desempenhar um papel importantíssimo pois, durante a etapa de alinhamento, os PC podem melhorar o processo de autocalibração da câmera (AGISOFT LLC, 2020). Também, os modelos 3D SfM oriundos de imagens aéreas, inicialmente, podem conter deformações ou erros sistemáticos. Essas deformações podem ser reduzidas quanto utilizam-se os pontos de controle (Eltner & Schneider, 2015; James & Robson, 2014). Porém, é importante o usuário se atentar à qualidade posicional dos PC, ou seja, à acurácia das coordenadas geodésicas, caso contrário, conforme apontado por Sanz-Ablanedo et al. (2018), quando coordenadas imprecisas são aplicadas ao processamento SfM, em vez de reduzir a deformação inicial, uma superfície de erro mais complexa será introduzida.

Quanto à quantidade e distribuição de PC no solo (na aerofotogramétrica com VANT e processamento SfM), já é um tema estudado e pode ser encontrado na literatura. Porém, possui certas peculiaridades, por utilizarem câmeras não-métricas e autocalibração, alguns resultados são inconclusivos ou até mesmo contraditórios (Sanz-Ablanedo et al. 2018). Teoricamente, quanto mais PC são utilizados e bem distribuídos, melhor o resultado da acurácia horizontal e vertical (Agüera-Veja; Carvajal-Ramírez & Martínez-Carricondo, 2017; Ferrer-González et al., 2020; James et al., 2017; James & Robson, 2014).

Sanz-Ablanedo et al. (2018) são categóricos em afirmar que não há dúvidas de que novas pesquisas reduzirão a dependência dos PC para projetos baseados em SfM. A não utilização dos PC resulta em economia de tempo, dispensa o georreferenciamento de alvos fotoidentificáveis em campo e reduz de investimento (compra ou aluguel de um Receptor Geodésico). Conforme apontado por Fawcett et al. (2019), alternativas de baixo custo de Receptores GNSS com precisão abaixo de 10 cm, tem-se mostrado promissoras, em exemplo seria o *Post Processed Kinematic* (PPK), o qual poderá reduzir, consideravelmente, a utilização dos PC (Zhang et al., 2019).

Em termos de rendimento operacional de campo, considerando apenas o intervalo de registro das imagens durante os voos obteve-se uma capacidade de campo efetiva de 22,4 ha hora⁻¹ (V60),

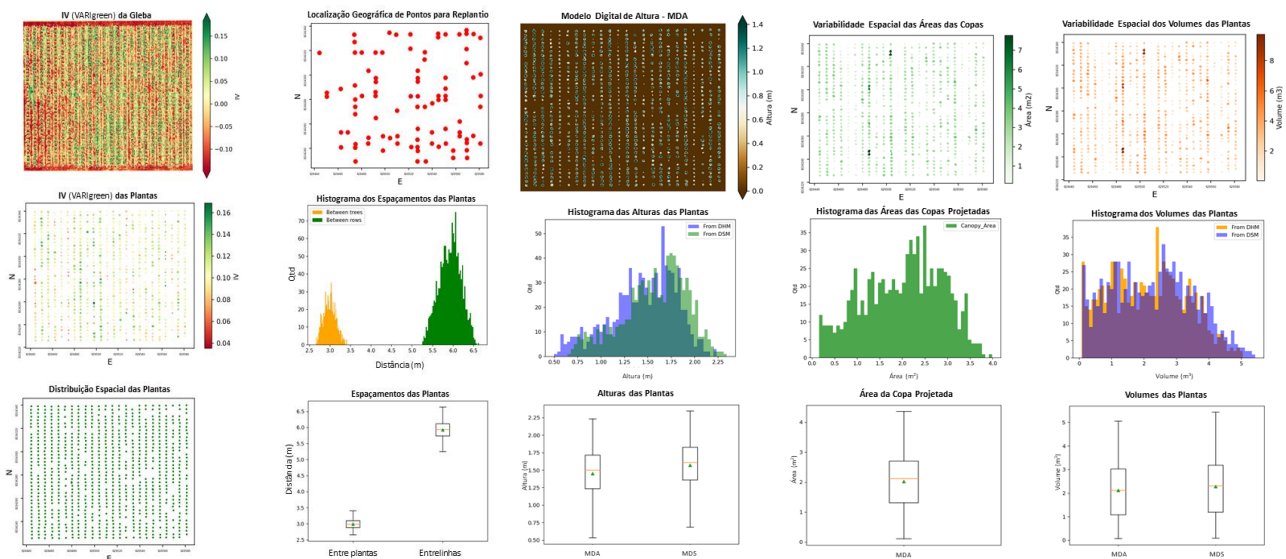
51,3 ha hora⁻¹ (V90) e 81,0 ha hora⁻¹ (V120). Em relação ao processamento SfM, conforme apontado por Torres-Sánchez et al. (2018), menor altitude de voo (menor GSD), aumenta a quantidade de imagens capturadas, maior demanda de armazenamento e tempo de processamento para gerar os produtos aerofotogramétricos (Castro *et al.*, 2019).

3.5 Desempenho da Rotina Automatizada – FindCITRUS-V1

Em termo de tempo de processamento computacional é relevante ressaltar que, utilizando-se de uma máquina do tipo Laptop, com sistema operacional Linux (Ubuntu 18.04-bionic), CPU Intel(R) Core(TM) i7-4500U (4 núcleos, 1.80GHz, L2 cache 4096 KB), RAM 16 GB e SSD Kingston SA 400S3, GPU (GeForce GT 740M), para analisar a referida área teste, consumiu-se 11'42"[V60], 4'38"[V90] e 2'21"[V120].

Os atributos avaliados são apresentados na forma de Mapas e Estatísticas Descritivas, sendo eles: IV (VARI green) da Gleba, IV planta⁻¹, Plantas Identificadas e Mudas para Replanteio, Modelo Digital de Altura (MDA), Área da Copa Projetada e Volume das Plantas (Figura 7).

Figura 7 – Principais atributos avaliados por meio da rotina FindCITRUS. Dados oriundos do voo V60, sem pontos de controle.



As informações são agrupadas em um *layout* personalizado, com informações Cadastrais (Propriedade, Gleba Avaliada e Proprietário) e Cartográficas (MDS, MDT e Ortofotomosaico), resultando no Relatório Estatístico de Mapas (REM). O relatório é gerado no formato “.pdf”, na

escala de uma planta, o qual fornece informações valiosas para o monitoramento da qualidade de pomares de lima ácida ‘Tahiti’ em formação, pois apresentam métricas estatísticas associadas aos atributos biométricos, os quais, conforme Ampatzidis et al. (2019), Colaço, Molin, Rosell-Polo & Escolà (2018) e Ok & Ozdarici-Ok (2018), permitem identificar zonas de manejos com diferentes características, o que certamente, proporcionará mais assertividade. Também, possibilita criar séries temporais de alta resolução que podem auxiliar o manejo da irrigação (Yeom et al., 2019).

Por fim, o presente estudo, além de apresentar um método de obtenção de dados aerofotogramétricos, utilizando sensor RGB em VANT, para pomares cítricos em formação, também se destaca nas seguintes contribuições: (i) apresenta uma rotina automatizada e calibrada, nos aspectos aerofotogramétricos e da visão computacional; (ii) a rotina estima alguns atributos biométricos da planta, os analisa por meio da estatística descritiva e os apresenta por meio de um relatório (REM) que pode ser utilizado na análise da qualidade de pomares cítricos em formação; (iii) a rotina exige mínima intervenção do usuário (ambiente gráfico e intuitivo), possibilitando a modificação dos parâmetros *default*, quando necessário; (iv) a rotina foi desenvolvida e pode ser utilizada em um único software *open source*, QGIS; (v) a rotina apresenta excelente desempenho em ortofotomosaico oriundo de canais RGB, ou seja, um sensor de baixo custo e de fácil operação (Yao et al., 2019); (vi) pode auxiliar no processo de fenotipagem de plantas em campo; (vii) fornece ao usuário (pesquisadores, consultores e produtores) uma nova ferramenta para avaliação de pomares cítricos (em fase de formação), até então, inexistente; (viii) apresenta flexibilidade para adaptação em outras culturas perenes como: manga, abacate e café, dentre outras.

4. CONCLUSÕES

Os resultados são suficientes para definir um método de obtenção de dados aerofotogramétricos (por meio de VANT) que pode ser utilizado para o monitoramento da qualidade de pomares de lima ácida ‘Tahiti’ em formação. A utilização dos PC, na etapa de geoprocessamento SfM, não aumenta a acurácia no processo de estimativa dos atributos

biométricos avaliados. A escala do mapeamento (tamanho do GSD) está fortemente correlacionada com a qualidade da estimativa dos atributos avaliados, em especial a altura da planta. A rotina desenvolvida apresenta alta acurácia e excelente desempenho computacional, além de um ambiente intuitivo e flexibilidade de adaptação para culturas perenes.

5. AGRADECIMENTOS

Os autores agradecem à Fazenda Saara (Sr. Cláudio), pela disponibilização da área de estudo, aos Programas de Pós-Graduação em Produção Vegetal no Semiárido (PPGPVS) e Modelagem Computacional e Sistemas (PPGMcS); bem como à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão de bolsas. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- Aasen, H., Honkavaara, E., Lucieer, A., & Zarco-Tejada, P. J. (2018). Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. *Remote Sensing*, 10(7), 1091. DOI: 10.3390/rs10071091
- AGISOFT LLC. Agisoft Metashape. User Manual: Professional Edition, Version 1.6. 2020.
- Aguera-Vega, F., Carvajal-Ramírez, F., & Martínez-Carricondo, P. (2017). Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle. *Measurement*, 98, 221-227. DOI: 10.1016/j.measurement.2016.12.002
- Ampatzidis, Y. & Partel, V. (2019). UAV-Based High Throughput Phenotyping in Citrus Utilizing Multispectral Imaging and Artificial Intelligence. *Remote Sensing*, 11(4), 410. DOI: 10.3390/rs11040410
- Ampatzidis, Y., Partel, V., & Costa, L. (2020). Agroview: Cloud-based application to process, analyze and visualize UAV-collected data for precision agriculture applications utilizing artificial intelligence. *Computers and Electronics in Agriculture*, 174, 105457. DOI: 10.1016/j.compag.2020.105457
- Ampatzidis, Y., Partel, V., Meyering, B., & Albrecht, U. (2019). Citrus rootstock evaluation utilizing UAV-based remote sensing and artificial intelligence. *Computers and Electronics in Agriculture*, 164, 104900. DOI: 10.1016/j.compag.2019.104900

- Apolo-Apolo, O. E., Martinez-Guanter, J., Egea, G., Raja, P., & Pérez-Ruiz, M. (2020). Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. *European Journal of Agronomy*, 115, 126030, 2020. DOI: 10.1016/j.eja.2020.126030
- Armstrong, J. S., & Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, 8(1), 69-80. DOI: 10.1016/0169-2070(92)90008-W
- Carrer, M. J., Souza Filho, H. M., & Batalha, M. O. (2017). Factors influencing the adoption of Farm Management Information Systems (FMIS) by Brazilian citrus farmers. *Computers and Electronics in Agriculture*, 138, 11-19. DOI: 10.1016/j.compag.2017.04.004
- Carvalho, S. A., Girardi, E. A., Mourão Filho, F. A. A., Ferrarezi, R. S., & Coletta Filho, H. D. (2019). Advances in citrus propagation in Brazil. *Revista Brasileira de Fruticultura*, 41(6), e-422. DOI: 10.1590/0100-29452019422
- Castricini, A., Silva, J. T. A., Silva, I. P., & Rodrigues, M. G. V. (2017). Quality of 'tahiti' acid lime fertilized with nitrogen and potassium in the semiarid region of Minas Gerais. *Revista Brasileira de Fruticultura*, 39(2), e-288. DOI: 10.1590/0100-29452017288
- Castro, A. I., Rallo, P., Suárez, M. P., Torres-Sánchez, J., Casanova, L., Jiménez-Brenes, F. M., ... López-Granados, F. (2019). High-throughput system for the early quantification of major architectural traits in olive breeding trials using UAV images and OBIA techniques. *Frontiers in Plant Science*, 10, 1472. DOI: 10.3389/fpls.2019.01472
- Colaço, A. F., Molin, J. P., Rosell-Polo, J. R., & Escolà, A. (2018). Application of light detection and ranging and ultrasonic sensors to high-throughput phenotyping and precision horticulture: current status and challenges. *Horticulture Research*, 5(1), 35. DOI: 10.1038/s41438-018-0043-0
- Csillik, O., Cherbini, J., Johnson, R., Lyons, A., & Kelly, M. (2018). Identification of Citrus Trees from Unmanned Aerial Vehicle Imagery Using Convolutional Neural Networks. *Drones*, 2(4), 39. DOI: 10.3390/drones2040039
- Dandois, J., Olano, M., & Ellis, E. C. (2015). Optimal Altitude, Overlap, and Weather Conditions for Computer Vision UAV Estimates of Forest Structure. *Remote Sensing*, 7(10), 13895-13920. DOI: 10.3390/rs71013895
- Dargan, S., Kumar, M., Ayyagari, M. R., & Kumar, G. (2019). A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning. *Archives of Computational Methods in Engineering*, 27, 1071-1092. DOI: 10.1007/s11831-019-09344-w
- Dong, X., Zhang, Z., Yu, R., Tian, Q., & Zhu, X. (2020). Extraction of Information about Individual Trees from High-Spatial-Resolution UAV-Acquired Images of an Orchard. *Remote Sensing*, 12(1), 133. DOI: 10.3390/rs12010133
- Donkersley, P., Silva, F. W. S., Carvalho, C. M., Al-Sadi, A. M., & Elliot, S. L. (2019). Correction to: Biological, environmental and socioeconomic threats to citrus lime production. *Journal of Plant Diseases and Protection*, 126(5), 489-489. DOI: 10.1007/s41348-019-00253-5

- Eltner, A.; & Schneider, D. (2015). Analysis of different methods for 3D reconstruction of natural surfaces from parallel axes UAV images. *The Photogrammetric Record*, 30(151), 279-299. DOI: 10.1111/phor.12115
- Fan, Z., Gong, M., Lu, J., Xie, H., & Goodman, E. D. (2018). D. Automatic Tobacco Plant Detection in UAV Images via Deep Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 99, 1-12. DOI: 10.1109/JSTARS.2018.2793849
- Fawcett, D., Kho, L. K., Hill, T. C., Azlan, B., Bennie, J., & Anderson, K. (2019). Unmanned aerial vehicle (UAV) derived structure-from-motion photogrammetry point clouds for oil palm (*Elaeis guineensis*) canopy segmentation and height estimation. *International Journal of Remote Sensing*, 40(1), 7538-7560. DOI: 10.1080/01431161.2019.1591651
- Ferrer-González, E., Aguerva-Vega, Carvajal-Ramírez, F., & Martínez-Carricondo, P. (2020). UAV Photogrammetry Accuracy Assessment for Corridor Mapping Based on the Number and Distribution of Ground Control Points. *Remote Sensing*, 12(15), 2447. DOI: 10.3390/rs12152447
- García-Ruiz, F., Sankaran, S., Maja, J. M. J., Rasmussen, J., Ehsani, R., & Lee, W. S. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*, 91, 106-115. DOI: 10.1016/j.compag.2012.12.002
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. DOI: 10.1016/S0034-4257(01)00289-9
- Holman, F. H., Riche, A. B., Michalski, A., Castle, M., Wooster, M. J., & Hawkesford, M. J. (2016). High throughput field phenotyping of wheat plant height and growth rate in field plot trials using UAV based remote sensing. *Remote Sensing*, 8(12), 1031. DOI: 10.3390/rs8121031
- Ivushkin, K., Bartholomeus, H., Bregt, A. K., Pulatow, A., Franceschini, M. H. D., Kramer, H., ... Finkers, R. (2019). UAV based soil salinity assessment of cropland. *Geoderma*, 338(15), 502-512. DOI: 10.1016/j.geoderma.2018.09.046
- James, M. R., Robson, S., D'Oleire-Oltmanns, S., & Niethammer, U. (2017). Optimising UAV topographic surveys processed with structure-from-motion: Ground control quality, quantity and bundle adjustment. *Geomorphology*, 280, 51-66. DOI: 10.1016/j.geomorph.2016.11.021
- James, M. R.; & Robson, S. (2014). Mitigating systematic error in topographic models derived from UAV and ground based image networks. *Earth Surface Processes and Landforms*, 39(10), 1413-1420. DOI: 10.1002/esp.3609
- Jiang, S., Jiang, C., & Jiang, W. (2020). Efficient structure from motion for large-scale UAV images: A review and a comparison of SfM tools. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 230-251. DOI: 10.1016/j.isprsjprs.2020.04.016
- Jing, L., Hu, B., Noland, T., & Li, J. (2012). Automated Delineation of Individual Tree Crowns from Lidar Data by Multi-Scale Analysis and Segmentation. *Photogrammetric Engineering & Remote Sensing*, 78(12), 1275-1284. DOI: 10.14358/PERS.78.11.1275

- Kang, D., Ma, Z., & Chan, A. B. (2019). Beyond Counting: Comparisons of Density Maps for Crowd Analysis Tasks-Counting, Detection, and Tracking. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(5), 1408-1422. DOI: 10.1109/TCSVT.2018.2837153
- Lavrac, N., Flach, P., & Zupan, B. (1999). Rule evaluation measures: A unifying view. In: *International Conference on Inductive Logic Programming*. Springer, Berlin, Heidelberg, 1634, 174-185. DOI: 10.1080/0952813x.2013.808801
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177. DOI: 10.1016/j.isprsjprs.2019.04.015
- Maes, W. H., & Steppe, K. (2019). Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends in Plant Science*, 24(2), 152-164. DOI: 10.1016/j.tplants.2018.11.007
- Moranduzzo, T., & Melgani, F. (2013). Automatic Car Counting Method for Unmanned Aerial Vehicle Images. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3), 1635-1647. DOI: 10.1109/TGRS.2013.2253108
- Ok, A. O.; & Ozdarici-Ok, A. (2018). 2-D delineation of individual citrus trees from UAV-based dense photogrammetric surface models. *International Journal of Digital Earth*, 11(6), 583-608, 2018. DOI: 10.1080/17538947.2017.1337820
- Oscó, L. P., Arruda, M. S., Marcato Junior, J., Silva, N. B., Ramos, A. P. M., Moryia, E. A. S., ... Gonçalves, W. N. (2020). A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 160, 97-106. DOI: 10.1016/j.isprsjprs.2019.12.010
- Remondino, F., Spera, M. G., Nocerino, E., Menna, F., & Nex, F. (2014). State of the art in high density image matching. *The Photogrammetric Record*, 29(146), 144-166. DOI: 10.1111/phor.12063
- Rodrigues, M. J. S., Araújo Neto, S. E., Andrade Neto, R. C. A., Soares Filho, W. S., Girardi, E. A., ... Araújo, J. M. (2019). Agronomic performance of the 'Pera' orange grafted onto nine rootstocks under the conditions of Rio Branco, Acre, Brazil. *Brazilian Journal of Agricultural Sciences*, 14(4), 1-8. DOI: 10.5039/agraria.v14i4a6642
- Sanz-Ablanedo, E., Chandler, J., Rodriguez-Peréz, J., & Ordóñez, C. (2018). Accuracy of unmanned aerial vehicle (UAV) and SfM photogrammetry survey as a function of the number and location of ground control points used. *Remote Sensing*, 10(10), 1606. DOI: 10.3390/rs10101606
- Seifert, E., Seifert, S., Vogt, H., Drew, D., Aardt, J. V., Kunneke, A., & Seifert, T. (2019). Influence of drone altitude, image overlap, and optical sensor resolution on multi-view reconstruction of forest images. *Remote Sensing*, 11(10), 2019. DOI: 10.3390/rs11101252
- Shi, Y., Thomasson, J. A., Murray, S. C., Pugh, N. A., Rooney, W. L., Shafian, S., ... Yang, C. (2016). Unmanned Aerial Vehicles for High-Throughput Phenotyping and Agronomic Research. *Plos One*, 11(7), e0159781. DOI: 10.1371/journal.pone.0159781.

- Snaveley, N.; Seitz, S. M.; & Szeliski, R. (2008). Modeling the world from internet photo collections. *International Journal of Computer Vision*, 80(2), 189-210. DOI: 10.1007/s11263-007-0107-3
- Solvin, T.M.; Puliti, S.; & Steffenrem, A. (2020). Use of UAV photogrammetric data in forest genetic trials: measuring tree height, growth, and phenology in Norway spruce (*Picea abies* L. Karst.). *Scandinavian Journal of Forest Research*, 35(7), 322-333. DOI: 10.1080/02827581.2020.1806350
- Stine, B. E., Stashower, D. M., Lee, S. F., Weiner, K. H., Hess, C., Weiland, L., ... Vallishayee, R. (2004). *System and method for product yield prediction using a logic characterization vehicle*. Depositante: Brian E. Stine. *et al.* U.S. Patent 6834375B1. 21 dez. 2004.
- Szeliski, R. (2010). *Computer vision: algorithms and applications*. Springer Science & Business Media.
- Torres-Sánchez, J., López-Granados, F., Borra-Serrano, I., & Peña, J. M. (2018). Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precision Agriculture*, 19 (1), 115-133. DOI: 10.1007/s11119-017-9502-0
- Tu, Y. H., Phinn, S., Johansen, K., Robson, A., & Wu, D. (2020). Optimising drone flight planning for measuring horticultural tree crop structure. *ISPRS Journal of Photogrammetry and Remote Sensing*, 160, 83-96. DOI: 10.1016/j.isprsjprs.2019.12.006
- Wang, S., Baum, A., Zarco-Tejada, P. J., Dam-Hansen, C., Thorseth, A., Bauer-Gottwein, P., ... Garcia, M. (2019). Unmanned Aerial System multispectral mapping for low and variable solar irradiance conditions: Potential of tensor decomposition. *ISPRS Journal of Photogrammetry and Remote Sensing*, 155, 58-71. DOI: 10.1016/j.isprsjprs.2019.06.017
- Yang, W., Zhang, X., Tian, Y., Wang, W., Xue, J. H., & Liao, Q. (2019). Deep Learning for Single Image Super-Resolution: A Brief Review. *IEEE Transactions on Multimedia*, 21(12), 3106-3121. DOI: 10.1109/TMM.2019.2919431
- Yao, H.; Qin, R.; & Chen, X. (2019). Unmanned Aerial Vehicle for Remote Sensing Applications-A Review. *Remote Sensing*, 11(12), 1443. DOI: 10.3390/rs11121443
- Yeom, J., Jung, J., Chang, A., Ashapure, A., Maeda, M., Maeda, A., & Landivar, J. (2019). Comparison of Vegetation Indices Derived from UAV Data for Differentiation of Tillage Effects in Agriculture. *Remote Sensing*, 11(13), 1548. DOI: 10.3390/rs11131548
- Zarco-Tejada, P. J., Varela, R. D., Angileri, V., & Loudjani, P. (2014). Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. *European Journal of Agronomy*, 55, 89-99. DOI: 10.1016/j.eja.2014.01.004
- Zhang, H., Aldana-Jague, E., Clapuyt, F., Wilken, F., Vanacker, V., & Oost, K. V. (2019). Evaluating the potential of post-processing kinematic (PPK) georeferencing for UAV-based structure-from-motion (SfM) photogrammetry and surface change detection. *Earth Surface Dynamics*, 7(3), 807-827. DOI: 10.5194/esurf-7-807-2019

CONCLUSÕES GERAIS E CONSIDERAÇÕES FINAIS

Alguns avanços e inovações destacam-se neste trabalho, em especial, por apresentar um método, contendo um conjunto de parâmetros aerofotogramétricos que pode ser utilizado, de forma rápida, fácil e confiável, nas avaliações biométricas das culturas analisadas. Além de implementar, calibrar e validar algumas técnicas de visão computacional para interpretar ortofotomosaicos oriundos de sensor RGB, de baixo custo e fácil operação, acoplado em VANT, por meio de rotinas computacionais com interfaces simples e intuitivas.

Para a cultura do eucalipto, no estágio fenológico avaliado, os resultados permitem inferir que a rotina desenvolvida fornece alguns produtos com acurácia elevada que podem ser utilizados para avaliar a qualidade dos plantios florestais, em especial, para avaliação de inventário de sobrevivência. A referida rotina exige mínima intervenção do usuário e foi desenvolvida em plataformas *open source*, que pode ser facilmente reproduzida e utilizada em escala comercial.

Já para pomar cítrico em fase de formação a rotina computacional fornece aos usuários como pesquisadores, consultores e produtores rurais uma nova ferramenta (em ambiente *open source*) para avaliação, até então, inexistente. Também são apresentados alguns avanços de implementação e calibração nas técnicas de processamento de ortofotomosaico RGB. Em especial, o trabalho destaca-se por analisar o efeito da variação de GSD e da utilização dos pontos de controle, na etapa de geoprocessamento SfM, para estimar alguns atributos biométricos. A escala de mapeamento está fortemente correlacionada com a qualidade da estimativa dos atributos avaliados, em especial a altura da planta. Já a utilização dos pontos de controle não aumenta a acurácia no processo de estimativa dos atributos biométricos.

Ressalta-se que, ambas rotinas podem auxiliar no processo de fenotipagem de plantas em campo e apresentam alta flexibilidade para adaptação em outras culturas perenes.