



MINISTÉRIO DA EDUCAÇÃO  
Universidade Federal de Alfenas / UNIFAL-MG  
Programa de Pós-graduação – Ciências Ambientais  
Rua Gabriel Monteiro da Silva, 714 - Alfenas - MG CEP 37130-001  
Fone: (35) 3701-9685 (Coordenação) / (35) 3701-9262 (Secretaria)  
<http://www.unifal-mg.edu.br/ppgca/>



FILIPPE CASTRO FELIX

**“Comportamento sazonal de coberturas vegetais a partir de imagens de sensores embarcados em veículo aéreo não tripulado”**

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

Aprovado em: 26 de outubro de 2018.

Prof. Dr. Ronaldo Luiz Mincato  
Instituição: UNIFAL-MG

Assinatura:

Prof. Dr. Henrique Llacer Roig  
Instituição: UnB

Assinatura:

Prof. Dr. Vinicius Xavier da Silva  
Instituição: UNIFAL-MG

Assinatura:

UNIVERSIDADE FEDERAL DE ALFENAS - MG

FILIPPE CASTRO FELIX

**COMPORTAMENTO SAZONAL DE COBERTURAS VEGETAIS A  
PARTIR DE IMAGENS DE SENSORES EMBARCADOS EM VEÍCULO  
AÉREO NÃO TRIPULADO**

**Alfenas/MG**

**2018**

FILIPPE CASTRO FELIX

**COMPORTAMENTO SAZONAL DE COBERTURAS VEGETAIS A  
PARTIR DE IMAGENS DE SENSORES EMBARCADOS EM VEÍCULO  
AÉREO NÃO TRIPULADO**

Dissertação como parte dos requisitos para obtenção do título de Mestre em Ciências Ambientais pela Universidade Federal de Alfenas. Área de concentração: Ecologia e Tecnologia Ambiental.

Orientador: Prof. Dr. Ronaldo Luiz Mincato  
(UNIFAL-MG)

Coorientador: Prof. Dr. Marx Leandro Naves Silva  
(UFLA)

**Alfenas/MG**

**2018**

**Dedico à família e aos amigos.**

À CAPES, pela bolsa de estudos.

À minha mãe Fabíola e ao meu pai Marcelo, pelo grande exemplo de vida, amor e dedicação.

Ao meu irmão Thiago, meu grande amigo e parceiro, pelo apoio e incentivo na realização deste trabalho.

Aos meus avôs João (*In memorian*) e Jair (*In memorian*), às minhas avós Aparecida e Sarah (*In memorian*), em nome de todos os meus familiares que sempre acreditaram no meu potencial.

Ao Prof. Dr. Ronaldo Luiz Mincato, antes de tudo amigo, orientador, pela confiança, pelo apoio e por acreditar na realização deste projeto.

Ao Prof. Dr. Marx Leandro Naves Silva, coorientador, pelos conselhos, acolhimento e disponibilidade de orientação.

Aos que me apoiaram nesta caminhada, desde a coleta e análise dos dados até a redação da dissertação: Fabio, Tom, Adnane, Milton, “Pézão”, Dani, Bernardo, Prof. Dr. Vinícius Xavier e Prof. Dr. Thiago de Souza.

Aos técnicos do DCS-UFLA pela atenção e receptividade.

Aos meus amigos de República em Alfenas: Marcelo, Henriqui, Tommy e Nikolas, por todo apoio, aprendizado e amizade ao longo destes anos.

Aos meus amigos de República em Lavras: Filipe, Matheus, Túlio e Tevico, pela acolhida e pela amizade nestes últimos dois anos.

À minha namorada, Fernanda, pelo apoio, pelo companheirismo, pela confiança e pelo incentivo para a conclusão de mais esta etapa.

## RESUMO

O monitoramento de coberturas vegetais a partir de aeronaves pilotadas remotamente cresceu nos últimos anos. Isso, devido ao aumento das pressões antrópicas nos ecossistemas. O uso dos índices de vegetação combinados a esta tecnologia têm mostrado resultados promissores na redução de custos e na obtenção de produtos elevada resolução espacial e temporal. Assim, a partir da correlação entre a umidade do solo e a dinâmica da vegetação, este estudo teve como objetivo avaliar o desempenho de um veículo aéreo não tripulado multirrotor (Phantom 3 - Professional) na compreensão do comportamento sazonal de cinco coberturas: *Coffea* spp, *Eucalyptus* spp., *Pinus* spp. e dois fragmentos da Floresta Estacional Semidecidual de Montana. Para tanto, foram utilizados três índices de vegetação (*Excess Green*, *Excess Red minus Green* e *Normalized Difference Vegetation Index*), coletas *in situ* de amostras superficiais do solo e dados meteorológicos. As melhores correlações a partir dos índices foram obtidas no cafeeiro, entretanto, os ortomosaicos também forneceram resultados relevantes para o entendimento da dinâmica dos remanescentes florestais. Os índices *Excess Green* ( $p = 0,96$ ) e *Excess red minus Green* ( $p = 0,94$ ) apresentaram a maior correlação em *Coffea* spp., enquanto o *Normalized Difference Vegetation Index* foi o de melhor correlação para estudo da Matinha ( $p = 0,90$ ) e do Cerradinho ( $p = 0,81$ ). Os povoamentos de *Pinus* spp. e *Eucalyptus* spp. não foram monitorados pelo veículo aéreo não tripulado, devido à homogeneidade desses estandes, mas os testes são relevantes para pesquisas futuras com o objetivo de mapeamento tais coberturas.

**Palavras chaves:** Fotogrametria, Índices de vegetação, Ecossistemas, Conservação

## ABSTRACT

Coverage monitoring with remotely piloted aircraft has grown in recent years. This, due to increasing anthropogenic pressures on ecosystems. The use of vegetation index combined with this technology has shown promising results in reducing costs and obtaining some high-resolution spatial-temporal products. Thus, from the correlation between soil moisture and vegetation dynamics, this study aimed to assess the performance of a multicopter UAV (Phantom 3 -Professional) in understanding the seasonal behavior of five covers: *Coffea* spp, *Eucalyptus* spp., *Pinus* spp. and two fragments of Montana Semideciduous Forest. For this purpose, we used three vegetation index (Excess green, Excess Red minus Green and NDVI), collecting in situ of soil surface samples and weather variables. The coffee was the best response area from the indexes, however, orthomosaics also provided relevant results for understanding the forest remnants dynamics. The indexes Excess Green ( $p = 0.96$ ) and Excess Red minus Green ( $p = 0.94$ ) had the highest correlation in *Coffea* spp., while the NDVI was the best to study Matinha ( $p = 0.90$ ) and Cerradinho ( $p = 0.81$ ). The *Pinus* spp. and *Eucalyptus* spp. areas were not monitored by the UAV, due to the homogeneity of these stands, but the tests were relevant for future research aimed at mapping such covers.

**Key words:** Photogrammetry, Vegetation indexes, Ecosystems, Conservation

## LISTA DE ABREVIATURAS E SIGLAS

<b>ACP</b>	Análise por componentes principais
<b>ANAC</b>	Agência Nacional de Aviação Civil
<b>ANATEL</b>	Agência Nacional de Telecomunicações
<b>ASAP</b>	Programa Austríaco de Aplicações Espaciais
<b>BVLOS</b>	<i>Beyond Visual Line of Sight</i>
<b>CAA-UK</b>	<i>Civil Aviation Authority-United Kingdom</i>
<b>CASA</b>	<i>Civil Aviation Safety Authority</i>
<b>CAVE</b>	Certificado de Autorização de Voo Experimental
<b>CBERS</b>	<i>China-Brasil Earth Resources Satellite</i>
<b>CTA</b>	Centro de Tecnologia Aeroespacial
<b>CTFS-ForestGEO</b>	<i>Center for Tropical Forest Science and Forest Global Earth Observatory</i>
<b>DCS</b>	Departamento de Ciências do Solo
<b>DECEA</b>	Departamento de Controle do Espaço Aéreo
<b>DGAC</b>	<i>Dirección General de Aeronautica Civil</i>
<b>DIAM</b>	Declaração de Inspeção Anual de Manutenção
<b>EASA</b>	<i>European Safety Aviation Authority</i>
<b>ERTS-1</b>	<i>Earth Resources Technology Satellite 1</i>
<b>ESA</b>	<i>European Space Agency</i>
<b>EUROCONTROL</b>	<i>European Organization for the Safety of Air Navigation</i>
<b>EVI</b>	<i>Enhanced Vegetation Index</i>
<b>EVLOS</b>	<i>Extended Visual Line of Sight</i>
<b>FAA</b>	<i>Federal Aviation Administration</i>
<b>GPS</b>	<i>Global Positioning System</i>
<b>HRV</b>	<i>High Resolution Visible</i>
<b>IAF</b>	Índice de área foliar
<b>IR</b>	Infravermelha
<b>JAA</b>	<i>Joint Aviation Authorities</i>
<b>MDA</b>	Diminuição Média de Precisão
<b>MDE</b>	Modelos digitais de elevação
<b>MDS</b>	Modelos digitais de superfície
<b>MLIT</b>	<i>Ministry of Land, Infrastructure, Transport and Tourism</i>
<b>MSS</b>	<i>Multispectral Scanner System</i>

<b>NASA</b>	<i>National Aeronautics and Space Administration</i>
<b>NDVI</b>	<i>Normalized Difference Vegetation Index</i>
<b>NIR</b>	<i>Near infrared</i>
<b>NOTAM</b>	<i>Notice to airmen</i>
<b>OACI</b>	Organização da Aviação Civil Internacional
<b>PDI</b>	Processamento digital de imagens
<b>PMD</b>	Peso médio de decolagem
<b>RAINFOR</b>	<i>Amazon Forest Inventory Network</i>
<b>RBAC-E</b>	Regulamento Brasileiro de Aviação Civil Especial
<b>REM</b>	Radiação eletromagnética
<b>RFA</b>	Radiação fotossinteticamente ativa
<b>RPAs</b>	<i>Remotely piloted aircraft</i>
<b>SACAA</b>	<i>South Africa Civil Aviation Authority</i>
<b>SIFT</b>	<i>Scale Invariant Feature Transform</i>
<b>SIG</b>	Sistemas de Informação Geográfica
<b>SISANT</b>	Sistema de Aeronaves não Tripuladas
<b>SPOT</b>	<i>Satellite Pour l'Observation de la Terre</i>
<b>SR</b>	Sensoriamento Remoto
<b>SUA</b>	<i>Small Unmanned Aircraft</i>
<b>SURF</b>	<i>Speeded UP Robust Features</i>
<b>SVM</b>	<i>Support Vector Machine</i>
<b>UAS</b>	<i>Unmanned Aircraft Systems</i>
<b>UFLA</b>	Universidade Federal de Lavras
<b>UNIFAL-MG</b>	Universidade Federal de Alfenas
<b>UV</b>	Radiação ultravioleta
<b>VANTs</b>	Veículos aéreos não tripulados
<b>VARI</b>	<i>Visible Atmospherically Resistant Index</i>
<b>VLOS</b>	<i>Visual Line of Sight</i>
<b>WDRVI</b>	<i>Wide Dynamic Range Vegetation Index</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>9</b>
<b>2</b>	<b>REVISÃO DE LITERATURA.....</b>	<b>12</b>
2.1	SENSORIAMENTO REMOTO.....	12
2.1.1	<b>Radiação Eletromagnética .....</b>	<b>14</b>
2.1.2	<b>Histórico.....</b>	<b>Error! Bookmark not defined.</b>
2.2	FOTOGRAMETRIA DIGITAL .....	20
2.2.1	<b>Histórico.....</b>	<b>21</b>
2.2.2	<b>Parâmetros de Obtenção de Imagens .....</b>	<b>21</b>
2.3	PROCESSAMENTO DIGITAL DE IMAGENS. <b>ERROR! BOOKMARK NOT DEFINED.</b>	
2.3.1	<b>Segmentação .....</b>	<b>Error! Bookmark not defined.</b>
2.3.2	<b>Classificação .....</b>	<b>Error! Bookmark not defined.</b>
2.4	VEÍCULOS AÉREOS NÃO TRIPULADOS.....	15
2.4.1	<b>Panorama internacional de regulamentação dos VANTs .....</b>	<b>18</b>
2.5	VEGETAÇÃO.....	28
2.5.1	<b>Radiação e Clima.....</b>	<b>29</b>
2.5.2	<b>Fotossíntese.....</b>	<b>30</b>
2.5.3	<b>Trocas Gasosas .....</b>	<b>32</b>
2.5.4	<b>Sensoriamento Remoto da Vegetação.....</b>	<b>33</b>
2.6	ÍNDICES DE VEGETAÇÃO .....	<b>ERROR! BOOKMARK NOT DEFINED.</b>
<b>3</b>	<b>OBJETIVO .....</b>	<b>35</b>
<b>4</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>36</b>
4.1	ÁREA DE ESTUDO .....	36
4.2	MÉTODOS.....	39
<b>5</b>	<b>RESULTADOS .....</b>	<b>43</b>
<b>6</b>	<b>DISCUSSÃO .....</b>	<b>53</b>
<b>7</b>	<b>CONCLUSÕES.....</b>	<b>66</b>
	<b>REFERÊNCIAS.....</b>	<b>67</b>

## 1 INTRODUÇÃO

As técnicas de processamento de imagens associadas à Sistemas de Informação Geográfica (SIG) cresceram muito nos últimos anos e são amplamente utilizadas em pesquisas de diversas áreas do conhecimento, como em atividades civis de planejamento ambiental, que fortalecem as tomadas de decisões em escalas variadas, com economia de custos e de tempo. Atualmente, com as preocupações acerca da conservação dos recursos naturais e da segurança alimentar, estas ferramentas se tornaram uma alternativa eficaz devido ao caráter imperioso que tais questões envolvem (DONNER; KUCHARIK, 2008; KHANAL, FULTON, SHEARER, 2017). Diante disso, o setor das geotecnologias está em franca evolução, com o desenvolvimento e a integração de tecnologias que atendam aos mercados com produtos de melhor qualidade (WANG et al., 2011; ZHANG et al. 2015).

As plataformas convencionais do sensoriamento remoto, como os satélites e os aviões, ainda representam uma alternativa de “alto custo” para os estudos ambientais, o que impede a maior utilização dessas técnicas na avaliação de mudanças da cobertura florestal, na densidade de árvores, distribuição de espécies, altura do dossel e estoques de carbono, por exemplo (SIMARD et al., 2011; HANSEN et al., 2013; CROWTHER et al., 2015; NIJLAND et al., 2015; ZHANG et al., 2016). Neste cenário, os Veículos Aéreos Não Tripulados (VANTs) se consolidam como alternativa efetiva para coleta de dados automáticos de alta resolução espacial. Os VANTs possuem um longo histórico de aplicações militares, mas só ganharam maior visibilidade devido aos recentes avanços do setor, que com os seus diversos tipos e modelos atendem aos requisitos de muitos mercados, em especial, a agricultura de precisão (RASI, 2008; KOH; WICH, 2012; JORGE; BRANDÃO; INAMASU, 2014). Apresentaram também resultados satisfatórios no monitoramento de fauna e de populações de plantas (JONES et al., 2006; CHABOT; BIRD, 2012; VERMEULEN et al., 2013), no mapeamento de mudanças de usos do solo (RANGO et al., 2009), no monitoramento de incêndios (MERINO et al., 2012), de erosão (OLTMANN et al., 2012; JAMES; QUINTON, 2014; CHIACCHIO et al., 2016), na mineração (GAO et al., 2017; SUH et al., 2017; WELLS et al., 2017), na arqueologia (MESAS-CARRASCOSA et al., 2016) e na prevenção e avaliação de desastres naturais (ZHANG et al., 2017).

As vantagens dos VANTs são a flexibilidade e o baixo custo em relação as técnicas tradicionais. Outros atrativos são a segurança durante as operações, já que os riscos de acidentes com a tripulação e terceiros são reduzidos pela pilotagem remota destas plataformas; a

estabilidade e a precisão, pois apresentam a capacidade de realizar voos próximos ao solo, com resolução espacial em escala micrométrica (HORCHER; VISSER, 2004; WHITEHEAD et al., 2014). Em contrapartida, mesmo com os benefícios apresentados, a inserção destas aeronaves no espaço aéreo civil ainda não é uma unanimidade, devido a ausência de uma normatização internacional que garanta a utilização das mesmas e preservação dos direitos dos cidadãos. Porém, no Brasil, desde 2017, está regulamentada a aeronavegabilidade dessas plataformas, devido à grande ampliação do uso desses equipamentos e do número de usuários (NACKAERTS et al., 2010; ANAC, 2015).

Nas pesquisas de coberturas vegetais, os destaques da aplicação dos VANTs são a avaliação da estrutura das vegetações, como, por exemplo, a identificação e monitoramento de clareiras naturais e o monitoramento da produção agrícola por índices de vegetação (FERRIER; DRIELSMA, 2010; RAYMOND; BROWN; ROBINSON, 2011; FRANKE; KEUCK; SIEGERT, 2012; JORGE; BRANDÃO; INAMASU, 2014).

Os índices de vegetação são caracterizados pela combinação aritmética das diferentes bandas dos sensores para extrair razões de reflectância da vegetação, cujos valores permitem obter dados de biomassa, de índice de área foliar (IAF) e de sanidade vegetal, entre outros. Assim, é possível detectar pragas, plantas com estresse hídrico e áreas que necessitam de manejos específicos, para o controle das produções e a otimização das colheitas, pois contribuem com a conservação do solo e o uso sustentável da água, essenciais à vida e aos ecossistemas (CROFT; CHEN; ZHANG, 2014; JONES et al., 2017). Existem diversos índices de vegetação, com ampla abrangência espectral, que utilizam desde as bandas do visível (RGB, do inglês *Red, Green e Blue*), até o infravermelho. Os índices mais empregados são o NDVI (*Normalized Difference Vegetation Index*), o EVI (*Enhanced Vegetation Index*), o VARI (*Visible Atmosphericly Resistant Index*) e o WDRVI (*Wide Dynamic Range Vegetation Index*), que representam operações do infravermelho e apenas as bandas do visível, respectivamente (YANG et al., 2017; BARATI et al., 2011; TORRES-SANCHÉZ et al., 2014).

Os objetivos deste estudo foram avaliar o desempenho de um VANT, embarcado com sensores não paramétricos, no estudo sazonal de cinco coberturas vegetais: (1) *Coffea* spp., (2) povoamento de *Pinus* spp., (3) povoamento de *Eucalyptus* spp. e (4,5) fragmentos de mata nativa, no Município de Lavras, sul de Minas Gerais, em 2017 e 2018. Para tanto, foram coletadas amostras da camada superficial dos solos destes locais, que foram analisadas para textura simples, matéria orgânica e umidade, a fim de subsidiar, junto aos dados climáticos, a interpretação dos valores obtidos a partir dos índices de vegetação. Para aferir o desempenho

do VANT nesta proposta de estudo, os resultados foram confrontados com os do satélite Seninel-2.

## 2 REVISÃO DE LITERATURA

### 2.1 SENSORIAMENTO REMOTO

Sensoriamento Remoto (SR) é considerado por muitos como ciência e é um termo que foi cunhado no início da década de 1960 por Evelyn L. Pruitt e colaboradores, sendo caracterizado pela coleta de informações da superfície terrestre e suas diversas manifestações, sem que haja contato físico com os alvos de interesse (FLORENZANO, 2002; MENESES; ALMEIDA, 2012). Desta forma, o SR representa um conjunto de tecnologias com a finalidade de capturar, transmitir e processar os dados da superfície terrestre a partir da sua interação com a radiação eletromagnética (REM), registrando imagens digitais e outros tipos de dados resultantes da reflexão ou emissão de energia pela superfície (JENSEN, 2010).

**2.1.1 Histórico:** o termo SR surgiu somente no Século XX, mas a sua origem, assim como as teorias e técnicas indispensáveis ao seu desenvolvimento, ocorreu anteriormente. Durante a Guerra Civil americana, por exemplo, no final do Século XVIII, balões a gás já eram adotados para o reconhecimento das tropas inimigas, o que já demonstrava o estreito laço entre os avanços militares e a fotografia aérea para o aparecimento do SR (FLORENZANO, 2002). Posteriormente, na I e II Guerras Mundiais, com o surgimento do avião e o desenvolvimento de novas tecnologias militares, como os radares, os Sistemas de Posicionamento Global (sigla GPS, do inglês *Global Positioning System*) e os sistemas de comunicações, o SR se consolidou como uma das mais bem-sucedidas tecnologias na coleta automática de dados (NOVO, 2010). Tal fato justifica a acelerada evolução tecnológica e espacial pós segunda Guerra Mundial, que culminou no surgimento dos diversos sensores de alta resolução e lançamento das primeiras plataformas artificiais, que foram os satélites meteorológicos, responsáveis por fornecer as primeiras imagens das feições da Terra. O pioneiro foi o TIROS-1 (*Television IR Operational Satellite*), que foi lançado em 1960 pelos Estados Unidos (LILLESAND; KIEFER; CHIPMAN, 2008).

Nos anos seguintes, os investimentos permaneceram e foram decisivos para que outras plataformas artificiais com objetivos distintos, como o de enviar o homem ao espaço por satélites tripulados, por exemplo, fossem alcançados. Isto viabilizou o registro das primeiras fotos por câmeras fotográficas manuais, que foram obtidas pelas missões dos programas Mercury, Gemini e Apollo. Já no final da década de 1960, o interesse pelas coletas fotográficas diminuiu, e as duas últimas plataformas artificiais com esta finalidade foram desenvolvidas e

lançadas, o satélite americano Corona e o soviético Zenit, (MENESES; ALMEIDA, 2012). Em 1972, o primeiro satélite de recursos terrestres foi desenvolvido pela *National Aeronautics and Space Administration* (NASA) e lançado pelos norte-americanos, o *Earth Resources Technology Satellite 1* (ERTS-1), mais tarde denominado Landsat – 1, que foi o marco inicial da grande revolução ocorrida no SR na década de 1970. O sensor imageador desse satélite, o *Multispectral Scanner System* (MSS), possibilitava a coleta simultânea de quatro imagens na faixa do espectro visível, do infravermelho próximo e uma no termal que cobre uma faixa no terreno de 185 km de largura, com resolução espacial de 76 m, a cada 18 dias (NOVO, 2010). O último exemplar dessa série colocado em órbita foi o Landsat 8, em 2013; porém seu sucessor, o Landsat 9, já possui lançamento previsto para dezembro de 2020, que manterá a grande capacidade de imageamento de seus satélites, com cerca de 740 cenas por dia (LANDSAT, 2017).

Outros projetos, europeus, canadenses, asiáticos e sul-americanos, surgiram depois de 1972, como o *Satellite Pour l'Observation de la Terre* (SPOT), em 1978 pela França em parceria com a Suécia e Bélgica, que era embarcado com dois sensores *High Resolution Visible* (HRV) que permitiam a varredura de faixas de até 60 km por sensor, a cada 26 dias (FERREIRA; MACHADO; ANDRADE, 2000). O último satélite do programa foi o SPOT 6, em 2012 (CNES, 2017).

No Brasil, o primeiro satélite foi lançado em 1999, onze anos após o tratado de cooperação com a China, que promoveu o desenvolvimento de plataformas para observação da Terra, o programa chamado *China – Brasil Earth Resources Satellite* (CBERS) (NOVO, 2010). O quinto satélite desta série está em órbita há três anos e conjuntamente já distribuíram gratuitamente quase 90 mil imagens com resolução espacial de 20 m, que auxiliam na gestão e nas pesquisas do território brasileiro (INPE, 2017).

No mesmo ano do primeiro satélite sino-brasileiro, outra plataforma também se destacou pela coleta de dados espaciais em alta resolução, o satélite IKONOS II, da iniciativa privada (*Space Imaging*) que fornecia imagens de alta resolução espacial e temporal, pois além de discriminar objetos de 1 m<sup>2</sup> no terreno, efetuava visadas no sentido de sua órbita e perpendicularmente a ela, ou seja, aumentava o número de revisitas (OLIVEIRA; FERREIRA, 2005).

Atualmente, há em órbita dezenas de sensores que coletam os dados da superfície terrestre em diversas faixas espectrais e resoluções espaciais e temporais. O projeto europeu Sentinel, embarcado com sensores hiperspectrais e radares, por exemplo, está sendo desenvolvido pela *European Space Agency* (ESA) para atendimento ao programa *Copernicus*

(*Observing the Earth*), já possui 9 missões de imageamento da Terra desde 2014 (ESA, 2017). O mesmo, coleta dados terrestres, oceânicos e atmosféricos, com resolução temporal de, em média, 6 dias, e resolução espacial de até 10 m (CNES, 2017), sendo um importante aliado às aplicações do SR, que requerem a maior frequência de revisitas e resolução espacial compatível com as diversas aplicações desta tecnologia (WANG, 2011).

Apesar dos satélites serem o grande expoente do SR, no decorrer de toda a evolução desta tecnologia os aviões também foram essenciais ao desenvolvimento do setor, pois ofereceram alternativas à altura das plataformas orbitais (MENESES; ALMEIDA, 2012); porém, não conseguiram minimizar a resolução temporal e as interferências climáticas dos registros, que são fatores que aliados aos seus elevados custos, não permitiram a essas plataformas ganharem maior projeção no SR. Desta forma, outra opção que está se firmando no setor são os Veículos Aéreos Não Tripulados (VANTs), que atendem aos mais diversos requisitos de estudo e permitem sobrevoar as áreas de interesse em baixas altitudes, diferenciais que facilitaram a coleta de dados em alta resolução e baixos custos (NEWCOME, 2004).

**2.1.2 Radiação Eletromagnética:** a Radiação Eletromagnética (REM), por sua vez, é a forma de energia que se move à velocidade da luz ( $300.000 \text{ km.s}^{-1}$ ), em ondas ou partículas transmitidas no meio e no vácuo (LIU, 2015). As fontes deste tipo de energia podem ser naturais, como o sol, ou artificiais, como o *flash* das câmeras fotográficas, por exemplo. No caso do SR, a principal fonte desta radiação é a natural, que interage com o sistema terrestre a partir de uma faixa de ondas eletromagnéticas, resultando em fenômenos que são objeto de investigação pelo SR (LAMPARELLI; ROCHA; BORGHI, 2001). Apenas 47% da radiação solar chegam ao solo, uma vez que os comprimentos de onda mais curtos são absorvidos na alta atmosfera pelo ozônio e oxigênio presentes no ar (LARCHER, 2000), portanto, os comprimentos de onda de interesse do SR se restringem à faixa de 0,3 a 15  $\mu\text{m}$ , que é conhecida como o espectro ótico, que abrange a região do visível (0,4 a 0,7  $\mu\text{m}$ ) e do infravermelho (0,7  $\mu\text{m}$  a 15  $\mu\text{m}$ ) (SILVA, 2013) (Figura 1).

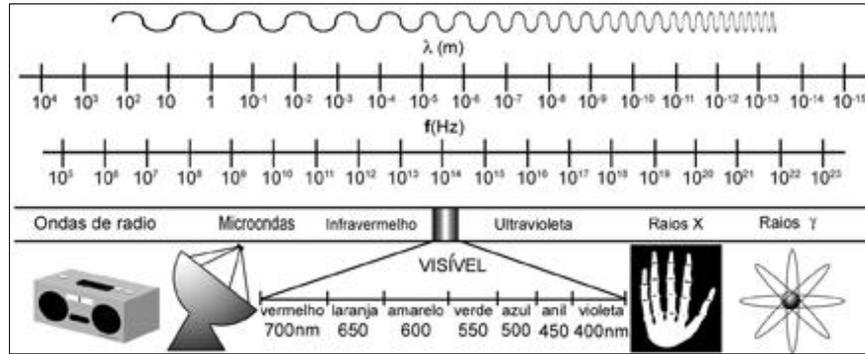


Figura 1 - Regiões do espectro eletromagnético com destaque às áreas de interesse do SR.  
Fonte: <http://profs.ccems.pt/PauloPortugal/CHYMICA/REM/REM.html>

## 2.2 VEÍCULOS AÉREOS NÃO TRIPULADOS

Os Veículos Aéreos Não Tripulados (VANTs) surgiram junto com o GPS para fins militares e, desde então, acompanham a evolução das demais tecnologias do setor (NEWCOME, 2004). Atualmente, representam uma das principais plataformas do SR, com diversos modelos e tamanhos, que são classificados de acordo com a capacidade de carga, o sistema de controle e a autonomia de voo, por exemplo (PANEQUE-GÁLVEZ et al., 2014). A classificação básica dessas aeronaves é entre asa fixa, multirrotor e híbridos, que são distintas não só em relação ao modelo, mas também em autonomia de voo e sensores a serem embarcados (WATTS et al., 2012). No Brasil, a Agência Nacional de Aviação Civil (ANAC) classifica os VANTs de acordo com o peso médio de decolagem (PMD), que é o parâmetro mais utilizado (VALAVANIS; VACHTSEVANOS, 2015). As três classes são: (1)  $> 150$  kg, (2) de 25 a 150 kg e (3)  $\leq 25$  kg (ANAC, 2015) (Figura 3).



Figura 2 - Tipos e modelos de VANT segundo classificação da ANAC: (a) categoria 3, (b) categoria 2 e (c) categoria 1.

Fonte: Departamento de Controle do Espaço Aéreo / Comando da Aeronáutica (2015).

O sucesso dos VANTs no SR se deve principalmente à coleta de dados com alta precisão em curto espaço de tempo, que foram os atributos que os tornaram vantajosos em relação aos satélites orbitais (SILVA et al., 2015; RANGO et al., 2009). Outras vantagens são: (a) obtenção

de imagens em escala micrométrica, (b) a insensibilidade ao efeito das nuvens, (c) o potencial na geração dos modelos 3D, (d) a facilidade de acesso a regiões difíceis, (e) e ainda contar com o baixo custo operacional e de obtenção de imagens, que são benefícios que dinamizaram o estudo da superfície terrestre (ARAUS; CAIRNS, 2014; HORCHER; VISSER, 2004).

Os VANTs apresentam também diversas desvantagens, segundo Getzin (2014), como: (a) a possibilidade de colisões; (b) a baixa resolução espectral, embora existam opções de sensores multiespectrais; (c) o desempenho radiométrico e geométrico pouco eficiente, pois depende da altura do voo a eficiência do sensor em discriminar a intensidade de energia dos alvos e (d) a sensibilidade meteorológica, que pode inviabilizar os voos em dias chuvosos ou nublados e reduzir a autonomia da bateria nos dias quentes.

Embora os VANTs sejam ferramentas de elevada aptidão à coleta de dados de alta resolução espacial, os impactos sociais, positivos e negativos, da utilização dessas plataformas também devem ser considerados, pois são fatores que podem influenciar a efetividade dos mesmos (SANDBROOK, 2015). Dentre os impactos sociais positivos, a aplicação dos VANTs para as finalidades de segurança e saúde pública, bem-estar, como o *hobby* e o combate à caça ilegal são os principais destaques (FINN; WRIGHT, 2012; PANEQUE-GALVEZ et al., 2014). Outra vantagem é de representarem uma alternativa mais segura e de maior precisão do que a utilização de aeronaves pilotadas para tais finalidades, com minimização dos danos à população em casos de problemas na execução dos voos (LEE et al., 2013). Em contrapartida, os impactos sociais negativos são aqueles que infringem os direitos individuais dos cidadãos, que são implicações éticas que dificultam a regulamentação e maior aceitação pela população da utilização dos VANTs (KREPS; KAAG, 2012). Isto, pois a variedade de modelos pequenos e silenciosos são facilitadores de práticas que interferem não só com a privacidade dos cidadãos (LUO et al., 2014), mas afetam também outros direitos humanos como o de liberdade de associação, por exemplo, que ocorre nos casos de investigações sem o conhecimento prévio dos investigados (SNITCH, 2014; MULERO-PAZMANI et al., 2014). Portanto, é necessária cautela diante das individualidades e da forma de inserção dessas tecnologias, para que os benefícios oferecidos não sejam prejudicados pelo mau uso dessas plataformas (DUFF, 2014; SCHIFFMAN, 2014).

O crescimento da tecnologia dos VANTs, no século XXI, se deve à intensificação da sua utilização como ferramenta de monitoramento, que foi um dos interesses facilitados pelos recentes avanços computacionais, pelo desenvolvimento de *softwares* mais robustos, de materiais mais leves, de sensores específicos e de sistemas de navegação global. Cerca de 40 países investem no desenvolvimento de novas plataformas e aplicações para os VANTs. Os

principais líderes são os Estados Unidos, o Japão e a Coreia do Sul. Porém, outros países como a França, a Austrália, a Inglaterra e a Itália, também estão empenhando recursos no desenvolvimento destas tecnologias (JORGE; BRANDÃO; INAMASU, 2014; GETZIN, 2012).

No Brasil, especificamente, os primeiros testes envolvendo aplicação dos VANTs ocorreram a partir de 1980, no Centro de Tecnologia Aeroespacial (CTA) Acauã, que foi uma iniciativa concluída em 2007 e que visava incentivar o desenvolvimento destas tecnologias no país. Desde então, outros projetos, como o AURORA e o ARARA, por exemplo, surgiram com a finalidade de fortalecer as aplicações agrícolas e civis dos VANTs, contudo, até os dias atuais o setor está nas fases iniciais de aplicação, com poucas as pesquisas brasileiras que utilizam essa ferramenta (MEDEIROS, 2007; JORGE, 2001; JORGE; BRANDÃO; INAMASU, 2014).

No cenário internacional, os VANTs são cada vez mais utilizados nos estudos de coberturas vegetais e de monitoramento dos recursos naturais. A agricultura de precisão é uma das aplicações mais positivamente impactadas. Segundo Aguërra et al. (2011), devido à grande aplicação nas atividades agrícolas, diversos resultados promissores já foram obtidos no monitoramento e mapeamento da produção de cultivares como a cebola (CÓRCOLES et al., 2013), o tomate (SENTHILNATH, 2016), o arroz (SWAIN et al., 2010), a viticultura (TURNER et al., 2011), batata (SANKARAN et al., 2011, 2015), algodão (ZARCO-TEJADA et al., 2005), trigo (RISSINI; KAWAKAMI; GENUÍ, 2014) e pomares cítricos (EHSANI et al., 2012), por exemplo, além da sua utilização na detecção e no combate às espécies invasoras. Devido à área de cobertura dessas plataformas ainda ser reduzida, favorece a aplicação na coleta de dados de elevada precisão, provendo dados fitossanitários e de estado nutricional das plantas em escala de detalhe, que são parâmetros auxiliares do manejo apropriado de cada produção e de previsão de colheitas em escalas regionais (SWAIN; ZAMAN, 2012; TORRÈS SANCHEZ et al., 2014).

Estudos e levantamentos de monitoramento de florestas nativas (GETZIN, 2014), mangues (TIAN et al., 2017) e silvicultura (WALLACE, 2016) também apresentaram resultados promissores, que facilitam a conservação de áreas prioritárias, como o Cerrado brasileiro, por exemplo, que é um *hotspot* internacional e se encontra em franco processo de degradação e de perda de diversidade biológica (VIEIRA et al., 2017). Assim, os VANTs são importantes para o monitoramento e diagnóstico de problemas ambientais, que servem de suporte para a formulação e adoção de políticas de manutenção dessas áreas e preservação dos diversos serviços ecossistêmicos prestados (STRASSBURG et al., 2017; ZHANG et al., 2016).

Considerando que, segundo a FAO (2017), o desmatamento persiste como uma tendência dominante, já que a superfície florestada mundial diminuiu 130 milhões de hectares nos últimos 25 anos, não utilizar o potencial do sensoriamento remoto como alternativa de monitoramento e manutenção dessas áreas é um erro, já que poderia colaborar à redução de uma taxa líquida de perda de 3 milhões de hectares anuais. Desta forma, os VANTs ainda podem ser uma ferramenta auxiliar fundamental para diversos programas de monitoramento e conservação da biodiversidade, como o *Amazon Forest Inventory Network* (RAINFOR) e o *Center for Tropical Forest Science and Forest Global Earth Observatory* (CTFS-ForestGEO), por fornecer informações de maior resolução espacial e de frequência temporal condizente às necessidades que as pesquisas requerem (RUFINO; MOCCIA, 2013; ANDERSON-TEIXEIRA et al., 2015).

**2.2.1 Panorama internacional de regulamentação dos VANTs:** a partir de 2013, os esforços para a regulamentação dos VANTs no espaço aéreo civil internacional se intensificaram. O início foi em 2002, quando a *Joint Aviation Authorities* (JAA) (sucedida pela *European Safety Aviation Authority* (EASA) em 2008) e a *European Organization for the Safety of Air Navigation* (EUROCONTROL) estimularam o debate de orientações para a integração dos VANTs no espaço aéreo europeu, na tentativa de preservar a expansão de mercado destas plataformas e garantir que as ameaças aos cidadãos e aos demais objetos do espaço aéreo fossem minimizadas (EASA, 2016). No entanto, tais atividades não impediram o surgimento de barreiras ao desenvolvimento tecnológico, científico e social oferecido por estes dispositivos, visto que um dos grandes problemas deste processo ainda é o atraso da formulação de políticas harmoniosas em relação à tecnologia. Alguns exemplos disso são a complexidade das plataformas e das suas capacidades operacionais, além das ameaças potenciais, como o emprego no transporte de armas aos presídios, pirataria ou ainda em tentativas de assassinato, como no caso da chanceler alemã Angela Merkel, em setembro de 2013 (SCHREIBER; OSTIARI, 2014; STÖCKER et al., 2017).

Assim, devido à popularização emergente dessa tecnologia, metas de curto prazo e grupos de trabalho para integração dos VANTs no espaço aéreo civil surgiram em diversas regiões do mundo (SCHREIBER; OSTIARI, 2014). Neste processo, a Circular ICAO 328 – NA/190, *Unmanned Aircraft Systems* (UAS) emitida pela Organização da Aviação Civil Internacional (OACI) foi significativa, na orientação e emissão das regulamentações e no direcionamento das formas de registro e certificação das aeronaves remotamente pilotadas (RPAs – da sigla em inglês *remotely piloted aircraft* adotada pela OACI) e seus respectivos

pilotos em todo o mundo. Tal fato, justifica a semelhança entre as atuais regulamentações, principalmente as iniciadas a partir de 2015. Todavia a heterogeneidade delas ainda persiste como característica marcante do cenário atual, no qual, cerca de 65 países possuem legislações específicas para os RPAs (TMLAW, 2018). Mas muitos países europeus e africanos, por exemplo, ou ainda não implementaram nenhuma legislação ou proibiram os projetos de inserção das aeronaves não tripuladas no espaço aéreo, mesmo com o aumento das pressões mundiais na última década. Um destes exemplos é a Espanha, que em 2014 suspendeu a utilização dos VANTs até que uma regulamentação apropriada fosse desenvolvida. Enquanto isso, decretos provisórios como o Real 08/2014 permitiram que aeronaves com peso abaixo de 150 kg fossem empregadas desde que em áreas despovoadas e com registro do equipamento e dos pilotos junto a Agência Estadual de Segurança da Aviação (ESPAÑA, 2014). Em contrapartida, outros continentes, como a América e a Oceania se destacam pela quantidade de adeptos e o pioneirismo legislativo, respectivamente.

À vista disso, a operação dos RPAs, no geral, é baseada em critérios visuais que buscam preservar a segurança de terceiros de três formas: (a) Linha de Visada Visual (VLOS – *Visual Line of Sight*), onde o piloto mantém contato visual constante com o equipamento; (b) em Linha de Visada Visual Estendida (EVLOS – *Extended Visual Line of Sight*), que requer o auxílio de um observador para que o contato seja mantido durante toda a execução do voo e (c) Além da Linha de Visada Visual (BVLOS – *Beyond Visual Line of Sight*), em que os critérios anteriores não são abordados e o contato com a aeronave é dificultado até com binóculos, por exemplo. A classificação destas operações também é dependente do propósito de utilização do RPA. Portanto, para a execução dos voos é necessário o atendimento de critérios básicos que levam em consideração não só o peso e a funcionalidade das plataformas, mas que considerem o objetivo, o planejamento da missão e também o grau de risco aos cidadãos (ANAC, 2015; OACI, 2015)

No Brasil, com a regulamentação vigente, mais de 41 mil aeronaves já foram registradas, com aproximadamente 65% delas destinadas a recreação e 35% para usos profissionais. Estes números refletem o esforço do estado brasileiro na expansão do setor, implementando práticas internacionais já empregadas com sucesso em diversos países como Irlanda, Rússia, China e Turquia (ANAC, 2018). O sistema de integração das RPAs no país foi iniciado em 2015 a partir da proposta ICA 100-40, que deu início ao debate sobre o assunto e foi a base para o desenvolvimento da resolução RBAC-E nº 94 (Regulamento Brasileiro de Aviação Civil Especial) que entrou em vigor em maio de 2017. Esta norma, é baseada no artigo 8º da

Convenção sobre Aviação Civil Internacional e foi expedida pela Agência Nacional de Telecomunicações (ANATEL), Departamento de Controle do Espaço Aéreo (DECEA) e ANAC, que regulam a utilização deste modal no país. Basicamente, esta norma determina como exigências a divisão das aeronaves de acordo com o seu peso, os modos operatórios em VLOS, EVLOS e BVLOS e o cadastro das mesmas junto a ANATEL, independente da classificação. As operações realizadas por aeronaves de 250 g até 25 kg e 120 m de altitude, desde que dispostas na linha de visada, não requerem autorização do DECEA, apenas o registro online na plataforma SISANT (Sistema de Aeronaves não Tripuladas) e a idade mínima de 18 anos para o piloto e os seus auxiliares (ANATEL, 2018). Em situações contrárias, são necessários procedimentos distintos, que exigem do piloto a apresentação do Certificado de Autorização de Voo Experimental (CAVE), registro da operação junto ao DECEA, com antecedência mínima de 30 dias para emissão da NOTAM (*Notice to airmen*), um documento indispensável as operações de voo, e também homologação da Declaração de Inspeção Anual de Manutenção (DIAM) junto à ANAC (ANAC, 2015). Todas as operações não autorizadas estão sujeitas a multas que variam de R\$ 3.200 a R\$ 40.000 de acordo com o previsto na Lei 7.565 do Código Brasileiro da Aeronáutica, que visa mitigar iniciativas ilícitas e manter a segurança do espaço aéreo brasileiro por aeronaves tripuladas e não tripuladas.

Diante de tais fatos, é nítida a tendência das aeronaves não tripuladas permanecerem em constante desenvolvimento nos próximos anos, gerando novos empregos, aplicações e dinamizando a economia internacional. Contudo, a fragmentação legislativa e a má utilização destas plataformas oferecem riscos potenciais à sociedade, com capacidade de ocasionar incidentes de grandes proporções que devem ser evitados (SCHREIBER; OSTIARI, 2014; STÖCKER et al., 2017). Portanto, as entidades nacionais e internacionais responsáveis devem continuar os esforços de uniformização da regulamentação e fiscalização destes, investindo não só na conscientização da população e dos usuários, mas também em medidas integrativas do espaço aéreo civil que acompanhem a evolução da tecnologia e agreguem maior número de adeptos, afinal apenas cerca de 32% dos países aderiram a inserção dos VANTs em suas legislações.

### 2.3 FOTOGRAMETRIA

Etimologicamente, a palavra fotogrametria significa medições executadas por fotografias (do grego: *photon* [luz], *graphos* [escrita] e *metron* [medições]). O consenso de

definição do termo foi: a ciência e tecnologia de obtenção de informações confiáveis a partir de imagens (COELHO; BRITO, 2007; WOLF, 2000).

**2.3.1 Histórico:** em 350 a.C., Aristóteles já se referia ao processo de projeção ótica de imagens e muito foi estudado sobre o assunto antes mesmo do surgimento das fotografias, mas em 1859 o primeiro trabalho de mapeamento por fotografias foi apresentado, sendo considerado o marco inicial da fotogrametria (WOLF, 2000). Em 1901, com o surgimento da fotogrametria analógica e a invenção do aparelho estereocomparador, por Pullfrich, houve a primeira revolução do setor, que facilitou o trabalho dos usuários, uma vez que os cálculos matemáticos foram substituídos pelos aparelhos óptico-mecânicos (COELHO; BRITO, 2007). Posteriormente, com a criação dos restituidores analógicos, como o Wild, Zeiss e Kern, por exemplo, as técnicas se estenderam ao mapeamento de superfícies maiores, além de permitirem a visão estereoscópica, ou seja, um par de fotografias da mesma área sendo observadas por dois pontos de vista distintos, produz a sensação de profundidade tridimensional (3D) (OLIVEIRA; FERREIRA, 2005). Desta forma, o setor fotogramétrico foi alavancado, com a necessidade de mão de obra melhor qualificada e surgimento de câmeras métricas cada vez mais específicas, responsáveis por medições precisas.

O período entre 1950 e 1990 foi marcado pela fotogrametria analógica, com o surgimento e suporte dos primeiros computadores que substituíram os cálculos matemáticos necessários, que simplificou o processo e melhorou a qualidade dos produtos, como comprovado em 1957, pelo restituidor analítico do finlandês Uki Helava. Tais restituidores permitiram a fototriangulação de conjuntos de imagens cada vez maiores e também o uso de câmeras comuns não-métricas (COELHO; BRITO, 2007).

Atualmente, a era da fotogrametria digital, é uma inovação que surgiu em 1980 e foi suportada pelos avanços computacionais desde então. As imagens digitais podem ser obtidas de câmeras digitais ou via scanner a partir de imagens analógicas processadas para sua ortorretificação, de maneira similar à fotogrametria analítica. Com o aperfeiçoamento dessa técnica, foi possível a criação de saídas de dados digitais que podem ser exportados em formato compatível com variados programas de geoprocessamento (WOLF, 2000).

Neste cenário, a fotogrametria foi estabelecida como uma das principais técnicas de imageamento terrestre, que visa a reconstituição automatizada do espaço-objeto tridimensional, a partir de espaço-imagem bidimensionais (OLIVEIRA; FERREIRA, 2005).

**2.3.2 Parâmetros de Obtenção Convencional:** a fotogrametria é dividida em terrestre ou estereofotogrametria e aérea ou aerofotogrametria. Em ambas, é recomendado preservar alguns

parâmetros de obtenção das imagens para garantir a qualidade dos produtos finais, como, por exemplo, os estereomodelos na fotogrametria terrestre (OLIVEIRA; FERREIRA, 2005).

Para manipulação das imagens pelos modelos matemáticos de fotogrametria digital deve ser respeitada a sobreposição longitudinal mínima de 60% e lateral de 30%, entre as áreas avaliadas, assim como a obtenção de um par estereoscópico da cena, que são responsáveis pelas injunções e, conseqüentemente, os cálculos e restituições posteriores (Figura 2). Os pontos de controle nas imagens são parâmetros importantes no processo e devem ser previamente identificados ou, mesmo, marcados posteriormente para garantir a qualidade final do produto (ABER et al., 2010).

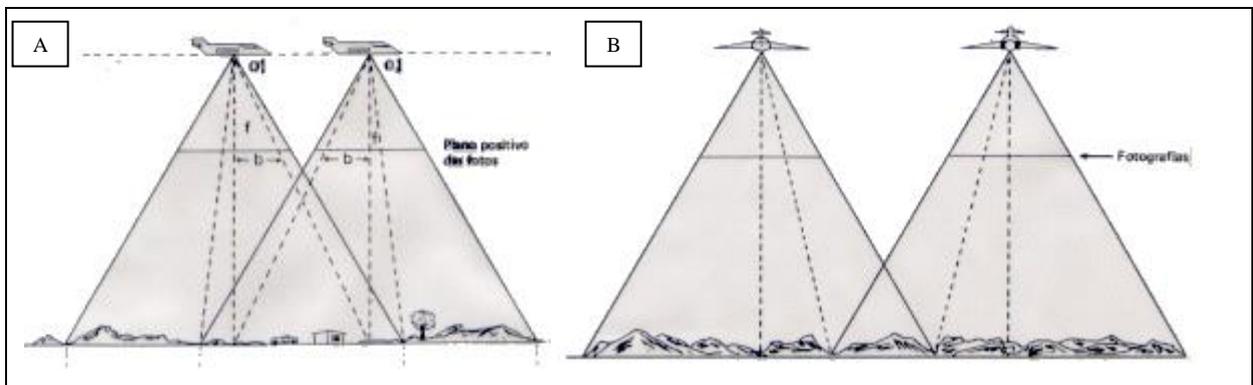


Figura 3 - Recobrimento fotográfico: (A) longitudinal (60%) e (B) recobrimento lateral (30%).  
Fonte: Oliveira; Ferreira (2005)

A aerofotogrametria é o método mais empregado para mapeamentos terrestres, porém, para efeito de correções, as condições em que foram registradas as imagens, como as variações na trajetória, na altura e nos ângulos de voo da aeronave, devem ser consideradas. Isto, pois as alterações na altura do voo, por exemplo, causam distorções nas sobreposições das imagens. Para tanto, é indispensável definir uma margem de erro para o correto processamento dos dados, que são definidos pela distância focal, recobrimento lateral e longitudinal e escala de voo (COELHO; BRITO, 2007; OLIVEIRA; FERREIRA, 2005).

O conhecimento prévio da área de abrangência de cada imagem é essencial, onde a área de cobertura da imagem no terreno (D) pode ser calculada com base na altura da câmara com relação ao solo (H), a distância focal (f) das lentes e o tamanho do sensor (d) (Equação 1) (WOLF, 2000).

$$D = d \cdot \frac{H}{f} \quad (\text{Equação 1})$$

A resolução espacial do aerolevantamento é determinada de acordo com o objetivo do estudo e representa o menor elemento detectável na imagem. Na fotogrametria digital, a resolução espacial é o tamanho de cada pixel no terreno, que é medida em metros por pixel ( $m\text{ px}^{-1}$ ). Desta forma, a resolução espacial ( $Res$ ) pode ser calculada a partir do tamanho de cada fotodetector do sensor ( $T_{\text{detector}}$ ) multiplicado pela altura do voo ( $H$ ) sobre a distância focal ( $f$ ) (Equação 2).

$$Res = T_{\text{detector}} \cdot \frac{H}{f} \quad (\text{Equação 2})$$

No caso dos VANTs, o planejamento de voo é realizado via *Ground Control Station* (GCS), isto é, uma estação de controle em solo que seja compatível à placa controladora da aeronave. Atualmente, existem diversas opções de GCS disponíveis no mercado, inclusive de forma gratuita, como a plataforma *Mission Planner*, por exemplo.

Assim, o planejamento da missão a partir destas plataformas, consiste na delimitação da área de estudo e seleção dos parâmetros de entrada, que por sua vez são as sobreposições frontais e laterais, a velocidade, a altitude de voo e também a lente da câmera utilizada, em que a partir dos mesmo há a determinação do tempo máximo de voo. O mapeamento da área desejada não deve exceder a autonomia do equipamento, sendo uma medida preventiva de segurança contra possíveis acidentes ocasionados pela queda do VANT. Portanto, é recomendada a realização de uma análise prévia da área de interesse com o equipamento a ser utilizado, para aferir a capacidade do mesmo na cobertura de toda a área a ser mapeada.

Desta forma, o objetivo do aerolevantamento é uma informação importante no planejamento e na execução do voo, pois é ele quem determinará a resolução espacial adequada e conseqüentemente a altitude da missão, visto que quanto menor a elevação melhor é a qualidade das fotos e também das informações que podem ser extraídas.

## 2.4 PROCESSAMENTO DIGITAL DE IMAGENS

O processamento digital de imagens (PDI) é o conjunto de técnicas que visa extrair informações de imagens digitais (GANDHI et al., 2015). Portanto, são abordadas as técnicas de aquisição, de realce, de segmentação, de pós-processamento, de extração de atributos e de classificação. Tais metodologias são dedicadas a problemas particulares das imagens avaliadas. Entretanto, é mais eficaz garantir que na aquisição desses dados seja evitado a perda de informações ou o uso excessivo de realce das imagens (COELHO; BRITO, 2007). O PDI conta

com diversos algoritmos especializados que permitem ao usuário trabalhar com elevada variedade de técnicas de processamento, que são divididas em dois tipos básicos: realce e classificação. Entretanto, antes do tratamento matemático das imagens é indispensável o pré-processamento das mesmas, isto é, um trabalho preliminar de correção e preparo dos dados a serem analisados (MENESES; ALMEIDA, 2012).

As operações podem ser realizadas, tanto pontualmente, como em nível de vizinhança, como, por exemplo, o efeito *striping* (sistemático, para calibração de sensores) e os filtros “passa-alta”. Os filtros “passa-alta”, por sua vez, são utilizados para o realce de componentes de alta frequência espacial a partir da exclusão dos componentes de baixa frequência, que desta forma são enfatizados os detalhes geométricos de interesse e problemas, como o de sombreamento, podem ser eliminados. Tais filtros são recomendáveis para regiões heterogêneas, principalmente quando o objetivo for o de interpretação visual temática da imagem, ou seja, que requer detalhamento sem que os componentes de baixa frequência sejam totalmente eliminados (MENESES; ALMEIDA, 2012).

Este exemplo, ilustra o potencial das técnicas de PDI, que, no geral, corrigem os erros e distorções introduzidos nas imagens pelos sistemas sensores (físicos) e facilitam a acessibilidade e análise das informações contidas, com redução de custos e de tempo. Mas cabe ressaltar que estas operações não possuem um padrão pré-estabelecido de fluxo de trabalho, até mesmo porque os resultados obtidos em determinado local não indicam a sua reprodutibilidade em outras áreas (MENESES; ALMEIDA, 2012; GANDHI et al., 2015).

A seguir serão abordadas duas técnicas de pós-processamento relacionadas ao estudo de coberturas vegetais, que representam os procedimentos para condução de análises geoespaciais a partir de produtos obtidos por VANTs.

**2.4.1 Geração de Ortomosaicos:** as fotos obtidas a partir de um aerolevante são chamadas de ortofotos, que são registros fotográficos caracterizados por manter as posições ortográficas verdadeiras dos objetos na imagem, pois eliminam os deslocamentos e a inclinação das fotografias. Portanto, são equivalentes aos mapas planimétricos convencionais.

Os ortomosaicos, são um dos principais produtos de um mapeamento aéreo e se tornaram um atrativo ao mercado dos VANTs pela possibilidade destas plataformas embarcadas com câmeras convencionais reduzirem os custos e a complexidade de obtenção destes produtos. Contudo, como estas câmeras não apresentam precisão geométrica, necessitam ser calibradas para que informações confiáveis sejam extraídas.

Tais imagens são acompanhadas de distorções radiais associadas ao formato das lentes (“efeito domo”), que devem ser corrigidas para a costura das imagens. Para isso, atualmente existem diversas alternativas, como o *software* Agisoft Photoscan, por exemplo, que realiza todo o processo de mosaicagem e calibração das imagens com a mínima intervenção do operador.

Estes *softwares*, geram outros produtos além dos ortomosaicos, como o modelo 3D e o Modelo Digital de Superfície (MDS), que são obtidos a partir de nuvem de pontos. Assim, os algoritmos não detectam apenas os pontos de interesse ou as características locais de regiões das imagens, mas que também são eficientes na resolução de problemas relacionados ao reconhecimento de padrões. Dentre eles, destacam-se o SIFT (*Scale Invariant Feature Transform*), proposto por Lowe (1999), e o SURF (*Speeded UP Robust Features*), proposto por Bay et al. (2006), que englobam diversas metodologias de identificação de pontos de interesse e geração de descritores com correspondência entre os pontos de interesse para aerotriangulação.

O SIFT, é baseado na obtenção de uma pirâmide gaussiana da imagem a partir de operações sucessivas de borrarmentos e redução de escala. Assim, as convoluções baseadas em filtros Gaussianos detectam os pontos extremos, que são candidatos a pontos-chave e submete os mesmos à análises de vizinhança, para orientação e magnitude. Logo, um ponto calculado com a técnica SIFT pode ser identificado com grande facilidade num elevado volume de pontos de outras imagens, já que os descritores são de fácil distinção, pois o processo de extração das individualidades envolve alta complexidade computacional (LOWE, 1999; BELO, 2006).

Já o SURF, se caracteriza pela agilidade no processamento e detecção destes pontos. Este algoritmo é baseado na Matriz Hessiana, que reduz o tamanho do vetor de distinção sem sacrificar o desempenho (BAY et al., 2006). As imagens são analisadas em blocos de filtros 9 x 9, que evitam que a mesma seja filtrada várias vezes, determinando o espaço de escala a partir da alteração das dimensões do filtro, ao invés da redução da imagem. Com isso, o descritor detecta a densidade e a distribuição dos pontos de interesse na vizinhança, explorando as imagens em 64 dimensões, o que justificaria a redução do tempo de detecção (EVANS, 2009). Portanto, o SURF torna-se uma alternativa mais robusta que o SIFT, tanto em relação a variação de escala, como na extração de características das imagens, embora em alguns estudos a seleção de pontos do SURF foi menor (MOZOS et al., 2007; GIL et al., 2009).

Assim, os produtos gerados permitem a obtenção de medidas planimétricas e altimétricas que subsidiam diversas análises geoespaciais, como na detecção de áreas de risco (SOLOMON et al., 2002), quantificação movimentos de massa (LUCIEER;

JONG; TURNER, 2014), definição de áreas de proteção permanente (APP) (CÂNDIDO; DA SILVA; FILHO, 2015), classificação e quantificação da vegetação (PRIMICERIO et al., 2012; BRAZ et al., 2015), delimitação e quantificação de áreas de inundação (SUMALAN; POPESCU; ICHIM, 2015; BUFFON; PAZ; SAMPAIO, 2017), dentre outras.

**2.4.2 Índices de vegetação:** os índices de vegetação (IV) (Tabela 1) foram desenvolvidos com diferentes interesses de estudos das coberturas vegetais. Para isso, das combinações de bandas são extraídos dados de reflectância dos alvos, que permitem estimar quantidades de clorofila, índices de área foliar (IAF) e a porcentagem de cobertura verde por unidade de terreno (VF) (Equação 4) (TORRES-SÁNCHEZ et al., 2014; HUETE; JUSTICE, 1999; YU et al., 2013). Desta forma, a utilização de IV é importante no manejo e monitoramento de coberturas vegetais, principalmente quando combinados com o uso de VANTs e outras tecnologias de precisão (YANG et al., 2006; BRYSON et al., 2010).

$$VF = \frac{\text{pixels classificados como vegetação}}{\text{total de pixels da área}} \times 100 \quad (\text{Equação 4})$$

As faixas de REM de interesse para os IV são as do vermelho e do infravermelho, pois são as regiões de maior absorção e reflexão da radiação. Por isso, a maior parte dos IV utiliza a combinação das duas bandas para realçar a vegetação, gerando imagens em tons de cinza, com os pixels de maior valor digital e tonalidade mais clara representando a vegetação, e os mais escuros, de menores valores digitais, são de alvos da superfície do terreno (MENESES; ALMEIDA, 2012). A região limítrofe do vermelho, *Red edge* (735 nm), é importante no estudo das coberturas vegetais, pois representa a faixa de mudança na reflectância da vegetação (IMMITZER; VUOLO; ATZBERGER, 2016).

Tabela 1 – Exemplos de índices de vegetação (IV) no espectro visível (VIS), infravermelho próximo (NIR) e Red Edge (RE).

Nome	Tipo	Abreviação	Equação	Referência
Ratio vegetation index	Red – NIR	RVI	$Rn/Rr$	JORDAN (1969), PEARSON; MILLER (1972)

Normalized difference vegetation index	Red – NIR	NDVI	$(R_n - R_r)/(R_n + R_r)$	TUCKER (1979)
Soil adjusted vegetation index	Red – NIR	SAVI	$(1 + 0.5)(R_n - R_r)/(R_n + R_r + 0,5)$	HUETE (1988)
Modified soil adjusted vegetation index	Red – NIR	MSAVI	$0.5\{2.R_n + 1 - \sqrt{[(2.R_n + 1)^2 - 8(R_n - R_r)]}\}$	QI et al. (1994)
Optimized soil adjusted vegetation index	Red – NIR	OSAVI	$(1+0.16) (R_n-R_r) / (R_n+R_r+0.16)$	RONDEAUX et al. (1996)
Enhanced vegetation index	Vis-NIR	EVI	$2.5(R_n-R_r) / (R_n+6.R_r-7.5.R_b+1)$	HUETE et al. (2002)
Triangular vegetation index	Vis-NIR	TVI	$0.5[120(R_n-R_g) - 200(R_r-R_g)]$	BROGE; LEBLANC (2000)
Chlorophyll vegetation index	Vis-NIR	CVI	$R_n.R_r / R_g^2$	VINCINI et al. (2008)
Normalized green red difference index	Vis	NGRDI	$(R_g-R_r) / (R_g+R_r-R_b)$	TUCKER (1979)
Green leaf index	Vis	GLI	$(2.R_g-R_r-R_b) / (2.R_g+R_r+R_b)$	LOUHAICHI et al. (2001)
Visible atmospherically resistant index	Vis	VARI	$(R_g - R_r) / (R_g + R_r - R_b)$	GITELSON (2002)
Modified chlorophyll absorption reflectance index	Red-RE	MCARI	$[(R_{700}-R_{670})-0.2(R_{700}-R_{550})] (R_{700}/R_{670})$	DAUGHTRY et al. (2000)
Green Normalized Difference Index	Vis-NIR	GNDVI	$(R_n-R_g) / (R_n+R_g)$	GITELSON et al. (1996)
Infrared percentage Vegetation Index	Vis-NIR	IPVI	$\frac{NIR}{NIR + R}$	CRIPPEN (1990)
Non-Linear Index	Vis-NIR	NLI	$(R^{2NIR}-R_{RED}) / (R^{2NIR}/R_{RED})$	GOEL; QUIN (1994)
Canopy Index	Vis-NIR	CI	$R_{SWIR} - R_{GREEN}$	VESCOVO; GIANELLE (2008)

Fonte: Do autor.

Vis: Visível; NIR: infravermelho próximo; SWIR: infravermelho médio.

O mais conhecido dos IV é o NDVI (*Normalized Difference Vegetation Index*), validado por Tucker (1979), que utiliza combinações lineares entre as bandas do vermelho e infravermelho próximo para o monitoramento da biomassa vegetal. Os valores variam entre -1 e 1, e quanto maior esse valor maior é a densidade vegetal. Considerando que o solo tem valor próximo de zero, a vegetação apresenta resposta entre 0,1 e 1 (OLIVEIRA, 2012). Embora seja um índice relacionado à saúde vegetal, muitas vezes, é recomendado o acompanhamento das lavouras, pois alguns nematoides, como o *Aphelenchoides sp*, podem causar danos à produção e são comumente confundidos com sanidade vegetal. Isso se deve à doença provocada pelo nematoide estimular o brotamento de folhas e a retenção das hastes de algumas espécies, como a soja e, assim, os valores de NDVI serão maiores, apontando a necessidade de manejos diferenciados (FAVORETO et al., 2015). Outros IV estão na Tabela 1.

As equações de IV devem ser relacionadas com os dados climáticos para a interpretação dos seus valores, assim como com os levantamentos de campo, que são práticas complementares à utilização destes índices (KIRINY et al., 1992; ARNOLD et al., 1995).

## 2.5 VEGETAÇÃO

A cobertura dos solos pela vegetação oferece diversos serviços ecossistêmicos, como a regulação do ciclo hidrológico e do clima, o sequestro de carbono, a contenção de sedimentos, o aumento da qualidade e do fluxo de água (FERRAZ et al., 2014; JOLY et al., 2014; MAGRIN et al., 2014; GOLDMAN, 2010; SCHEFFER et al., 2001) mas, isoladamente, é o fator de maior importância no controle da erosão hídrica (AMADO et al., 1989). Os serviços ecossistêmicos são os bens e serviços obtidos dos ecossistemas diretamente ou indiretamente. Estes serviços podem ser de provisão, que representam os materiais consumidos, como as matérias-primas, os alimentos e o combustível; de regulação, que desempenham funções reguladoras das condições naturais, como a qualidade do solo e a disponibilidade de água; culturais, àqueles que oferecem benefícios não materiais como a recreação e o turismo e, por fim, os serviços de suporte, que são necessários para que outros serviços também sejam desempenhados, que são exemplos a produção de oxigênio e o ciclo dos nutrientes (COSTANZA et al., 2017; BENNET; PETERSON; GORDON, 2009).

Como todos os organismos de um ecossistema, as plantas coexistem e se mantem por várias dependências e interações complexas, que regulam a convivência dos indivíduos, sejam eles vegetais, animais e microorganismos. O ciclo de vida das plantas é influenciado diretamente pelas condições específicas impostas pelo *habitat*, que determinam os processos morfogenéticos de evolução, de adaptação e de seleção. Desta maneira, as interações ecológicas são essenciais para o desenvolvimento das plantas. Alguns exemplos dessas interações são a cooperação, como a proteção das plantas jovens pelas maiores, evitando a exposição excessiva, o superaquecimento ou o resfriamento das mesmas; a competição por luminosidade e espaço, assim como por água e material nutritivo; a comunicação química, que é realizada por substâncias que permitem a manutenção de relações ecológicas; ou ainda, as interações via metabólitos secundários, que mantem a resiliência da biosfera (FITTER; HAY, 2002).

Os processos abióticos são importantes na interação das raízes das plantas com os constituintes dos solos, com troca constante de matéria. Assim, os vegetais são nutridos pelos nutrientes minerais e aqueles que resultam da mineralização de restos vegetais. Tais processos

são controlados pelas variáveis do *habitat*, como umidade, temperatura, pH, quantidade e tipo do substrato degradável. Nas regiões tropicais, em especial, tais processos tendem a ser mais rápidos devido às características edafoclimáticas peculiares dos ecossistemas (LARCHER, 2000; FITER; HAY, 2002).

**2.5.1 Interações entre vegetação, radiação e clima:** o fluxo de energia é responsável pela manutenção da vida na Terra. As plantas, por meio da fotossíntese, fixam a energia irradiada pelo sol e a transformam em energia química potencial para realização dos processos vitais. A radiação solar é responsável pela reposição da matéria orgânica na cadeia alimentar, regulando os balanços hídricos e energéticos. Contudo, a radiação é também estímulo às plantas, que condiciona o seu desenvolvimento ou atua como fator fotodestrutivo, afetando alguns processos vitais como a germinação, o crescimento e a forma externa da planta. A radiação fotossinteticamente ativa (RFA) apresenta faixa espectral entre 400 e 700 nm, próxima à radiação ultravioleta (UV) e à infravermelha (IR).

O clima pode ser entendido como as condições rotineiras médias do tempo de uma região. Logo, é um fator ambiental determinante do crescimento das plantas e da área de distribuição, já que ocupam o *habitat* mais apropriado às necessidades específicas (WALTER; WALTER, 1953). Portanto, sem desconsiderar o tempo cronológico, o material parental e o relevo, as zonas climáticas determinam algumas particularidades de cada região, com os tipos vegetacionais e de solo. No Brasil, as regiões de clima tropical são marcadas por duas estações distintas, uma chuvosa, e quente, no verão, e uma seca e fria, no inverno.

Nas regiões tropicais, os solos apresentam baixa fertilidade natural e são, em geral, argilosos e de coloração amarelo a avermelhada, com pH levemente ácido e elevados teores de ferro e alumínio (BRADY; WEIL, 2013). Já a vegetação dominante é caracterizada pelas Florestas tropicais decíduas, como a Mata Atlântica. Essas áreas estão em franco processo de desmatamento que resulta num avançado estágio de fragmentação das matas nativas, que promove o desequilíbrio dos processos naturais, afetando a umidade do ar, a temperatura média, a incidência de radiação solar e, ainda, acelerando a erosão hídrica (SCARANO; CEOTTO, 2015). Esse desequilíbrio ameaça toda a diversidade biológica e favorece o estabelecimento de espécies invasoras, que prejudicam as relações ecológicas e outros processos ambientais, como a polinização (GUIMARÃES; COGNI, 2002; LAURANCE et al., 2002; METZGER, 2000).

No geral, as zonas climáticas ilustram o efeito de diversos balanços energéticos sobre a superfície terrestre, em diferentes latitudes. Assim, o relevo determina fatores como a disponibilidade e direção dos ventos e da radiação, que determinam a organização e o

desenvolvimento das populações vegetais, além do controle do mesoclima e microclima. As plantas também possuem bioclimas individuais, onde o bioclima ao seu redor é determinado pela estrutura e funcionamento da comunidade vegetal, isto é, a posição das folhas em relação ao vento e à radiação é essencial para o balanço de calor. Este balanço, por sua vez, é controlado pela transpiração estomática, que regula as trocas de energia com o ambiente (LARCHER, 2000).

**2.5.2 Fotossíntese:** é uma atividade desenvolvida desde quando os ambientes eram altamente anóxicos. Os produtos finais, oxigênio e carbono absorvidos, são importantes não só para as plantas, mas também para os demais seres vivos (FITTER; HAY, 2002).

A fotossíntese é a transformação da energia radiante absorvida em energia de ligação química, que envolve processos enzimáticos, fotoquímicos e de difusão, entre os cloroplastos e a atmosfera. Os cloroplastos são uma organela envolvida por dupla membrana e um sistema de tilacóides, contendo ainda pigmentos fotossintetizantes ativos, ribossomos, plasmídeos e diversas inclusões (CLEMENTS, 1904 apud LARCHER, 2000) (Figura 5). Tais processos são influenciados por fatores externos e internos responsáveis pelo grau de assimilação da folhas. O desencadeamento dessa transformação é a absorção da radiação pelas clorofilas e pelos pigmentos acessórios xantofila e caroteno, nas faixas de maior absorção, do azul e do vermelho. Plantas com deficiência de clorofila são facilmente detectáveis, já que tendem a apresentar efeitos indicativos da baixa atividade fotossintética, a clorose, como observado no outono. A clorofila pode ser deteriorada em casos de maior ou menor exposição à radiação ou por problemas genéticos (BJÖRKMAN; DEMMING, 1987).

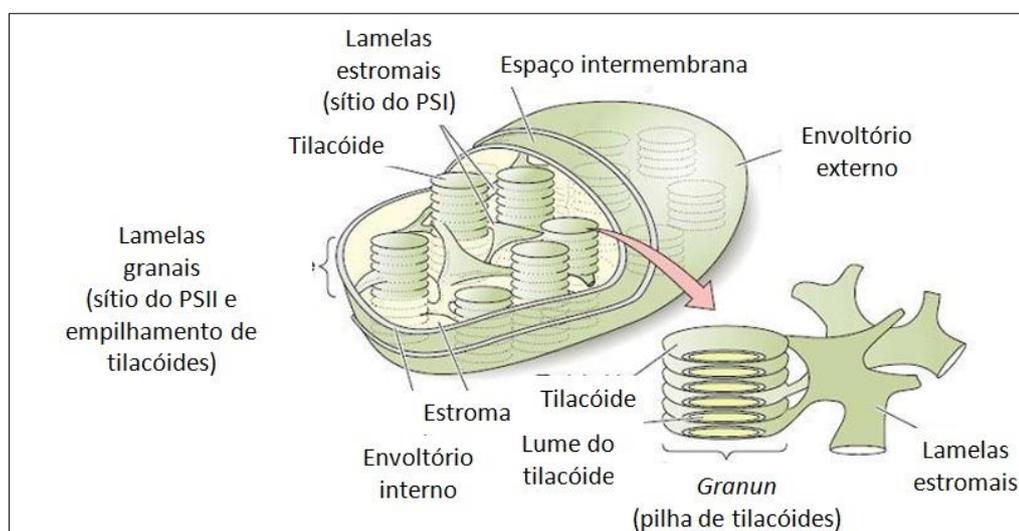


Figura 4 - Esquema estrutural de um cloroplasto.  
 Fonte: Taiz e Zeiger (1998)

A eficiência fotossintética está ligada ao teor de clorofila das plantas, o que afeta o seu crescimento e influencia a adaptabilidade das mesmas ao ambiente (ENGEL; POGGIANI, 1991). Em presença da luz é constantemente sintetizada e destruída pelo processo de foto-oxidação, sendo que a velocidade de decomposição é diretamente proporcional à intensidade luminosa, que pode causar prejuízos para a fotossíntese. Segundo Lee (1988), estudos evidenciaram que o teor de clorofila é variável entre as espécies, assim como entre os genótipos de uma mesma espécie. O rendimento do processo depende da energia absorvida, ou seja, é depende do comprimento de onda. Desta forma, o mesmo é o resultado da razão entre o trabalho fotoquímico e a absorção de luz (Equação 3) (LONG et al., 1993).

$$[O_2] = \frac{\text{trabalho fotoquímico (mol } O_2)}{\text{quantidade de luz absorvida (mol de fótons)}} \quad (\text{Equação 3})$$

A capacidade fotossintética das plantas é alterada sazonalmente e com o desenvolvimento das plantas. Pois as folhas mais jovens não realizam a fotossíntese de maneira eficiente, já que os cloroplastos não atingiram a maturidade. Nas regiões temperadas, a atividade fotossintética atinge seus limites máximos no início do verão e nas fases de floração e frutificação, que são períodos de expansões foliares totais e de alta taxa assimilatória para nutrição dos frutos. Já no inverno e outono, é observado o contrário, ou seja, o declínio da capacidade fotossintética devido à senescência das folhas e à diminuição das temperaturas (KOIKE, 1990). Portanto, a adaptação das plantas às condições do ambiente é essencial para manutenção da atividade fotossintética, já que os fatores ambientais são limitantes deste processo. Exemplos de condições que limitam a fotossíntese são a falta de água e os climas extremos quentes e frios, que desencadeiam casos de estresse (KYPARISSIS; MANETAS, 1993).

A absorção de radiação e a adaptação à disponibilidade são imprescindíveis para fixar e liberar CO<sub>2</sub>, que são processos de proporcionalidade direta: a disponibilidade de radiação determina o rendimento fotossintético. Assim, folhas que se encontram em áreas de sombra realizam respiração com menor intensidade do que as expostas em áreas de maior luminosidade, compensando em ganho de carbono. Em vista disso, se nenhum outro fator ambiental, como a temperatura limitar as trocas gasosas das plantas, a atividade fotossintética acompanhará linearmente a disponibilidade de radiação até que atinja o ponto de saturação (PS), que é a fase



que depende da disponibilidade energética da planta e das substâncias efetoras e endógenas que regulam o funcionamento da cadeia de reações. Diante disto, a sensibilidade dos estômatos é variável de acordo com a adaptação, o desenvolvimento do vegetal e as condições a que estão submetidos (LARCHER, 2000).

O entendimento de parâmetros fisiológicos, como a resistência estomática, é importante para a interpretação dos efeitos osmóticos e hídricos sobre a eficiência fotossintética das plantas. Todavia, a magnitude desta eficiência, por fatores osmóticos ou não, influi diretamente no desenvolvimento dos vegetais (LINDON et al., 1999; PEREIRA et al., 2000; AKAIA; TAKENAKA, 2001; PEIXOTO et al., 2002). Estudos demonstraram que o déficit hídrico é limitante à abertura dos estômatos, alterando as taxas de transpiração e de fotossíntese (CASTRO NETO, 2003; AMARAL, 2006). Desta forma, a compreensão desses processos contribui na elaboração de estratégias de manejo e irrigação dos cultivares que facilitam o desenvolvimento das plantas.

**2.5.4 Sensoriamento Remoto da Vegetação:** a capacidade de refletir, absorver e transmitir os feixes da REM são determinados pelas características físico-químicas de cada planta. Porém, a incidência do fluxo radiante na superfície vegetal varia com a intensidade e o comprimento de onda e não ocorre de maneira uniforme, ou seja, é geometricamente aleatória, assim como a reflexão deste fluxo, que apresenta geometria similar, mas não idêntica à incidente. Assim, o sentido do fluxo da reflexão será aleatório, mas em sentido contrário, porém com dimensões diferenciadas, sendo que alguns fluxos podem ser refletidos com maior intensidade, pois a vegetação é uma superfície anisotrópica, como a maioria das superfícies dos recursos naturais. Isto é, não refletem de maneira igual a REM em todas as direções, independentemente do fluxo incidente (GUPTA; IBARAKI, 2014).

Nos casos em que o feixe atravessar a folha, haverá uma trajetória errante que é determinada pelos constituintes internos, como a quantidade de água e de ar, que são exemplos de fatores limitantes à forma de movimentação do feixe. Essa movimentação, por sua vez, pode ser interrompida pela captura dos pigmentos fotossintetizantes, caso seja radiação visível. Contudo, não significa que toda a radiação visível será capturada. Nesta faixa espectral, a energia radiante interage com a estrutura foliar por absorção e espalhamento, sendo conseqüentemente convertida em calor ou fluorescência, que proporcionará também o armazenamento de energia na forma de componentes orgânicos. Estudos de Shul'gin e Kleshnin (1959) e de Taggeva, Brandt e Derevyanko (1960) concluíram que grande parte das espécies

apresenta correlação direta da quantidade de clorofila das folhas com a absorção da energia radiante.

Na região do infravermelho ( $0,72 \mu\text{m} - 3,2 \mu\text{m}$ ), não há absorção da radiação pelos pigmentos fotossintetizantes, assim a trajetória errante do feixe incidente permanecerá no interior da folha, interagindo com as estruturas do mesófilo. Dessa maneira, a disponibilidade de água pode interferir quantitativamente na reflectância das folhas. Portanto, quanto mais lacunosa for a estrutura da folha, maior será o espalhamento e maiores os valores de reflectância, assim quanto maior a umidade das folhas menor será a reflectância delas (GATES et al., 1965, KUMAR, 1974). A influência dos fatores ambientais e patogênicos na composição química ou estrutural das folhas confirma a capacidade de modificações nas propriedades espectrais das mesmas (GUYOT, 1995).

Embora os critérios particulares das folhas das plantas, nas técnicas de SR aplicadas à vegetação devem ser consideradas as propriedades dos dosséis. Portanto, a região do visível tem a sua reflectância reduzida de acordo com a quantidade de camadas de folhas. As dinâmicas apresentadas pelo infravermelho são inversas, aumentam com a maior sobreposição das folhas, que comprova o caráter assintótico dos dosséis, também conhecido como reflectância infinita (PONZONI; SHIMAKUBURO, 2007). Outro fenômeno referente à interação da REM com as camadas de folhas no infravermelho é o espalhamento múltiplo, considerado na transmissão da radiação sobre as folhas, que pode levar a diferentes comportamentos da reflexão entre as faces ventrais e dorsais do dossel, com efeito análogo ao espalhamento interno da radiação nas folhas individuais (PONZONI, 2001).

Nos dosséis de porte florestal, o movimento do fluxo solar incidente sobre a superfície e o movimento em direção ao sensor, que não são dependentes apenas das propriedades de espalhamento e de absorção da vegetação, mas também pela densidade e orientação dos fluxos. Ou seja, a vegetação recebe dois tipos de radiação: a não interceptada e a interceptada e espalhada pelo dossel, resultando em diferentes fluxos capturados pelo sensor. Desta forma, o fluxo que é espalhado apenas uma vez é chamado de espalhamento único; o espalhamento múltiplo é espalhado várias vezes pela vegetação sem atingir o solo; e o fluxo que é refletido pelo solo, responde ao sensor sem ter sido interceptado pela vegetação. Portanto, a arquitetura dos diferentes dosséis agrícolas e florestais são determinados pelas suas respectivas orientações e densidades, que define a distribuição espacial das espécies, variável com os tipos vegetacionais. Outro efeito dessa arquitetura sobre a reflectância ocorre quando os elementos não se encontram uniformemente distribuídos, aumentando a probabilidade de ocorrência de

lacunas sobre a extensão alterando o espalhamento das áreas mais próximas ao solo (GUPTA; IBARAKI 2014; PONZONI; SHIMABUKURO; KUPLICH, 2012).

De maneira geral, ao considerar as folhas isoladas em relação aos dosséis, é esperado que os fatores de reflectância individual sejam superiores ao conjunto de camadas de folhas, na região do visível. O infravermelho, neste contexto, apresenta resultados inversos, devido ao espalhamento múltiplo da radiação entre as camadas. Contudo, por conta do sombreamento entre as folhas é natural a reflectância maior das folhas isoladas em relação aos dosséis (SILVA; PONZONI, 1995).

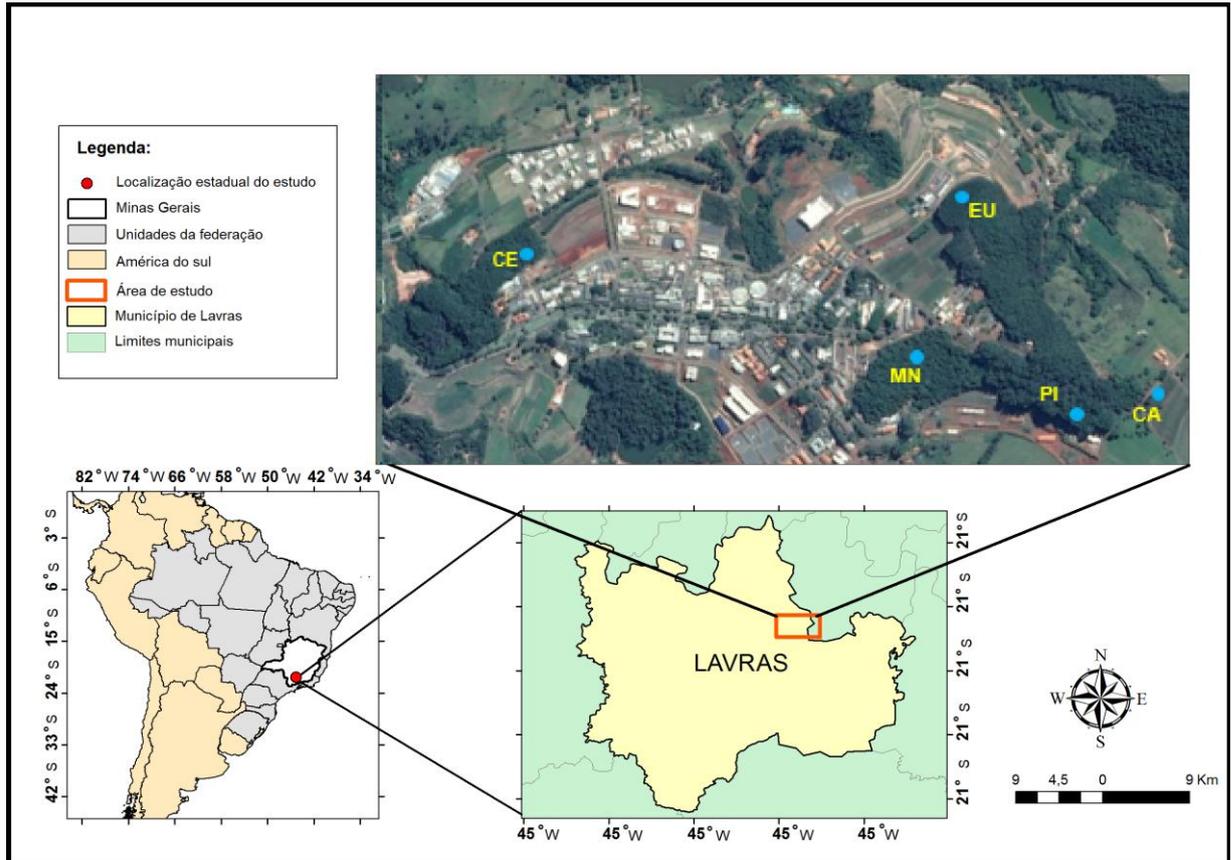
### **3 OBJETIVO**

O objetivo desta pesquisa foi avaliar o potencial de um modelo de asa rotativa no estudo sazonal de cinco coberturas vegetais entre 2017 / 2018 a partir de índices de vegetação (IV) e coletas georreferenciadas da camada superficial de solo em campo. Para aferir o desempenho do VANT nesta proposta de pesquisa, foi utilizado um satélite de dados gratuitos (Sentinel-2).

## **4 MATERIAIS E MÉTODOS**

### **4.1 ÁREA DE ESTUDO**

As cinco áreas de estudo estão localizadas na Universidade Federal de Lavras (UFLA), Município de Lavras, sul de Minas Gerais, e caracterizam as diferentes coberturas vegetais do Campus, como o cultivo de *Coffea* spp. (CA), os povoamentos de *Pinus* spp. (PI), de *Eucalyptus* spp. (EU) e 2 dos fragmentos florestais, representados pelo fragmento “Matinha” (MN) e pelo fragmento “Cerradinho” (CE) (Figura 7).



**Figura 6** - Mapa de localização do estudo.

Fonte: Do autor

O Campus, que foi fundado em 1908, possui área de 505,2 ha compostos por regiões urbanizadas, cultivadas e de vegetação nativa (ARAUJO, 2018). A paisagem é caracterizada por um cenário fragmentado de diversos tipos de coberturas, com 13,82% da área urbanizada e 57% de áreas agrícolas e de florestas plantadas (UFLA, 2016). As áreas nativas são representadas por 9 fragmentos, que perfazem 25% do total. Estes remanescentes enfrentam problemas de isolamento, visto que a conectividade dos mesmos é exercida pelos povoamentos de *Pinus ssp.* e *Eucalyptus spp.*, que são áreas expostas a diferentes impactos e que não apresentam capacidade de manutenção destas funções. Dentre eles, se destacam a presença de vias de acesso, ausência de cercamento adequado, presença de trilhas, benfeitorias muito próximas e depósitos tecnogênicos, no interior e nas bordas dos povoamentos. No entanto, estas áreas nativas são consideradas diversas, o que reflete os esforços da comunidade da UFLA na implantação de programas de gestão sustentável para adequação à legislação pertinente aos recursos naturais (PEREIRA, 2010).

Dentre os fragmentos, o fragmento “Matinha” é o maior (5,72 ha) e também é o que detém índice de diversidade mais elevado (*Shannon* -  $H' = 3,917$ ). No total, são encontradas 19 famílias, 31 espécies e 27 gêneros neste fragmento, que é um dos principais remanescentes

locais, com diversos estudos de caracterização (DIAS et al., 2002; PEREIRA et al., 2010). O fragmento “Cerradinho”, em contrapartida, além do tamanho menor (2,81 ha), não foi uma área muito estudada, mas detém 19 famílias, 38 espécies e 38 gêneros ( $H' = 3,289$ ), com indivíduos como a *Bowdichia virgiloides* (Sucupira-preto), *Dalbergia miscolodium* (Caviúna do cerrado) e a *Qualea grandiflora* (Pau preto) de ocorrência exclusiva (D'ANGELO NETO et al., 1998).

De acordo com os levantamentos realizados, a principal síndrome de dispersão é a zoocoria, ou seja, àquela realizada pela fauna silvestre, como os mamíferos, as aves e os insetos (D'ANGELO NETO et al., 1998; DIAS et al., 2002; PEREIRA et al., 2010; ROCHA et al., 2006). Segundo Aubert e Oliveira Filho (1994), a Matinha é a principal fonte de propágulos para a colonização das áreas vizinhas, o que demonstra a importância deste remanescente e dos povoamentos adjacentes para a manutenção da diversidade biológica local, já que a dispersão de sementes é um fator primordial para o enriquecimento das áreas de integração agroflorestais (LEVINE; MURRELL, 2003; BECKMAN; ROGERS, 2013).

Em relação a fauna, estudos como o de D'Angelo Neto (1998), Prado et al. (2008), Eduardo e Passamani (2009), Silva et al. (2009), Machado et al. (2016), Machado et al. (2017), e Melo-Dias e Passamani (2018), registraram 20 espécies de mamíferos de médio e grande porte e cerca de 110 espécies de aves. Esta riqueza representa 55,5% dos registros no sul de Minas Gerais (ROSA; SOUZA 2017, MAZZA et al., 2018). Das espécies amostradas, quatro estão ameaçadas de extinção: *Leopardus pardalis* (*Jaguaririca*), listada como vulnerável na região, e *Chrysocyon brachyurus* (Lobo-guará) e *Puma yagouaroundi* (Gato mourisco), ameaçadas em nível nacional e *Leopardus guttulus* (Gato-do-mato-pequeno), que é ameaçado globalmente (LAURINDO et al., 2017). Estes dados retratam a importância destes remanescentes para o ecossistema local, pois comprovam que a região oferece recursos e é utilizada como corredor ecológico por diversas espécies.

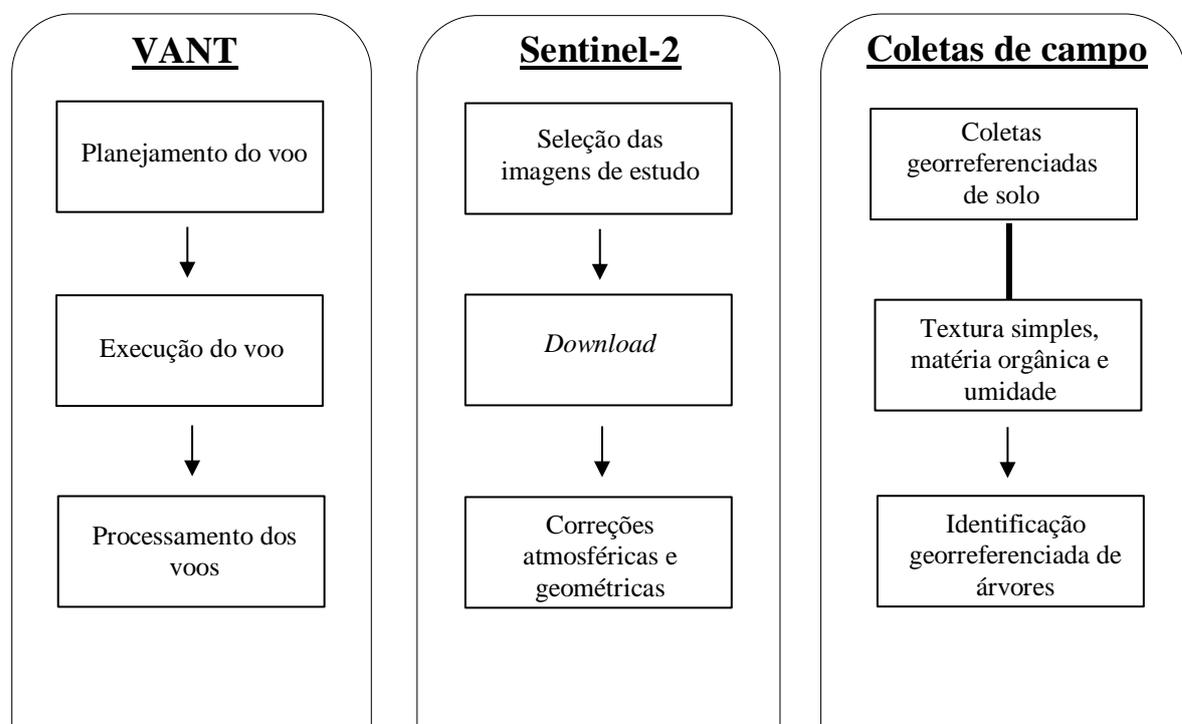
O clima da região é classificado como Cwa, de acordo com a classificação de Köppen (SPAROVEK; DE JONG VAN LIER; DOURADO NETO, 2007), temperado chuvoso (mesotérmico), com inverno seco, subtropical e temperatura média anual de 19,4° C. A altitude média da área é 918 m, com precipitação média anual de 1.529,7 mm. As coberturas vegetais estudadas estão sobre Latossolo Vermelho Distroférico (UFV et al., 2010).

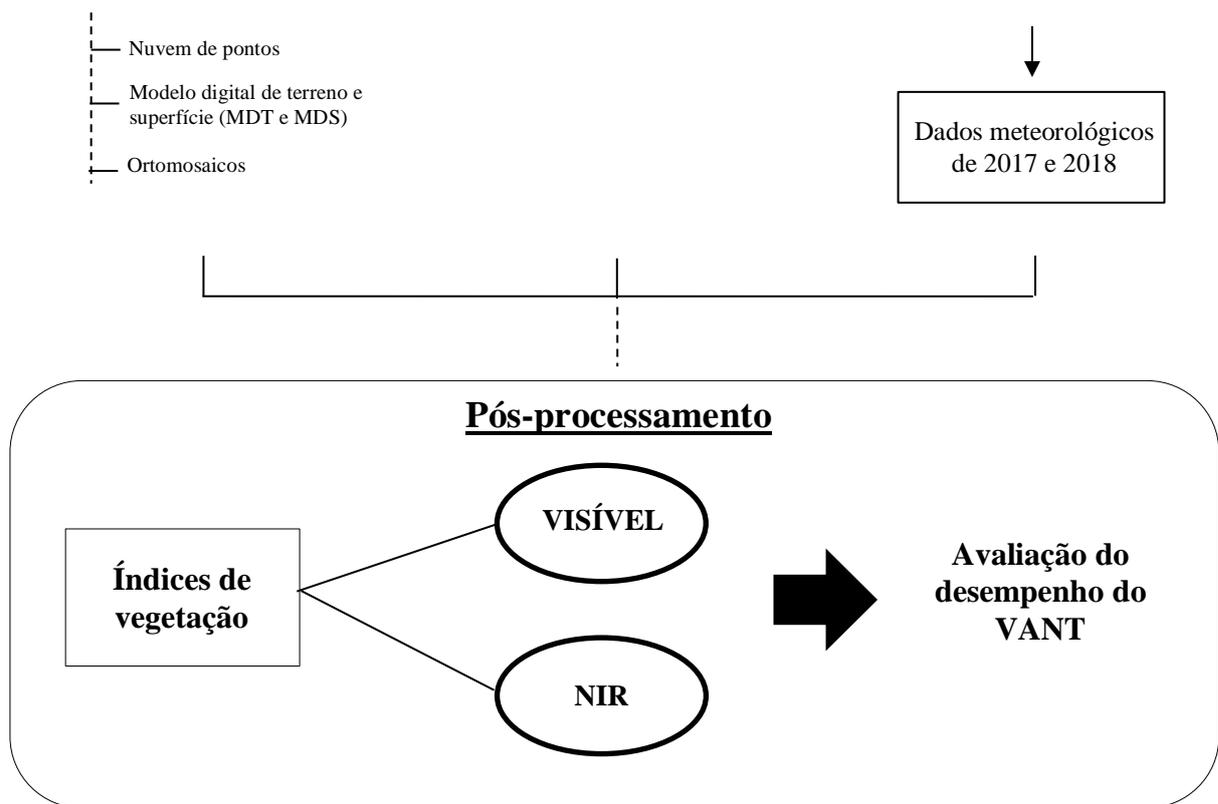
O município é inserido na porção montante da Bacia Hidrográfica do Rio Grande, que é um dos principais afluentes do Rio Paraná, grande produtor de energia hidrelétrica no Brasil. De acordo com Silva (2014), a região compõe a unidade geomorfológica do Planalto Atlântico, com relevo ondulado e rochas cristalinas do Complexo Varginha. Já a vegetação compreende a transição dos biomas Cerrado e Mata Atlântica, com presença de remanescentes florestais de

Floresta Estacional Semidecidual Montana, inserida no domínio de Mata Atlântica (OLIVEIRA-FILHO; FONTES, 2000).

## 4.2 MÉTODOS

O método de pesquisa foi dividido nas etapas: (1) coletas de campo; (2) levantamentos com VANT; (3) obtenção e correção das imagens Sentinel-2; (4) aplicação dos índices de vegetação; (5) comparação entre os resultados orbitais e do VANT. Esta configuração visou monitorar a dinâmica das coberturas vegetais de 2017 e 2018 (Fluxograma 1).





**Fluxograma 1** - Fluxo de trabalho para avaliação da performance dos índices de vegetação obtidos pelos sensores embarcados no VANT.

**4.2.4 Trabalho de campo:** os estudos de campo, foram compostos pela coleta georreferenciada de amostras de solo nas cinco áreas estudadas, assim como a coleta georreferenciada dos códigos das árvores do fragmento “Matinha”, para possíveis identificações junto ao inventário florestal. O GPS utilizado foi o GARMIN eTrex Vista H.

Foram realizadas quatro campanhas para coletar as amostras de solos, sendo que estas eram realizadas no meio de cada estação para a detecção dos padrões sazonais. Na primeira campanha de coletas (Outono), o número de amostras foi de 250, isto é, 50 amostras de 0-20 cm de profundidade em cada área. No restante do estudo, o esforço amostral foi reduzido à 50 amostras totais, 10 amostras por cobertura, visto que análises preliminares demonstraram a representatividade desta quantidade para caracterização das áreas avaliadas. As amostras foram analisadas para matéria orgânica e textura simples no laboratório do Departamento de Ciências do Solo (DCS) da UFLA. O método para determinação da matéria orgânica foi o volumétrico por bicromato de potássio (EMBRAPA, 1998). Já a textura e argila dispersa foram obtidas a partir do método do densímetro (BLACK, 1986), que é baseado no tempo de sedimentação das partículas de diferentes dimensões em meio líquido, com base na lei de Stokes (1851).

A determinação da umidade padrão foi feita pelo método gravimétrico (HILLEL, 1998), em que as amostras são coletadas em latas de alumínio devidamente vedadas, etiquetadas e pesadas antes de serem transferidas para estufa a 110°C por 24 horas. Após este período as amostras são colocadas em dessecador e são pesadas novamente (EMBRAPA, 1997). Em campo, também foram realizadas medições de umidade atual e temperatura do solo a partir de um sensor de reflectometria no domínio do tempo (Time Domain Reflectometry, TDR – 5 TM, Decagon devices), que é uma técnica indireta de estimativa do conteúdo de água no solo ( $\theta$ ) em função da constante dielétrica ( $K_a$ ) (PEREIRA et al., 2006). Todas as coletas foram feitas no mesmo dia do primeiro voo de cada estação, para identificação de padrões sazonais.

Os dados climáticos, como a temperatura ambiente, a umidade relativa do ar, a precipitação média e a insolação, foram obtidos na Estação Climatológica Principal de Lavras, no setor de Agrometeorologia do Departamento de Engenharia da UFLA (Tabela 4) para o período de 2017/2018.

**4.2.1 VANT:** o VANT utilizado foi o modelo Phantom 3 (Professional), que pesa 1.280 g, e é embarcado com uma câmera de modelo Sony EXMOR ½.3”, que captura imagens em cores reais de tamanho máximo de 4.000 x 3.000 pixels nas bandas RGB, com lente FOV 94° 20 mm. Este equipamento multirrotor pode voar por controle remoto ou de forma autônoma, a partir de planos de navegação por GPS. Nele, também foi embarcado um sensor infravermelho, MAPIR Survey 2, com lentes 82° HFOV (23 mm) e disparos a cada 0,2 segundos.

Os voos foram planejados e executados em meados de cada estação para detecção dos padrões sazonais. Assim, no outono a data foi de 02/05/2017, no inverno 24/08/2017, na primavera 27/11/2017 e no verão 01/02/2018. A altitude foi de 60 m com *overlap* e *sidelap* de 80%. Foram adotados dois grids, um de 50 x 50 m nos remanescentes florestais e outro de 100 x 50 m nas demais áreas. Assim, o mapeamento das áreas foi realizado a partir de 20 voos, planejados e executados a partir do GCS (*Ground Control Station*) Pix4D.

Previamente, ao processamento dos aerolevantamentos no software Agisoft Photoscan 1.2.7, os conjuntos de imagens de cada cobertura vegetal foram avaliados manualmente para remoção das fotos da decolagem e da aterrissagem e, posteriormente, foram gerados os ortomosaicos.

No Agisoft Photoscan, a configuração da fototriangulação e a geração da nuvem de pontos, ou seja, a materialização do sistema de coordenadas do terreno, foi: “*Align Photos*” – high; “*Accuracy*” - *generic / pair pre-selection* e *40.000 points features per image*. Desta forma, foi determinado que o nível de detalhamento do estudo seria elevado, com acurácia

genérica e o limite de pontos-chave detectáveis nas áreas de sobreposição foi de 40.000, que após análise pelo algoritmo se transformariam em até 10.000 pontos de enlace, que são os pontos de amarração das imagens. Esta configuração de trabalho é a recomendada pelo Agisoft Photoscan.

**4.2.2 Sentinel-2:** as imagens orbitais foram obtidas a partir do portal Earth Explorer (USGS). Tais imagens foram, posteriormente, processadas no *software* SNAP 2.5 (*Sentinels Application Platform*), para correções geométricas e atmosféricas a partir da ferramenta sen2cor. As datas das imagens foram: (1) outono - 02/05/2017 (2) inverno - 01/07/2017; 21/07/2017; 26/07/2017; 15/08/2017; 30/08/2017; 04/09/2017; 19/09/2017, (3) primavera - 24/09/2017; 09/10/2017; 14/10/2017; 13/11/2017; 08/12/2017 e (4) verão - 22/01/2018 e 16/02/2018. Nos meses de abril e junho não foram utilizadas imagens devido à persistência das nuvens.

**4.2.3 Índices de vegetação:** os índices de vegetação testados foram: *Excess Green* (Woebbecke et al., 1995) (Eq.1), *Excess Red minus Green* (Meyer e Neto, 2008) (Eq.2) e Normalized Difference Vegetation Index (NDVI) (Rouse et al., 1974) (Eq.3) e *Intensity* (Lowe, 2004) (Eq. 4), aplicados a partir do *software* ArcGIS 10.4.1.

$$\text{Ex G} = (2 \times \text{Green} - \text{Red} - \text{Blue}) \quad (1)$$

$$\text{ExRmG} = (2 \times \text{Green} - \text{Red} - \text{Blue}) - (1,4 \times \text{Red} - \text{Green}) \quad (2)$$

$$\text{NDVI} = (\text{NIR} - \text{Red}) (\text{NIR} + \text{Red})^{-1} \quad (3)$$

$$\text{Intensity} = (\text{Red} + \text{Green} + \text{Blue}) \quad (4)$$

Os valores médios de cada índice de vegetação, foram extraídos por três ferramentas: *Minimum Bounding Geometry*, *Fishnet* e *Zonal Statistics as Table*. A primeira foi utilizada para a criação um polígono em cada cobertura vegetal. Assim, a partir dos pontos georreferenciados dos solos foi determinado o limite mínimo de abrangência da coleta em cada cobertura. Em seguida, a *Fishnet* foi aplicada nestes polígonos para a criação de uma malha de 10 x 10 m, idêntica aos pixels das imagens Sentinel-2. Esta malha igualou a escala de trabalho, devido à resolução espacial distinta das plataformas.

Os valores médios de cada célula da malha foram obtidos a partir da *Zonal Statistics as Table*, que gera uma tabela com diversos atributos da área de interesse, como a quantidade de

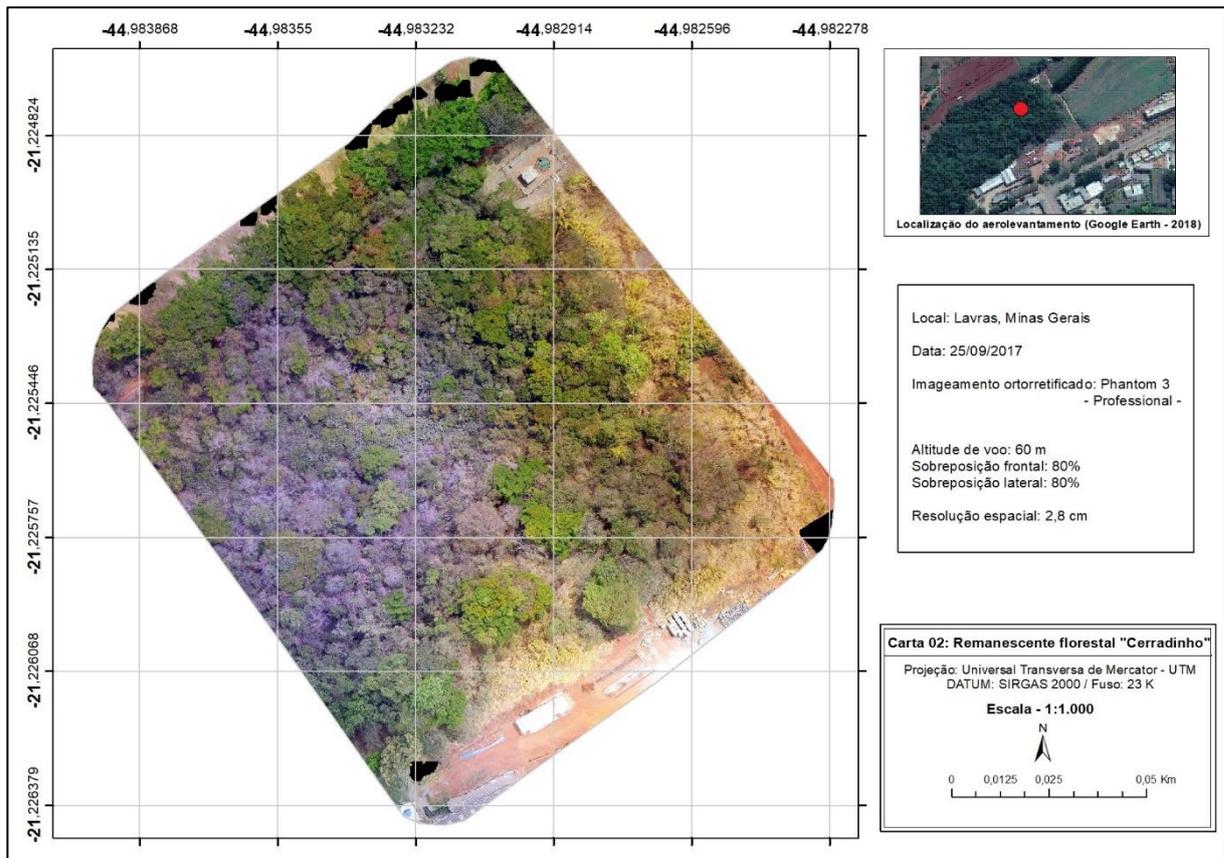
*pixels* no polígono e seus valores máximos, médios e mínimos, assim como a soma e o desvio padrão de cada polígono, sendo utilizado a média de cada cobertura.

Para normalizar os ortomosaicos, foram identificados alvos comuns entre todos os voos, que não apresentam variação de reflectância. Para tanto, foram selecionados alvos de solo exposto, de telhados, de asfalto, entre outros, representados por geometria circular de tamanhos variados. Após a detecção destas áreas foram determinados os valores médios das mesmas via *Zonal Statistics as Table*. Estes valores foram submetidos a regressões lineares para calibração final via *Raster Calculator*.

O método de extração dos valores médios de cada índice de vegetação nas imagens do Sentinel-2 foi o mesmo. Assim, na quinta etapa, a partir dos dados das duas plataformas, as médias foram analisadas pela correlação de Pearson, para determinar o índice de melhor desempenho em cada cobertura.

## 5 RESULTADOS

Os ortomosaicos foram gerados em duas etapas. Primeiramente, foram processados os voos do sensor RGB para obtenção dos ortomosaicos e MDE em alta resolução (Figura 8). Contudo, as áreas de *Pinus* spp. e *Eucalyptus* spp. apresentaram inconsistências na fase de materialização do sistema de coordenadas (*Align Photos*), isto é, no alinhamento das imagens para extração dos pontos de enlace, o que inviabilizou a conclusão de todos os processamentos.



**Figura 7** – Exemplo de um dos ortomosaicos gerados da área “Cerradinho”.

Fonte: Do autor.

Do sensor infravermelho, foram gerados os ortomosaicos na segunda fase de processamento dos voos, que ainda necessitam de calibração adequada para obtenção de valores confiáveis do NDVI.

Em relação ao satélite Sentinel-2, foram obtidas 14 imagens. Tais arquivos possuem resolução de 10 m no espectro visível e infravermelho próximo. Não foram obtidas imagens de abril, junho e março.

Os valores médios dos índices de vegetação aplicados em cada plataforma estão nas tabelas a seguir (Tabela 2 e Tabela 3).

Tabela 2 – Valores médios dos índices de vegetação (IV) aplicados a partir do VANT

Estação	Índices de Vegetação VANT			
	ExG	ExRmG	Intensity	NDVI
<i>Coffea spp</i>				
Outono	-5,62	-51,77	426,00	-0,005
Inverno	-12,71	-156,52	448,30	-0,001
Primavera	28,80	-51,20	388,07	-0,001

Verão	-	-	-	-
<b>Cerradinho</b>				
Outono	-12,20	-225,24	411,57	-0,004
Inverno	-24,16	-464,00	294,00	-0,050
Primavera	-13,46	-350,37	552,33	-0,067
Verão	-29,208	-241,30	529,00	-0,006
<b>Matinha</b>				
Outono	78,00	-206,80	283,65	-0,005
Inverno	62	-286,24	353,82	-0,009
Primavera	96,86	-234,50	320,86	-0,010
Verão	45,03	-241,30	335,50	0,008

ExG: *Excess Green*; EXRmG: *Excess Red minus Green*; NDVI: *Normalized Difference Vegetation Index*  
 Fonte: do autor.

Tabela 3 – Valores médios dos índices de vegetação (IV) aplicados a partir do Sentinel-2

Estação	Índices de Vegetação Sentinel-2			
	ExG	ExRmG	Intensity	NDVI
<b><i>Coffea spp</i></b>				
Outono	37,70	-1689,24	2279,32	0,60
Inverno	-109,00	-2110,95	2499,72	0,47
Primavera	63,00	-1679,07	2313,00	0,46
Verão	-80,70	-2023,86	2412,46	0,50

<b>Cerradinho</b>				
Outono	85,5	-1319,00	2039,76	0,68
Inverno	68,48	-1496,04	2134,20	0,60
Primavera	183,30	-1317,22	2094,17	0,63
Verão	214,00	-1033,04	1826,76	0,74
<b>Matinha</b>				
Outono	77,34	-1214,90	1917,00	0,68
Inverno	70,85	-1333,62	1952,06	0,62
Primavera	156,6	-1221,60	1952,61	0,67
Verão	217,44	-985,75	1771,12	0,75
<b><i>Eucalyptus spp.</i></b>				
Outono	22,03	-1293,74	1936,34	0,71
Inverno	15,37	-1475,44	2040,63	0,64
Primavera	12,68	-1397,92	1970,55	0,62
Verão	98,27	-1072,74	1725,24	0,73
<b><i>Pinus spp.</i></b>				
Outono	100,85	-1280,10	2011,90	0,66
Inverno	12,00	-1565,77	2077,52	0,56
Primavera	64,53	-1463,45	2087,65	0,56
Verão	199,00	-1105,83	1872,71	0,70

ExG: Excess Green; EXRmG: Excess Red minus Green; NDVI: Normalized Difference Vegetation Index  
 Fonte: do autor.

As coletas de campo totalizaram 390 amostras de solos, que após submetidas a análises laboratoriais de textura simples e matéria orgânica, também foram avaliadas a partir de análise discriminante linear. As análises laboratoriais determinaram que a textura do solo é argilosa nas cinco áreas avaliadas, enquanto a ACP revelou elevada associação entre os tipos de vegetação e os atributos do solo, que permitiu considerar o tipo de vegetação como um indicador das condições do solo (Figura 9). As primeiras duas funções discriminaram 91,35% dos dados (71,85 e 24,5%) no Outono, 60,12% (32,98 e 28,37%) no Inverno, 60,98% (51,42 e 46,63%) na primavera e 68,98% (62,63 e 31,07%) no verão. Os valores médios desvio padrão dos atributos de solo para as coberturas vegetais e variação sazonal são observados na Tabela 4.

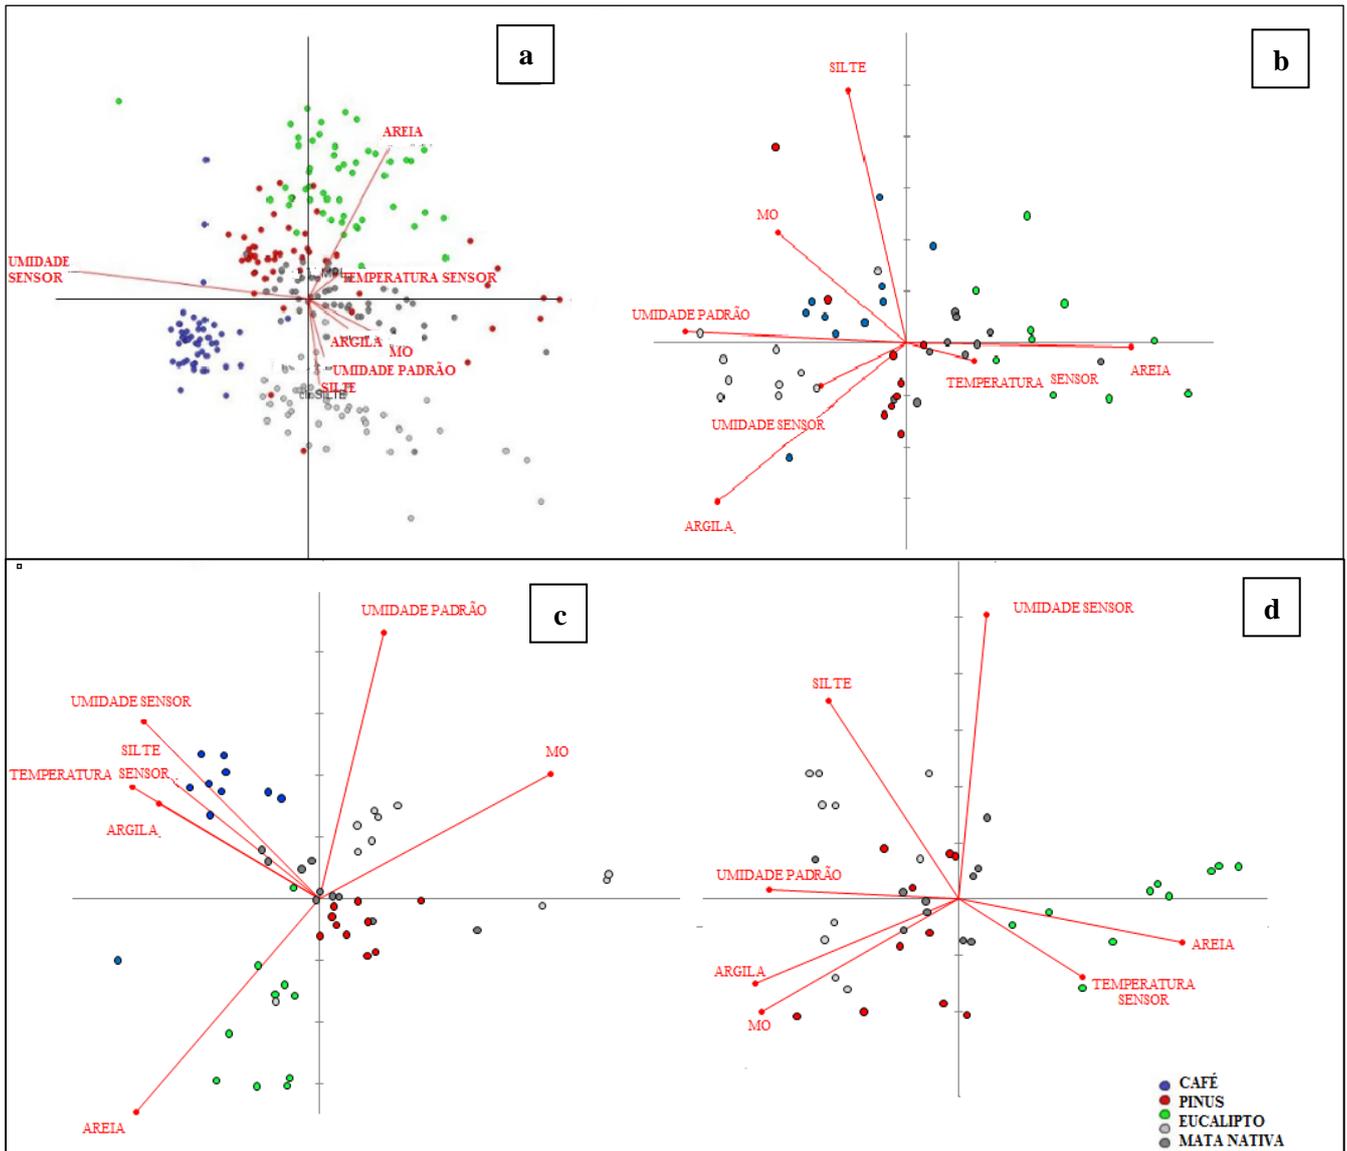


Figura 9 - ACP dos tipos de cobertura vegetal, atributos do solo e comportamento sazonal: (a) Outono de 2017, (b) Inverno de 2017, (c) Primavera de 2017 e (d) Verão de 2017 / 2018.

Fonte: do autor

Tabela 4 – Valores médios e desvio padrão dos atributos do solo entre os padrões de vegetação e variação sazonal.

Estações	Atributos de solo					
	UA	TA	MO	Textura		
	-- % --	-- °C --	-----	Argila	Silte	Areia Total
			g kg <sup>-1</sup> -----			
<b><i>Coffea spp</i></b>						
Outono	32,08 (1,89)	22,05 (1,06)	2,82 (0,32)	69,08 (6,66)	12,84 (3,25)	17,35 (5,14)
Inverno	24,99 (2,36)	23,69 (2,46)	3,52 (0,53)	61,45 (5,93)	20,45 (5,33)	18,18 (2,99)
Primavera	32,98 (2,63)	24,74 (1,73)	2,76 (0,34)	68,18 (8,57)	11,63 (2,90)	20,18 (9,40)
Verão	-	-	-	-	-	-
<b><i>Pinus spp</i></b>						
Outono	27,26 (4,61)	21,00 (0,96)	3,70 (0,65)	71,60 (2,91)	6,40 (3,55)	22,00 (1,88)
Inverno	23,11 (1,70)	20,13 (2,06)	3,73 (0,99)	63,70 (4,62)	14,90 (4,67)	21,40 (1,26)
Primavera	31,16 (0,62)	21,06 (0,38)	2,95 (0,61)	72,80 (2,25)	6,20 (2,74)	21,00 (1,56)
Verão	32,96 (1,68)	22,95 (0,70)	3,66 (0,63)	70,10 (2,84)	9,90 (5,64)	20,00 (3,65)
<b><i>Eucalyptus spp</i></b>						
Outono	19,44 (2,76)	21,50 (0,60)	2,67 (0,55)	55,66 (7,66)	7,46 (1,60)	36,88 (6,86)
Inverno	18,93 (1,95)	23,79 (1,23)	3,37 (0,69)	54,30 (2,21)	14,00 (5,41)	32,70 (4,34)
Primavera	22,57 (3,97)	22,02 (0,46)	2,58 (0,55)	53,60 (8,08)	10,40 (2,17)	36,00 (9,79)
Verão	25,01 (5,20)	23,84 (0,38)	2,23 (0,45)	55,60 (7,35)	8,20 (1,87)	36,20 (6,71)
<b>Cerradinho</b>						
Outono	25,15 (1,46)	19,35 (1,80)	2,96 (0,37)	61,42 (3,78)	12,82 (2,54)	25,76 (2,46)
Inverno	22,51 (2,61)	23,62 (0,89)	3,33 (0,30)	60,00 (3,62)	14,00 (1,94)	26,00 (2,86)
Primavera	31,59 (1,54)	21,3 (0,49)	3,15 (0,28)	56,11 (1,41)	13,00 (1,93)	24,66 (1,11)
Verão	34,19 (1,32)	23,6 (0,63)	3,24 (0,71)	64,80 (2,97)	12,00 (2,10)	23,20 (1,68)
<b>Matinha</b>						
Outono	30,92 (6,39)	18,19 (1,00)	3,87 (0,66)	75,60 (2,27)	10,94 (2,42)	13,46 (1,09)
Inverno	28,27 (2,63)	22,45 (1,02)	4,11 (0,62)	70,80 (2,65)	15,20 (2,15)	14,00 (1,15)
Primavera	33,02 (2,38)	21,24 (0,34)	4,04 (0,82)	67,00 (9,67)	15,28 (4,34)	17,71 (12,06)
Verão	33,81 (4,30)	23,03 (0,52)	3,67 (0,67)	69,9 (3,24)	18,30 (3,65)	11,80 (0,91)

Fonte: do autor

UA: umidade atual do solo; TA: temperatura atual do solo; MO: teor de matéria orgânica do solo.

A variação da umidade do solo ao longo do ano de estudo pode ser observada na Figura 10.

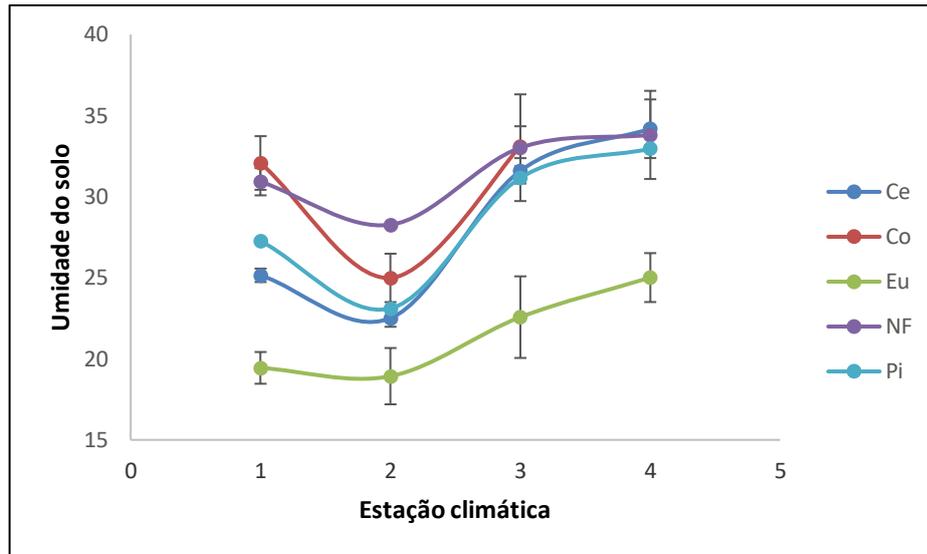


Figura 10 – Variação da umidade do solo (100\*kg/kg) em 2017 / 2018: (1) Outono, (2) Inverno, (3) Primavera e (4) Verão. Ce: fragmento Cerradinho; Co: Coffea spp.; Eu: Eucalyptus spp.; NF: fragmento Matinha; Pi: Pinus spp.

Fonte: do autor

Na Tabela 5 é observada a distribuição mensal dos dados climáticos do município de Lavras, Minas Gerais, referente ao ano de estudo 2017/2018.

Tabela 3 – Distribuição mensal dos dados climáticos do município de Lavras, Minas Gerais, referente ao ano de estudo 2017/2018.

Meses	VV	DV	PRE	TMa	TMi	UR
	ms <sup>-1</sup>		mm	°C		%
Janeiro/2017	1,38	Calma (C)	157,90	30,30	19,32	72,80
Fevereiro/2017	1,95	Leste (E)	64,10	29,90	18,62	69,64
Março/2017	1,75	Leste (E)	158,60	29,31	17,61	70,06
Abril/2017	1,77	Leste (E)	108,30	27,61	16,70	74,24
Mai/2017	1,66	Leste (E)	57,60	25,09	14,87	77,85
Junho/2017	1,71	Leste (E)	29,00	24,81	12,68	74,78
Julho/2017	2,33	Leste (E)	0,00	23,08	10,92	67,31
Agosto/2017	2,01	Leste (E)	4,00	26,51	12,39	61,81
Setembro/2017	2,04	Leste (E)	32,60	28,97	13,42	49,86
Outubro/2017	1,70	Leste (E)	125,30	29,31	17,13	63,11
Novembro/2017	1,55	Leste (E)	126,40	27,21	17,30	73,56
Dezembro/2017	1,58	Leste (E)	236,00	29,00	18,42	74,11
Janeiro/2018	1,25	Calma (C)	180,00	29,38	18,81	74,17
Fevereiro/2018	1,70	Leste (E)	154,00	28,60	18,69	74,50
Março/2018	1,22	Leste (E)	235,00	30,41	18,96	73,00

Fonte: Do autor

DV: Direção do Vento; VV: Velocidade do Vento; IT: Insolação Total; PRE: precipitação; TMa: Temperatura máxima; TMi: Temperatura mínima; UR: Umidade relativa do ar.

As Figuras 11, 12, 13 e 14 apresentam a correlação de cada índice de vegetação à variabilidade da umidade nas cinco coberturas vegetais.

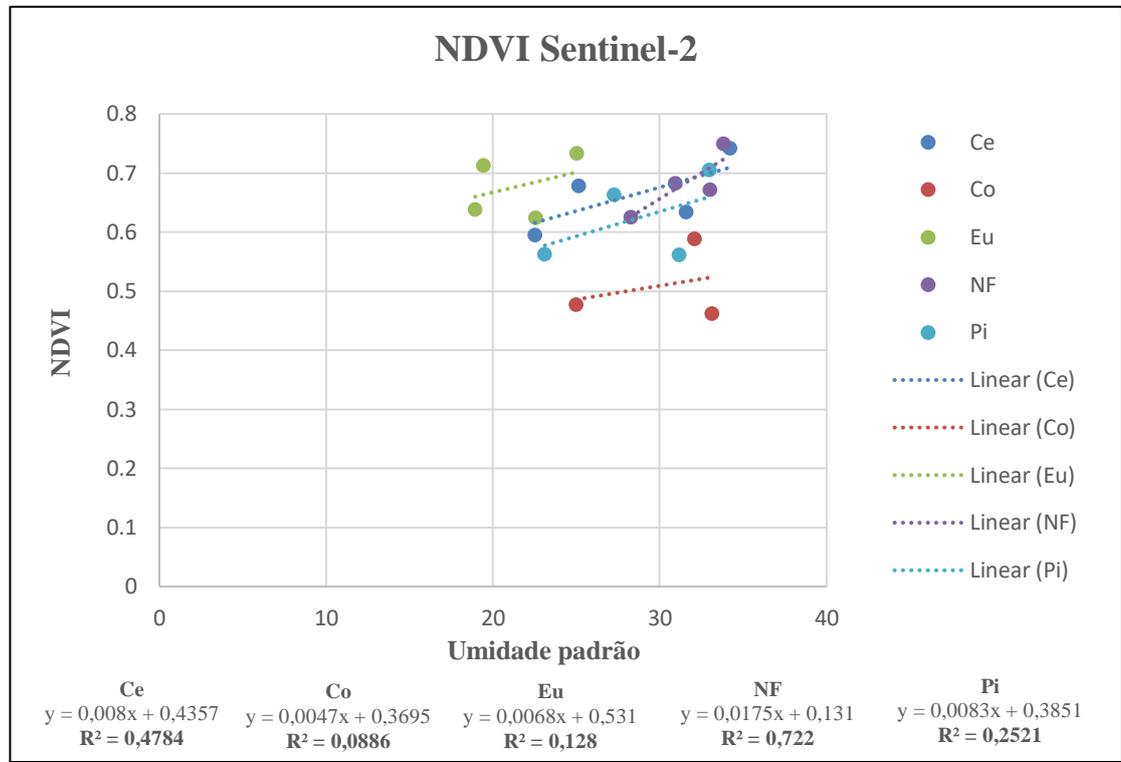


Figura 11– Correlação do IV NDVI com as coberturas de estudo a partir do Sentinel-2. Ce: fragmento Cerradinho; Co: Coffea spp.; Eu: Eucalyptus spp.; NF: fragmento Matinha; Pi: Pinus spp.

Fonte: do autor

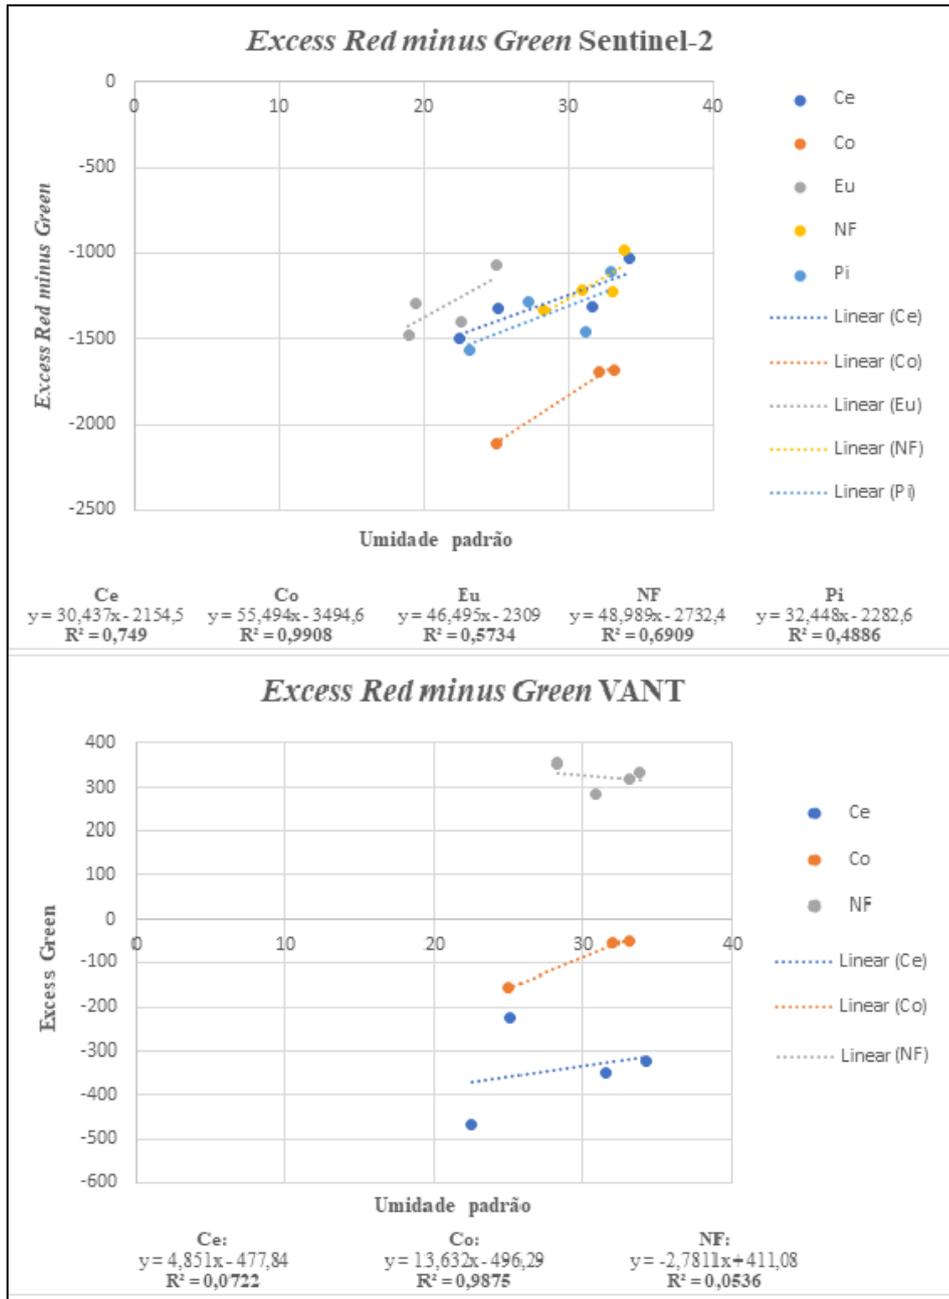


Figura 12 – Correlação do IV *Excess Red minus Green* com as coberturas de estudo a partir do Sentinel-2 e VANT. Ce: fragmento Cerradinho; Co: Coffea spp.; Eu: Eucalyptus spp.; NF: fragmento Matinha; Pi: Pinus spp. Fonte: do autor

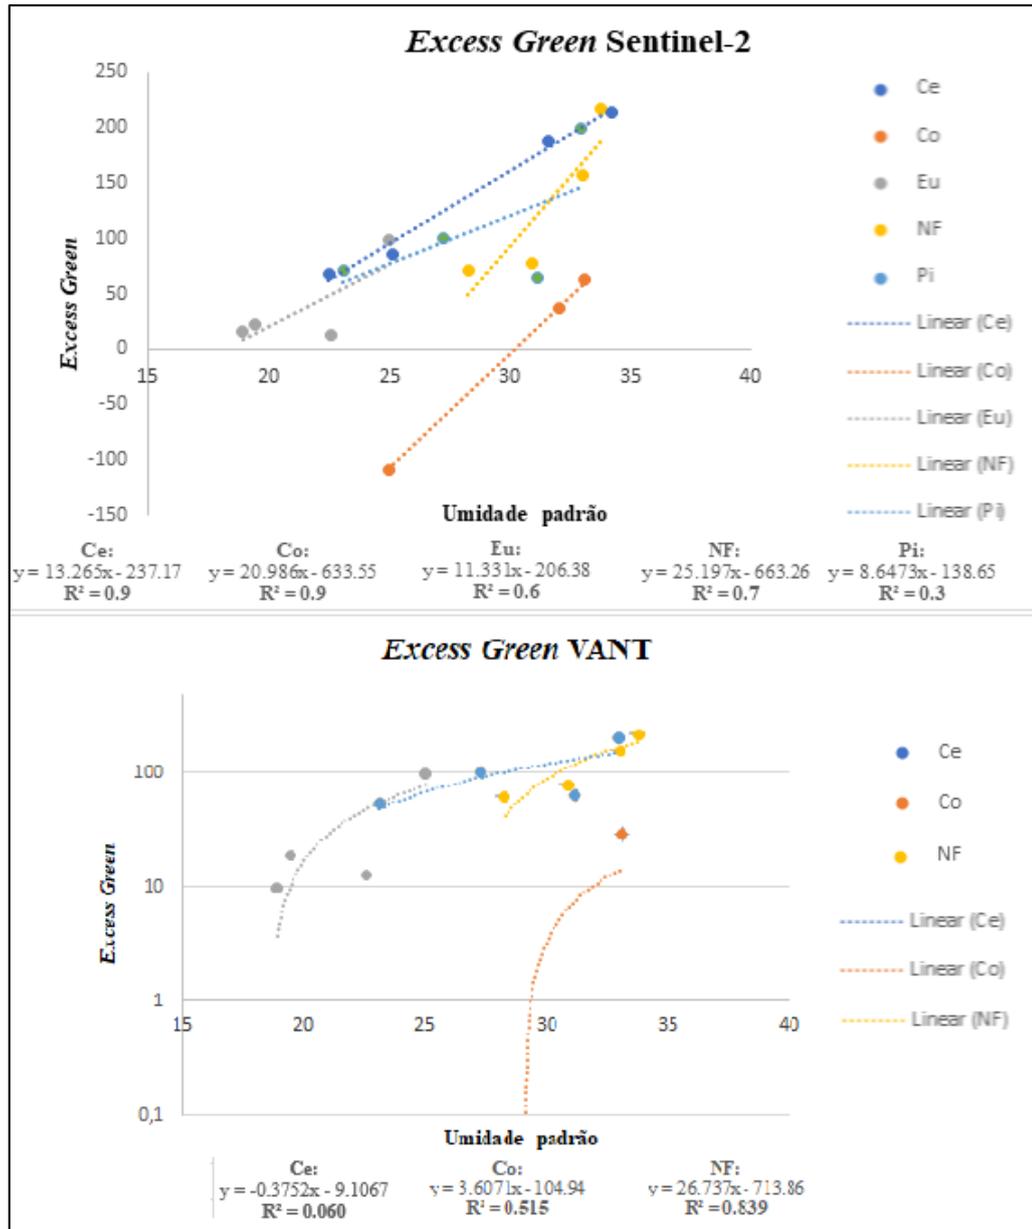


Figura 13 – Correlação do IV *Excess Green* com as coberturas de estudo a partir do Sentinel-2 e VANT. Ce: fragmento Cerradinho; Co: *Coffea* spp.; Eu: *Eucalyptus* spp.; NF: fragmento Matinha; Pi: *Pinus* spp.  
Fonte: do autor

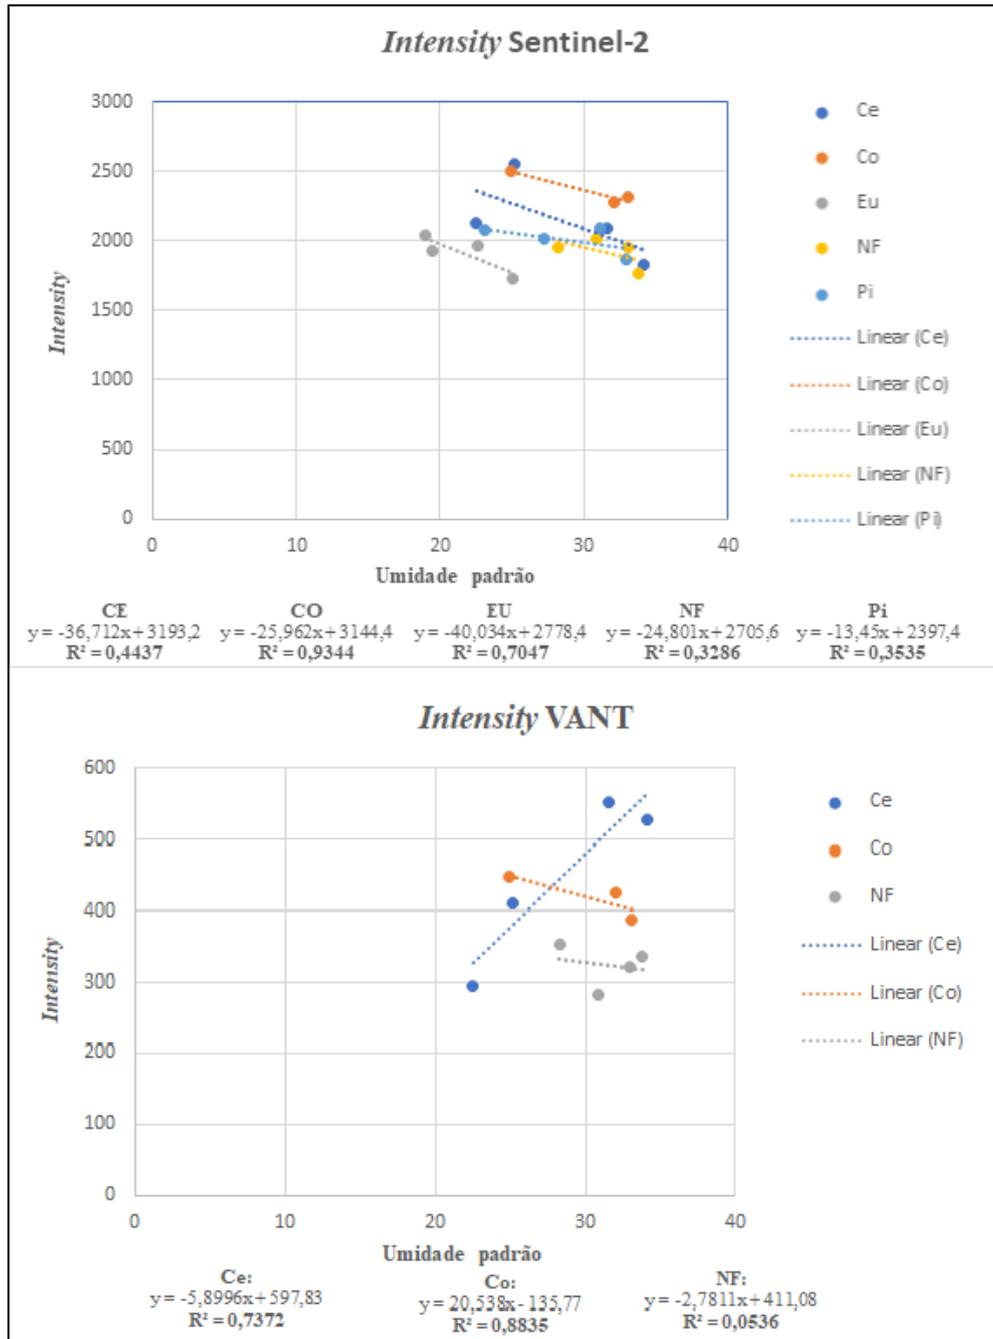


Figura 14 – Correlação do IV *Intensity* com as coberturas de estudo a partir do Sentinel-2 e VANT. Ce: fragmento Cerradinho; Co: Coffea spp.; Eu: Eucalyptus spp.; NF: fragmento Matinha; Pi: Pinus spp.  
Fonte: do autor

## 6 DISCUSSÃO

Os resultados ilustraram o potencial do SR nos estudos de coberturas vegetais e a capacidade das duas plataformas em atender diversas frentes de estudo. No entanto, a utilização destas tecnologias não substitui as práticas tradicionais de coletas em campo, visto que muitas informações só podem ser confirmadas ou detectadas *in situ* (*ground truth*). Desta forma, a

integração das duas técnicas é uma alternativa de baixo custo operacional e com resultados promissores, que confirmam a eficácia da configuração metodológica em pesquisas ecossistêmicas, que pode contribuir para o manejo e a conservação de áreas específicas, assim como subsidiar tomadas de decisões.

## 6.1 COMPARAÇÃO DO DESEMPENHO DOS SENSORES

As duas plataformas utilizadas apresentaram limitações, contudo o VANT com sensores RGB e NIR demonstrou algumas desvantagens em relação ao Sentinel-2. A principal delas foi no alinhamento das áreas de *Eucalyptus* spp. e *Pinus* spp., que impediu as análises destas coberturas. Os VANTs, em geral, apresentam dificuldades para o estudo de áreas homogêneas, pois reduzem a capacidade de detecção dos pontos de enlace (*tie points*) (MATESE et al., 2015, PÁDUA et al., 2017).

Para superar estas dificuldades, foram realizados testes em junho de 2018 para avaliar os efeitos da altitude e da sobreposição no alinhamento das imagens. O aumento do *overlap* e do *sidelap* foi de 10% em relação ao restante do estudo, isto é, foi de 90%, e as altitudes de voo nos testes foram de 100 e 110 m (40 e 50 m acima), com os parâmetros de processamento mantidos. Todavia, os problemas persistiram, mesmo com a obtenção de nuvens mais densas de pontos, que se concentraram nas intersecções das coberturas com as áreas de solo exposto e pastagem, o que confirma a influência da heterogeneidade no volume de detecção de pontos de interesse. Uma segunda tentativa foi a de alinhamento manual dessas imagens, em que pontos homólogos foram identificados ao longo dos registros, mas foi outra alternativa que resultou em insucesso.

Uma alternativa distinta para a correção do problema citado, mas que não foi avaliada nesta pesquisa, seria o processamento por outros algoritmos, como o SURF (*Speeded UP Robust Features*).

Cumpramos ressaltar, que o estudo dessas duas espécies é agravado também pela morfologia das folhas quando utilizados os VANTs. O *Eucalyptus* spp., por exemplo, apresenta folhas estreitas e de forma lanceolada, enquanto o *Pinus* spp. possui folhas de forma aciculada, que são ainda mais finas (IBÁ, 20015). Assim, a interação destes dosséis com a REM depende de um conjunto denso das folhas para registro da refletância, havendo, portanto, a necessidade de maiores altitudes de voo para o monitoramento dessas espécies, para facilitar a discriminação das copas.

Os sensores embarcados no VANT, por sua vez, demonstraram bom desempenho nos estudos vegetacionais. O sensor MAPIR é um equipamento de baixo custo, que apresentou limitações no estudo de *Eucalyptus* spp. e *Pinus* spp. também, não sendo gerados os ortomosaicos. Alguns problemas de alinhamento e detecção dos pontos de enlace também foram observados nas demais coberturas. Aliado a isto, os registros com disparos a cada 0,2 segundos geram um grande volume de imagens não sincronizadas àquelas obtidas pelo sensor RGB. Por isso, o *software* Photoscan, possivelmente, tenha limitações para realizar a sobreposição pela proximidade entre os registros, ou seja, o algoritmo pode interpretar que imagens estão na mesma posição e considera-las iguais, impossibilitando o alinhamento delas. Entretanto, modelos recentes de sensores MAPIR, como o 3.0 são acompanhados de GPS próprio, que pode garantir a permanência destes produtos como uma alternativa de baixo custo no monitoramento de coberturas vegetais.

O sensor RGB, em contrapartida, foi mais confiável, com desempenho satisfatório nas coberturas estudadas. A profundidade e a qualidade dos dados capturados pela câmera Sony EXMOR ressaltaram a capacidade deste modelo como ferramenta decisiva na eficácia dos estudos vegetais. Os ortomosaicos obtidos geraram produtos em alta resolução espacial (2,5 cm em média), assim como os Modelos Digitais de Superfície (MDS), de Terreno (MDT), 3D e as curvas de nível, que podem subsidiar diversos estudos e planos de manejo. Estes produtos enfatizam a capacidade destes dispositivos para mapeamento, contagem de plantas, monitoramento fitossanitário, gestão do uso e ocupação dos solos e em abordagens ecológicas. Os resultados são equivalentes aos de pesquisas com equipamentos similares (TURNER; LUCIEER; WATSON, 2012; NEX; REMONDINO, 2013; COLOMINA; MOLINA, 2014), que ressaltam o seu potencial em aplicações agroflorestais.

Já o satélite Sentinel-2 foi a alternativa mais estável no estudo, com bom desempenho em todas as áreas. O principal problema enfrentado foi persistência das nuvens entre abril e junho de 2017, que causou a falta de dados do período. Entretanto, esta plataforma apresenta grande potencial para as aplicações ambientais. Os resultados obtidos confirmam que o Sentinel-2 é uma ferramenta gratuita de alta resolução espectral e temporal, que fortalece o uso destes sensores (KOH, WICH; 2012; ASNER, 2015). O intervalo entre as imagens utilizadas neste estudo foi de 5 dias, que é uma vantagem a ser destacada nos monitoramentos vegetais, que requerem curtos intervalos entre os registros (ASNER, 2015; DANDOIS, 2015).

O Sentinel-2 foi essencial para o estudo do comportamento espectral do cafeeiro, que não foi amostrado pelo VANT no verão, devido ao replantio previamente ao planejado, mas foi monitorado pelo satélite. Os resultados ilustraram que esta plataforma possui boa acurácia no

monitoramento da umidade das lavouras a partir dos IV, como o NDVI. Devido as dificuldades operacionais enfrentadas com o sensor MAPIR, não foram obtidos resultados confiáveis do NDVI, para determinar qual plataforma apresentou melhor desempenho. Contudo, com o Sentinel-2 houve boa correlação entre os IV, demonstrando que apesar das limitações espaciais pode ser uma alternativa ao monitoramento agroflorestal.

Diante do exposto, os resultados obtidos e as dificuldades enfrentadas apontam um desempenho melhor da plataforma orbital em relação ao VANT. Entretanto, a flexibilidade e qualidade dos dados coletados pelo VANT não podem ser desconsiderados, devido principalmente a diferença de resolução espacial e as nuvens de pontos, que permitiram acessar dados estruturais dos fragmentos florestais que não são disponíveis a partir dos satélites, o que enfatiza a necessidade de novas pesquisas nestas coberturas para que eventuais ajustes tecnológicos aprimorem o desempenho das aeronaves não tripuladas.

A pesquisa confirmou que apesar dos avanços proporcionados pelos VANTs e pelos sensores, que podem ser utilizados, esta tecnologia ainda não compete com as técnicas tradicionais de fotografias aéreas ou de sensores orbitais, mas apresenta grande utilidade e versatilidade como ferramenta complementar aos estudos da superfície terrestre (GETZIN, WIEGAND, SCHÖNING, 2012; LAGÜELA et al., 2015; WARD et al., 2016; PÁDUA et al., 2017). Deste modo, a melhor opção para as pesquisas de monitoramento de coberturas vegetais a partir de SR é integrar as tecnologias convencionais e emergentes para obtenção de resultados confiáveis (KOH, WICH, 2012; MARVIN et al., 2016). No caso das plataformas usadas nesta pesquisa, as imagens obtidas pelo VANT poderiam ser utilizadas para a solução dos problemas de mistura espectral, por exemplo, que são muito comuns nas imagens orbitais, tornando possível que estudos multiespectrais sejam realizados de forma mais precisa e barata, utilizando a banda *Red-edge* do Sentinel-2, por exemplo, que é um realidade incompatível aos VANTs de menor custo, já que são sensores mais pesados e mais caros, limitando estas aeronaves a utilização de sensores de baixa performance (EISENBEISS, 2009).

## 6.2 ÍNDICES DE VEGETAÇÃO

As análises apresentaram resultados relevantes no monitoramento das coberturas propostas, pois foi possível determinar a partir dos IV a correlação entre a umidade do solo e a resposta espectral da vegetação ao longo de 2017 / 2018.

No outono e o verão, períodos de maior precipitação e baixa insolação, foram obtidos os maiores valores de NDVI e os menores valores dos demais índices de vegetação. Enquanto

no inverno e na primavera os padrões dos índices foram opostos, que se justifica pelo fato da considerável perda de folhas das coberturas neste período, que interferem na resposta espectral (Ponzoni et al. 2012). Foi possível determinar ainda que durante as estações mais secas houve uma maior variação nos valores de NDVI do cafeeiro, que não era irrigado, em relação as outras coberturas. Diante do exposto, verifica-se que o cafeeiro exigiu baixo custo de energia para a manutenção da evapotranspiração em relação as demais coberturas, pois os valores de NDVI indicam a resposta do fechamento estomático diante da escassez hídrica no solo deste período do ano, em que o cafeeiro por apresentar sistema radicular superficial tem maiores dificuldades para captação de insumos do que o Cerradinho e a Matinha, que são compostos por indivíduos de raízes mais profundas.

O índice de melhor desempenho no estudo de *Coffea spp.* foi o *Excess Green* ( $\rho = 0,96$ ), seguido pelo *Excess Red minus Green* ( $\rho = 0,94$ ) e NDVI ( $\rho = -0,99$ ). Em relação aos fragmentos florestais, a melhor correlação foi o NDVI, na Matinha ( $\rho = 0,90$ ) e no Cerradinho ( $\rho = 0,81$ ). Os demais índices foram superiores no Cerradinho, com *Excess Red minus Green* ( $\rho = 0,75$ ) e *Excess Green* ( $\rho = -0,29$ ), e inferiores na Matinha, com *Excess Red minus Green* ( $\rho = 0,37$ ) e *Excess Green* ( $\rho = -0,30$ ).

As áreas de *Pinus spp.* e *Eucalyptus spp.* não apresentaram resultados expressivos a partir dos índices de vegetação. Isto, aponta a necessidade de mais estudos sobre estas coberturas a partir de IV, pois estas espécies exóticas, ocupam grande parte do território brasileiro, devido sua fácil adaptabilidade aos diversos ambientes (IBÁ, 2015). Assim, o desenvolvimento de índices específicos para estas coberturas ou a combinação de vários IV para o seu monitoramento são algumas alternativas para melhorar o manejo destes povoamentos. Pois, o estudo dos mesmos a baixas altitudes com VANT também foi um problema verificado nesta pesquisa, pela impossibilidade de gerar os ortomosaicos na escala trabalhada. A partir de satélites, estudos dessas coberturas com IV, como o NDVI, o SAVI e o GNDVI, por exemplo, obtiveram resultados satisfatórios (GOERGE et al, 2016; PONZONI,; SHIMAKUBURO; KUPLICH, 2012).

Os resultados obtidos confirmaram os IV como ferramentas de auxílio ao monitoramento ambiental da vegetação, principalmente quando utilizados em conjunto ou a partir da combinação de plataformas remotas.

### 6.3 ESTADO DA ARTE

Os resultados obtidos pelas duas plataformas no monitoramento do cafeeiro são relevantes, especialmente devido à carência de trabalhos científicos sobre esta temática. Apesar da menor correlação com alguns dos IV testados com o VANT, os produtos obtidos a partir dos sensores podem ser úteis ao manejo dessas lavouras, e se integrados ao maior intervalo espectral dos satélites podem favorecer o acompanhamento da cultura, conforme outros estudos publicados que encontraram maior relação da umidade com os canais do infravermelho médio (CARTER, 1991; JEGER; PAUTASSO, 2008; KHANAL, FULTON, SHERER, 2017).

a A alta resolução espacial dos ortomosaicos do sensor RGB é importante nos estudos de agricultura de precisão, pois torna possível o monitoramento adequado de pragas e de possíveis estresses que podem ocorrer no cultivo. Mas é possível, também, a extração de outras variáveis de interesse, como a contagem de plantas por ruas, mapeamento dos talhões e a determinação da biomassa, que são dados determinantes das estimativas de produção (SILVA, ALVES, 2013) (Figura 11). Desta forma, há impacto direto nos custos produtivos, pois os gastos são reduzidos e permitem ações pontuais ao invés de abordagens em grande escala.

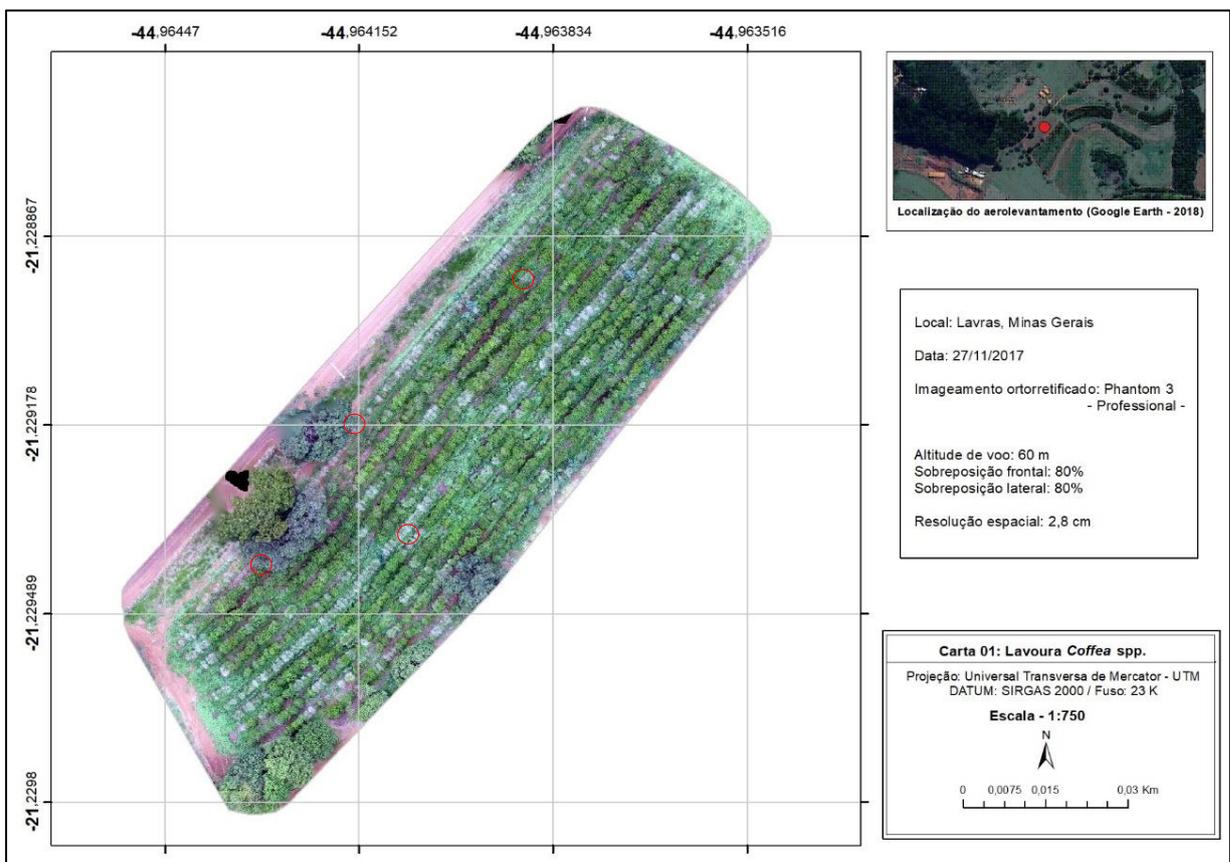


Figura 11 - Ortomosaico do cafeeiro, com destaque para a detecção de mudas individuais e possíveis contagens entre as ruas.

Fonte: do autor

As nuvens de pontos desta cultura, sob análise 3D no *software* Cloud Compare facilitaram a compreensão da biomassa, assim como a detecção de falhas de plantio, que são fatos essenciais aos produtores para maximizar as colheitas e minimizar os investimentos. Representam ainda, um avanço nas possibilidades de conservação do solo e da água, pois com o aumento das demandas pelas *commodities*, os processos de intervenção na cobertura vegetal se intensificam e favorecem a erosão hídrica, por exemplo (MARTINELLI; FILOSO, 2008). A modelagem destes processos é necessária ao setor agrícola, principalmente com as mudanças climáticas que geram desequilíbrios ecossistêmicos. Estes estudos requerem análises multitemporais, para melhorar as estimativas de perdas de solo, promovendo instrumentos técnicos para políticas de planejamento e manejo adequado das áreas afetadas (VICENTE-SERRANO, 2011). Neste cenário, o uso de plataformas orbitais e VANTs são uma alternativa, por oferecerem produtos em escala de detalhe, com flexibilidade temporal, que contribui para o desenvolvimento de tecnologias regionalizadas de mitigação de impactos e monitoramento da suas eficiências (SILVA, ALVES, 2013; MULUNGU, MUNISHE, 2007).

Este estudo, que foi conduzido no sul de Minas Gerais, apresenta resultados de importância regional, visto que esta porção do estado é um parque cafeeiro antigo e que mantém práticas de cultivo mais tradicionais, sendo poucas as áreas mecanizadas (SILVA, BORGES, 1998; SILVA, ALVES, 2013). Contudo, estas informações não deixam de ser relevantes para um contexto mais abrangente, que considere a região produtora de café do Brasil, afinal a realidade socioeconômica da cafeicultura é ainda heterogênea, com grande distinção entre as formas de cultivo, o tamanho das áreas cultivadas e as práticas de manejo adotadas. Assim, os avanços tecnológicos, como os VANTs, devem ser explorados e incentivados, pois como demonstrado, são capazes de proporcionar a redução nos custos de produção e promover melhores colheitas, atendendo os pequenos e os grandes produtores. Embora haja poucos estudos científicos em agricultura de precisão com *Coffea* spp., pesquisas como a de Chemura, Mutanga e Dube (2017), Herwitz (2004) e Jhonson et al. (2003) aplicaram aeronaves não tripuladas no monitoramento desta cultura e obtiveram resultados de sucesso.

#### 6.4 SERVIÇOS ECOSSISTÊMICOS

As florestas cobrem um terço da superfície terrestre e são essenciais a vida, aos ecossistemas terrestres e a estabilização das paisagens (BURKHARD, MAES, 2017; METZGER, 2000). Pois, oferecem diversos serviços ecossistêmicos, em que um dos principais é a ciclagem de nutrientes ou ciclos biogeoquímicos. Isto é essencial para a manutenção da

produtividade dos ecossistemas, principalmente nas regiões tropicais (ROCHA et al., 2006; SCHELIESINGER, 1997). Contudo, o mapeamento desses serviços é um desafio, pois necessita de levantamentos de campo que possam auxiliar na compreensão da estrutura, da composição e da dinâmica dos remanescentes florestais (BURKHARD, MAES, 2017; WALLACE, 2016).

Os estudos florestais por sensores remotos ganharam um grande número de adeptos, pois as pressões antrópicas sobre as áreas naturais têm aumentado rapidamente, colocando em risco a diversidade biológica (GETZIN, 2014; VIANA, 1992). Como resultado da expansão da ocupação desordenada, diversos impactos já são perceptíveis. Um deles são as mudanças climáticas, que é um fenômeno diretamente influenciado pelo desequilíbrio do ciclo biogeoquímico do C (FOGARTY, 2018).

Pesquisas recentes buscam compreender o papel das mudanças climáticas na dinâmica das florestas mundiais (NOLAN et al., 2018), utilizando modelos de simulação capazes de avaliar o efeito das mesmas sobre os biomas (REHDFELDT et al., 2006). Resultados preliminares indicaram que as regiões mais afetadas estão nas grandes latitudes do Hemisfério Norte, no sudeste da América do Sul, nas florestas temperadas e tropicais da África, na Austrália e na Nova Zelândia (NOLAN et al., 2018). No Brasil, em relação ao ano de estudo, as temperaturas médias máximas e mínimas da série temporal de 1933 a 2017, apresentaram um aumento das temperaturas em 2,1° C e 2,4° C, respectivamente (IAG, 2017), que confirma os modelos de predição citados.

Diante disso, este tópico da pesquisa visou reunir os diversos estudos já publicados nas áreas do Campus da UFLA conjuntamente com os resultados aqui obtidos, para avaliar o potencial da integração dos sensores remotos com as pesquisas convencionais de campo na conservação dos ecossistemas terrestres.

Considerando os resultados obtidos, o uso integrado das tecnologias utilizadas, como proposto no item 6.2, demonstra ser uma alternativa eficiente no monitoramento das coberturas vegetais, podendo subsidiar planos futuros de manejo e conservação das áreas do Campus e adjacências e, ainda, servir de exemplo motivador para outras áreas similares. Os ortomosaicos e as nuvens de pontos, por exemplo, permitiram a individualização das copas e também a detecção das clareiras naturais. Embora não tenham sido utilizados pontos de controle em campo, que impede que medidas precisas de altura do dossel sejam realizadas, o sensor RGB apresentou boa profundidade nas coberturas nativas (Figura 12 e Figura 13), o que viabilizou o acesso de informações estruturais relevantes à compreensão da morfologia destes fragmentos (CHAPIN III; MATSON; MOONEY, 2002; SETTELE et al., 2014).

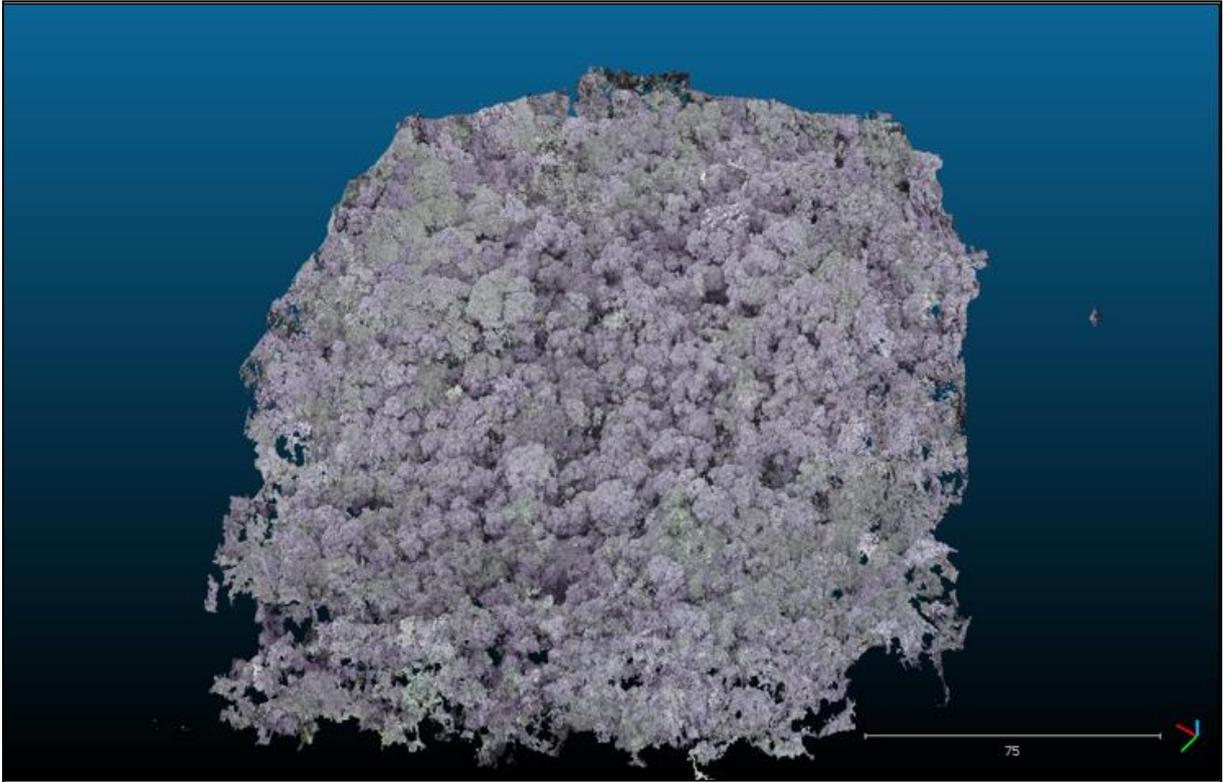


Figura 12 – Co-registro das nuvens de pontos do fragmento Matinha no *software* Cloud Compare.  
Fonte: do autor

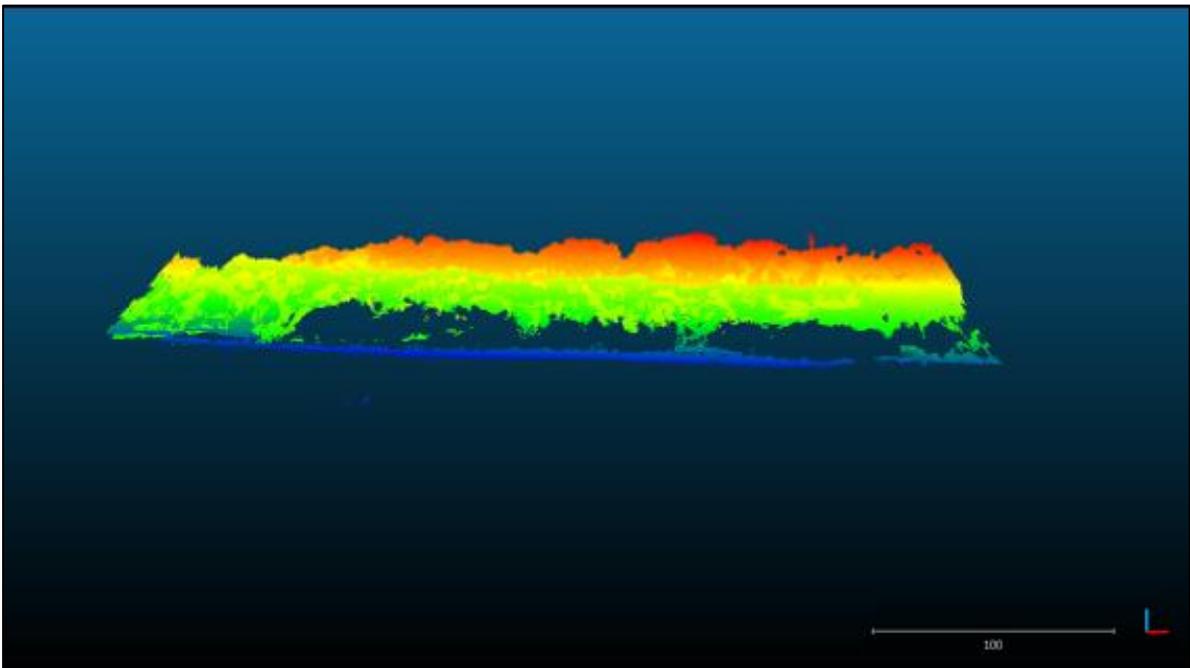


Figura 13 – Perfil do fragmento Cerradinho a partir de nuvem de pontos.  
Fonte: do autor

As clareiras naturais representam o resultado final de distúrbios ecológicos, sendo um elemento chave para a compreensão da estrutura e das dinâmicas florestais (KARKI; HALLGREN, 2015, HUBBELL; FOSTER 1986). Essas áreas influenciam a composição, a

distribuição e a riqueza de espécies dos fragmentos a partir de microhabitats, que fornecem maior quantidade de recursos, como a luminosidade, que promove a regeneração natural (BURTON et al., 2014; PEARSON et al. 2003). Assim, o monitoramento das clareiras é necessário para o manejo sustentável e garantia da estabilidade ecológica destes remanescentes, que pode gerar bons resultados, como os demonstrados por Getzin; Nuske; Wiegand (2014) e Chianucci et al. (2015).

A partir da combinação dos dados obtidos ao inventário florestal do remanescente Matinha, temos a presença de duas espécies de interesse. A primeira é a *Xylopia brasiliensis* (Pindaíba). Esta espécie é uma das mais representativas do fragmento, e estudos sobre a avifauna da região já indicaram a influência da mesma na ocorrência de *Aratinga leucophthalmus* (periquitão - maracanã / maritaca) (D'ÂNGELO-NETO et al., 1998; VASCONCELOS, BRAND e FILHO, 2002; LOMBARDI et al., 2012). Embora esta ave não esteja ameaçada de extinção, o tráfico internacional está afetando suas populações, com reduções significativas no número de indivíduos. Elas costumam ser facilmente registradas entre setembro e outubro, que é a época de frutificação da Pindaíba (D'ÂNGELO-NETO et al., 1998; LORENZI, 2002; BACKES; IRGANG, 2004). Portanto, a possibilidade oferecida pelo VANT de monitoramento individualizado destas árvores na paisagem, pode ser uma alternativa para a conservação das duas espécies, visto que a Pindaíba depende da *Aratinga leucophthalmus* para a dispersão das suas sementes, que são do tipo recalcitrantes e necessitam de escarificações mecânicas para a germinação (CARVALHO, 2006) (Figura 14).

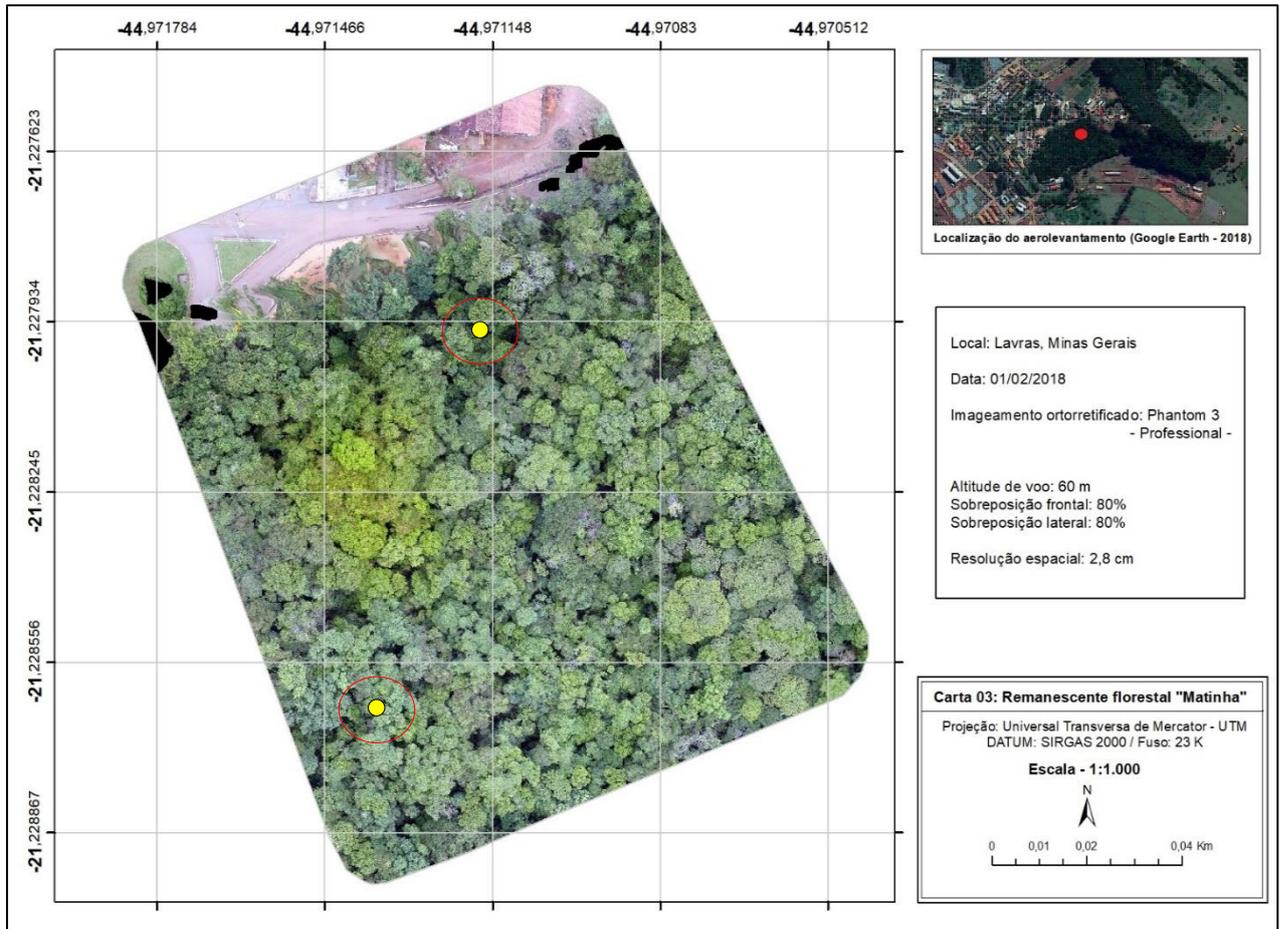


Figura 16 - Ortomosaico da Matinha, com indicação do ponto em GPS da *Xylopia brasiliensis* em amarelo, e possíveis localizações da espécie considerando os erros dos equipamentos, em vermelho.

A outra espécie de interesse é a *Diospyros hispida* (Caqui do cerrado). Ela compõe os hábitos alimentares do Lobo-guará (*Chrysocyon brachyurus*) (RODRIGUES et al., 2007), que é o maior canídeo silvestre e um dos principais dispersores de sementes, devido a sua área de vida de até 132 km<sup>2</sup> (RODDEN et al., 2004; ROCHA et al., 2005). Este animal é expressivo no sul de Minas Gerais, sendo identificado em diversos estudos (ROSA; SOUZA 2017; DIAS; PASSAMANI, 2018; MAZZA et al. 2018). Desta forma, embora a *Diospyros hispida* seja um indivíduo de menor representatividade nos fragmentos, a detecção da espécie para monitoramento pode colaborar para melhor compreensão dos hábitos do Lobo-guará na região, proporcionando o desenvolvimento de medidas ecológicas para a conservação desta espécie, que sofre principalmente com os atropelamentos na região (LAURINDO et al., 2017). Vale ressaltar, que a ocorrência deste animal também é um indicador da qualidade ambiental, pois animais de topo da cadeia alimentar são considerados como espécies-chave de um ecossistema e a sua ocorrência é relacionada à conservação dos ambientes (FONSECA et al., 1994; MOTTA-JÚNIOR et al., 1996).

A *Diospyros hispida* também pode ser utilizada como alternativa de monitoramento para outras espécies, como as abelhas, por exemplo. As abelhas são as responsáveis pela polinização da *Diospyros hispida* e estão em acelerado declínio populacional por conta da fragmentação e uso elevado de defensivos agrícolas, deixando de prestar diversos serviços ecossistêmicos (CARVALHO, 2006; IMPERATRIZ-FONSECA; SILVA, 2010). Ao considerarmos que o fragmento Matinha é próximo do cafeeiro, o uso do VANT combinado com o Sentinel-2, pode favorecer que estudos voltados à *Diospyros hispida* direcionem práticas de conservação das abelhas que podem agregar valor à produção cafeeira, melhorando a qualidade e a produtividade da cultura. Estudos como de Malerbo-Souza et al., 2002; Rickets, 2003, D'ávila e Marchini, 2013, Souza e Evangelista, 2007, já demonstraram o impacto dos serviços ecossistêmicos das abelhas nos cultivos *Coffea* spp..

Os resultados obtidos no monitoramento da umidade por IV e coletas de campo para matéria orgânica, também são importantes para a complementação de estudos ecossistêmicos. Os mesmos demonstraram que as duas variáveis possuem maior relação com as áreas nativas de estudo (Figura 9), e o acompanhamento delas ainda é uma tarefa morosa, pois exige grande número de coletas e a utilização de sensores é dificultada pela umidade e densidade dos dosses florestais (MARVIN et al., 2016). A matéria orgânica é importante ao desenvolvimento das plantas e a sua decomposição é influenciada por fatores ambientais, como a presença de oxigênio no solo, a temperatura, a umidade, a composição e a atividade da biota, por exemplo, podendo ser considerada um indicador de disponibilidade de nutrientes e de estruturação dos solos (LOSS et al., 2014). Nas florestas, a matéria orgânica tende a ser decomposta de forma mais rápida, já que as condições climáticas e a disponibilidade de resíduos vegetais (serapilheira) aceleram o processo de mineralização (FITTER, HAY, 2002).

Assim, o monitoramento da umidade combinado aos dados 3D obtidos pelas nuvens de pontos, permite o acompanhamento e o desenvolvimento das clareiras naturais identificadas, facilitando a compreensão do desenvolvimento do subbosque e conseqüentemente a regeneração dos remanescentes florestais (SETTELE et al., 2014). Logo, tais informações colaboram com possíveis estimativas de estoques de carbono, que são essenciais, quando consideramos que as florestas, que são o principal reservatório deste elemento, não estão conseguindo absorver as quantidades emitidas de CO<sub>2</sub> na atmosfera, deixando de realizar uma das suas principais funções, que é a de regulação climática (OLSCHEWSKI; BENITEZ 2005; NOLAN et al., 2018).

Sendo assim, foi possível determinar a partir da combinação dos resultados obtidos com os estudos já publicados sobre o Campus, que as integrações de tecnologias de baixo custo

podem complementar as análises ecossistêmicas e fornecer informações relevantes a diversas áreas de interesse, principalmente na de interação planta-animal, que são essenciais à manutenção das áreas naturais e ao combate à defaunação (ROCHA et al., 2006, KOH; WICH, 2012). Em conjunto, estas tecnologias podem ajudar a propor o desenvolvimento de práticas adequadas de manejo e conservação da paisagem em escala local e regional, permitindo a coleta de dados das condições atuais dos ecossistemas, que é um dos grandes desafios conservacionistas da atualidade (BURKHARD, MAES, 2017).

Iniciativas como a de conservação do Muriqui (*Brachyteles hypoxanthus*) a partir de estudos com VANTs e sensores termais, em Minas Gerais, é um dos exemplo de como esta integração metodológica pode ser bem sucedida na conservação de habitats e espécies ameaçadas de extinção (LISBOA, 2018).

## 7 CONCLUSÕES

Os índices de vegetação a partir de sensores a bordo de veículos aéreos não tripulados foi eficaz no monitoramento sazonal da vegetação e afeta positivamente a cafeicultura de precisão.

O manejo e conservação dos remanescentes Matinha e Cerradinho pode ser eficaz a partir da combinação de índices de vegetação e análises dos ortomosaicos, pois com a escala de detalhe destes produtos é possível a identificação e monitoramento de clareiras naturais e das copas das árvores, que são informações relevantes à compreensão das dinâmicas florestais.

Apesar de não serem avaliadas as áreas de *Pinus* spp. e *Eucalyptus* spp. a partir do veículo aéreo não tripulado, os testes realizados nestas coberturas são relevantes para pesquisas futuras que busquem o monitoramento específico destas espécies.

Os índices de melhor correlação à *Coffea* spp. foram o *Excess Green* e o *Excess Red minus Green*, enquanto para o Cerradinho e Matinha foi o NDVI.

## REFERÊNCIAS

ABER, J.; MARZOLFF, I.; RIES, J. **Small-Format Aerial Photography: Principles, Techniques and Geoscience Applications**. 1. ed. Amsterdam: Elsevier, 2010.

AGÜERA, F.; CARVAJAL, F.; PÉREZ, M. **Measuring sunflower nitrogen status from an unmanned aerial vehicle-based system and anon the ground device**. In: Conference on Unmanned Aerial Vehicle in Geomatics, Zurich, Switzerland. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. XXXVIII-1/C22 UAV-g, v. 38, p. 33-37, 2011.

AKAIA, M.; TAKENAKA, C. **Effects of illumination stress on photosynthesis of Quercus glauca Thru mb**. Plant and Soil, v. 237, n. 1, p. 137-146, 2001.

ALATORRE, L. C.; BEGUERÍA, S.; VICENTE-SERRANO, S. Evolution of vegetation activity on vegetated, eroded, and erosion risk areas in the central Spanish Pyrenees, using multitemporal Landsat imagery. **Earth Surface Processes and Landforms**, v. 36, n. 3, p. 309-319, 2011

AMADO, T.J.C.; COGO, N.; LEVIEN, R. **Eficácia relativa do manejo do resíduo cultural de soja na redução das perdas de solo por erosão hídrica**. Revista Brasileira de Ciência do Solo, Campinas, v.13, n.2, p.251-257, 1989.

AMARAL, J. A. T.; RENA, A. B.; AMARAL, J. F. T. **Crescimento vegetativo sazonal do cafeeiro e suas relações com fotoperíodo, frutificação, resistência estomática e fotossíntese**. Pesquisa Agropecuária Brasileira, v. 41, n. 3, p. 377-384, 2006.

ANAC – AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **A proposta de regulamento da Agência Nacional de Aviação Civil**. (2015). Disponível em: [http://www.anac.gov.br/Noticia.aspx?ttCD\\_CHAVE=1914](http://www.anac.gov.br/Noticia.aspx?ttCD_CHAVE=1914). Acesso em: 18 mar. 2016.

ANAC 2018 - <http://www.anac.gov.br/noticias/regulamentacao-da-anac-sobre-drones-completa-um-ano-em-vigor> - acesso em 07 de setembro de 2018

ANDERSON-TEIXEIRA, Kristina J. et al. **CTFS-ForestGEO: a worldwide network monitoring forests in an era of global change**. 2014. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/gcb.12712>>. Acesso em: 23 jul. 2017.

ASNER, Gregory P. et al. Quantifying forest canopy traits: Imaging spectroscopy versus field survey. **Remote Sensing of Environment**, v. 158, p. 15-27, 2015.

AUBERT, Eric; OLIVEIRA-FILHO, AT de. Análise multivariada da estrutura fitossociológica do sub-bosque de plantios experimentais de Eucalyptus spp. e Pinus spp. Lavras (MG). **Revista Árvore**, v. 18, n. 3, p. 194-214, 1994.

BACKES, Paulo; IRGANG, Bruno. **Mata Atlântica: as árvores e a paisagem**. Porto Alegre: Paisagem do Sul, 2004.

BARATI, S. **Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas.** *The Egyptian Journal of Remote Sensing and Space Science*, v. 14, n. 1, p. 49-56, 2011.

BAY, Herbert; TUYTELAARS, Tinne; VAN GOOL, Luc. Surf: Speeded up robust features. **In: European conference on computer vision. Springer, Berlin, Heidelberg, 2006.** p. 404-417.

BECKMAN, Noelle G.; ROGERS, Haldre S. Consequences of seed dispersal for plant recruitment in tropical forests: interactions within the seedscape. **Biotropica**, v. 45, n. 6, p. 666-681, 2013.

BELO, Felipe Augusto Weilemann. Desenvolvimento de Algoritmos de Exploração e Mapeamento Visual para Robôs Móveis de Baixo Custo. **Rio de Janeiro, 2006.**

BENNETT, E. M.; PETERSON, G. D.; GORDON, L. J. **Understanding relationships among multiple ecosystem services.** *Ecology letters*, v. 12, n. 12, p. 1394-1404, 2009.

BJÖRKMAN, O.; DEMMING, B., 1987. **Photon yield of O<sub>2</sub> evolution and chlorophyll fluorescence characteristics at 77K among vascular plants of diverse origins.** *Planta*: 170:489-504.

BLACK, C. A. (Ed.). **Methods of soil analysis. Part I:** physical and mineralogical methods. 2. ed. Madison: Soil Science Society of America, 1986.

BROGE, N.H., LEBLANC, E., 2000. **Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density.** *Remote Sensing of Environment* 76, 156–172.

BRYSON, Mitch et al. Airborne vision-based mapping and classification of large farmland environments. **Journal of Field Robotics**, v. 27, n. 5, p. 632-655, 2010.

BURKHARD, Benjamin; MAES, Joachim. **Mapping ecosystem services.** *Advanced Books*, v. 1, p. e12837, 2017.

BURTON, J. I.; GANIO, L. M.; PUETTMANN, K. J. Multi-scale spatial controls of understory vegetation in Douglas-fir–western hemlock forests of western Oregon, USA. **Ecosphere**, v. 5, n. 12, p. 1-34, 2014.

CARTER, Gregory A. Responses of leaf spectral reflectance to plant stress. **American Journal of Botany**, v. 80, n. 3, p. 239-243, 1993.

CARVALHO, Paulo Ernani Ramalho. **Espécies arbóreas brasileiras.** Brasília: Embrapa Informação Tecnológica, 2003.

CASTRO JUNIOR, L.G. **Mercados derivativos agropecuários:futuros, opções e cpr.** Lavras: UFLA/DAE, 2002.

CASTRO NETO, M. T. Efeito do déficit hídrico na transpiração e resistência estomática da mangueira. **Revista Brasileira de Fruticultura**, v. 25, n. 1, p. 23-95, 2003.

CHABOT, D.; BIRD, D.M. Evaluation of an off-the-shelf unmanned aircraft system for surveying flocks of geese. **Waterbirds**, v. 35, n. 1, p. 170-174, 2012.

CHAPIN, F. Stuart; MATSON, Pamela A.; MOONEY, Harold A. Terrestrial decomposition. **Springer New York**, 2002.

CHEMURA, Abel. The growth response of coffee (*Coffea arabica* L) plants to organic manure, inorganic fertilizers and integrated soil fertility management under different irrigation water supply levels. **International Journal of Recycling of Organic Waste in Agriculture**, v. 3, n. 2, p. 59, 2014.

CHEMURA, Abel; MUTANGA, Onesimo; DUBE, Timothy. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, v. 18, n. 5, p. 859-881, 2017.

CHIACCHIO, S. S.; TEIXEIRA; B. E.; TECH, A. R. B. VANT: Um estudo sobre a utilização de Veículo Aéreo Não Tripulado na agricultura de precisão. **Revista Espacios** 2016.

CHIANUCCI, F., DISPERATI, L., GUZZI, D., et al., 2016. Estimation of canopy attributes in beech forests using true colour digital images from a small fixed-wing UAV. **International journal of applied earth observation and geoinformation**, v. 47, p. 60-68, 2016.

Civil Aviation Authority. (2012, Aout 10). CAP 722: Unmanned Aircraft System Operations in UK Airspace - Guidance. Récupéré sur <http://www.caa.co.uk/application.aspx?catid=33&pagetype=65&appid=11&mode=detail&id=45>

CNES – Centre National D’Études Spatiales. Disponível em: <<https://cnes.fr/en>>. Acesso em: 17 dez. 2017.

COELHO, L.; BRITO, J. N. **Fotogrametria digital**. Ed. UERJ. 2007. 196 p.

COLÔMBIA. AERONAUTICA CIVIL DE COLOMBIA. **Regulamentacion aéros no tripulados – UAVs Operation**. Bogotá, 2015. Disponível em: <http://www.aerocivil.gov.co/AAeronautica/Rrglamentacion/CINAeronauticas/Biblioteca%20Conceptos%20Interpretativos/AEREOS%20NO%20TRIPULADOS-UAVS-OPERACION.pdf>. Acesso em: 08 set. 2018.

CÓRCOLES, J.I., ORTEGA, J.F., HERNÁNDEZ, D., et al., 2013. Estimation of leaf area index in onion (*Allium cepa* L.) using an unmanned aerial vehicle. **Biosyst. Eng.** **115 (1), 31–42**.

COSTANZA, R. Twenty years of ecosystem services: How far have we come and how far do we still need to go? **Ecosystem Services**, v. **28**, p. **1-16**, 2017.

CRIPPEN, R.E., 1990. Calculating the vegetation index faster. **Remote Sensing of Environment** **34**, **71–73**.

CROFT, H.; CHEN, J. M.; ZHANG, Y. The applicability of empirical vegetation indices for determining leaf chlorophyll content over different leaf and canopy structures. **Ecological Complexity**, v. 17, p. 119-130, 2014.

CROWTHER, T. W. et al. Mapping tree density at a global scale. **Nature**, [s.l.], v. 525, n. 7568, p.201-205, set. 2015. Disponível em: <[https://www.researchgate.net/publication/281532511\\_Mapping\\_tree\\_density\\_at\\_a\\_global\\_sc](https://www.researchgate.net/publication/281532511_Mapping_tree_density_at_a_global_scale) ale>. Acesso em: 20 jan. 2018.

DANDOIS, J.P.; ELLIS, E.C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**. 2013, 136, 259–276.

DAUGHTRY, C. S. T. et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DE VASCONCELOS, Marcelo Ferreira et al. Avifauna de Lavras e municípios adjacentes, sul de Minas Gerais, e comentários sobre sua conservação. **Unimontes Científica**, v. 4, n. 2, p. 153-165, 2008.

DIAS TEIXEIRA, Herly Carlos et al. Variação temporal de nutrientes na serapilheira de um fragmento de floresta estacional semidecidual montana em Lavras, MG. **Cerne**, v. 8, n. 2, 2002.

D'OLEIRE-OLTMANN, S. Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. **Remote Sensing**, v. 4, n. 11, p. 3390-3416, 2012.

DONNER, S.D., KUCHARIK, C.J., 2008. Corn-based ethanol production compromises goal of reducing nitrogen export by the Mississippi River. **Proceedings of the National Academy of Sciences**, v. 105, n. 11, p. 4513-4518, 2008.

DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern classification. 2001. **International Journal of Computational Intelligence and Applications**, v. 1, p. 335-339, 2001.

DUFFY, R. 2014. **Forget the war for biodiversity, it's just war. Just Conservation**. <http://www.justconservation.org/forget-the-warfor-biodiversity-its-just-war>. Acesso em: 12 set. 2014.

EDUARDO, A. A., & PASSAMANI, M. 2009. Mammals of medium and large size in Santa Rita do Sapucaí, Minas Gerais, southeastern Brazil. **Check List**, 5(3), 399–404.

EHSANI, R.; SANKARAN, S.; MAJA, J.M.; CAMARGO NETO, J. Affordable multi-rotor remote sensing platform for applications in precision horticulture. In: **11th International Conference Precision Agriculture**, Indianapolis, IN, July 15-18, 2012.

ELITH, J.; LEATHWICK, J. R.; HASTIE, T. A working guide to boosted regression trees. **Journal of Animal Ecology**, v. 77, n. 4, p. 802-813, 2008.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (Embrapa). **Análises químicas para avaliação da fertilidade do solo: métodos usados na Embrapa Solos**. Rio de Janeiro: Embrapa Solos, 1998.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (Embrapa). **Manual de Métodos de Análise de Solo**. Rio de Janeiro: Embrapa Solos, 1997.

ENGEL, V.L.; POGGIANI, F. Estudo da concentração de clorofila nas folhas e seu espectro de absorção de luz em função do sombreamento em mudas de quatro espécies florestais nativas. **Revista Brasileira de Fisiologia Vegetal**, v.3, p.39 - 45,1991.

European Space Agency - ESA. **Introducing Sentinel-2**. Disponível em: <[http://www.esa.int/Our\\_Activities/Observing\\_the\\_Earth/Copernicus/Sentinel-2/Introducing\\_Sentinel-2](http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel-2/Introducing_Sentinel-2)>. Acesso em: 17 dez. 2017.

ESPAÑA. **Real Decreto-ley 8/2014**, de 4 de julio, de aprobación de medidas urgentes para el crecimiento, la competitividad y la eficiencia. Sección 6º. Artículo 50. Madrid, 2014. Disponível em: <[http://www.fomento.es/NR/rdonlyres/86D0572B-5FDF-4994-9E66-12903CFE963FA1D/125965/RDley\\_8\\_2014.pdf](http://www.fomento.es/NR/rdonlyres/86D0572B-5FDF-4994-9E66-12903CFE963FA1D/125965/RDley_8_2014.pdf)>. Acesso em: 19 set. 2018.

EVANS, Christopher. Notes on the opensurf library. **University of Bristol, Tech. Rep. CSTR-09-001**, January, 2009.

FAO - Food and Agriculture Organization of the United Nations. **Relatório Estado dos Bosques do Mundo. 2017**.

FARLEY, Kathleen A.; JOBBÁGY, Esteban G.; JACKSON, Robert B. Effects of afforestation on water yield: a global synthesis with implications for policy. **Global change biology**, v. 11, n. 10, p. 1565-1576, 2005.

FAVORETO, L., MEYER, M. C., KLEPKER, D., CAMPOS, L. J. M., & PAIVA, E. V. (2015). Ocorrência de *Aphelenchoides* sp. em plantas de soja com sintomas de Soja Louca II. In *Embrapa Soja-Resumo em anais de congresso (ALICE)*. In: **CONGRESSO BRASILEIRO DE NEMATOLOGIA**, 32., 2015, Londrina.

FERRAZ, Silvio FB et al. How good are tropical forest patches for ecosystem services provisioning? **Landscape ecology**, v. 29, n. 2, p. 187-200, 2014.

FERREIRA, E.; MACHADO, R. V.; ANDRADE, H. **Sensoriamento Remoto**. Lavras; UFLA/FAEPE, 2000. 23p. Apostila.

FERRIER, S.; DRIELSMA, M. Synthesis of pattern and process in biodiversity conservation assessment: a flexible whole-landscape modelling framework. **Diversity and Distributions**, v. 16, n. 3, p. 386-402, 2010.

FINN, R.L., AND D. WRIGHT. 2012. Unmanned aircraft systems: Surveillance, ethics and privacy in civil applications. **Computer Law & Security Review** 28: 184–194.

FITTER, A. H.; HAY, R. K. M. **Environmental plant physiology**. 2002.

FLORENZANO, T.G., 2007. **Iniciação em Sensoriamento Remoto**. 2 ed. São Paulo: 2007. for conservation. *Trop. Conserv. Sci.* 5, 121–132.

FRANKE, J.; KEUCK, V.; SIEGERT, F. Assessment of grassland use intensity by remote sensing to support conservation schemes. **Journal for Nature Conservation**, v. 20, n. 3, p. 125-134, 2012.

GANDHI, G. Meera et al. NDVI: vegetation change detection using remote sensing and GIS—A case study of Vellore District. **Procedia Computer Science**, v. 57, p. 1199-1210, 2015.

- GAO, Y. Investigation and dynamic analysis of the long runout catastrophic landslide at the Shenzhen landfill on December 20, 2015, in Guangdong, China. **Environmental Earth Sciences**, v. 76, n. 1, p. 13, 2017.
- GATES, D. M., KEEGAN, H. J.; SCHLETER, J. C.; WEIDNER, V.R. Spectral properties of plants. **Applied optics**, v.4, n.1, p. 11-20, 1965.
- GETZIN, S.; NUSKE, R. S.; WIEGAND, K. Using unmanned aerial vehicles (UAV) to quantify spatial gap patterns in forests. **Remote Sensing**, v. 6, n. 8, p. 6988-7004, 2014.
- GETZIN, S.; WIEGAND, K.; SCHÖNING, I. Assessing biodiversity in forests using very high-resolution images and unmanned aerial vehicles. **Methods in Ecology and Evolution**, v. 3, n. 2, p. 397-404, 2012.
- GITELSON, A. A., Y. J. K., MERZLYAK, M. N. 1996. "Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS." **Remote Sensing of Environment** 58 (3): 289–298.
- GITELSON, A.A., KAUFMAN, Y.J., STARK, R., RUNDQUIST, D., 2002. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment** 80, 76–87.
- GOEL, N.S., QUIN, W., 1994. Influences of canopy architecture on relationships between various vegetation indexes and LAI and FPAR: a computer simulation. **Remote Sensing of Environment** 10, 309–347.
- GOLDMAN, R. L. Ecosystem services: How people benefit from nature. **Environment**, v. 52, n. 5, p. 15-23, 2010.
- GUIMARÃES, P. R. & R. COGNI. 2002. Seed cleaning of *Cupaniavernalis* (Sapindaceae) by ants: edge effect in a highland Forest in south-east Brazil. **Journal of Tropical Ecology** 18: 303-307.
- GUPTA, S. D.; IBARAKI, Y. **Plant Image Analysis: Fundamentals and Applications**. 2014
- GUYOT, G.; GUYON, D.; RIOM, J. Factors affecting the spectral response of forest canopies: a review. **Geocarto International**, v. 4, n. 3, p. 3-18, 1989.
- HANSEN, M. C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, [s.l.], v. 342, n. 15, p.850-853, 15 nov. 2013. Disponível em: <<http://science.sciencemag.org/content/342/6160/850>>. Acesso em: 23 fev. 2017.
- HERWITZ, S. R. et al. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. **Computers and electronics in agriculture**, v. 44, n. 1, p. 49-61, 2004.
- HILLEL, D. (1998) **Environmental Soil Physics: Fundamentals, Applications, and Environmental Considerations**. Academic Press, Waltham.
- HORCHER, A.; VISSER, R.J. Unmanned Aerial Vehicles: Applications for Natural Resource Management and Monitoring. In Proceedings of the Council on Forest Engineering.

**Proceedings 2004: Machines and People, The Interface, Hot Springs, AR, USA, 27–30 April 2004.**

HUBBELL, S. P. Canopy gaps and the dynamics of a neotropical forest. **Plant ecology**, p. 77-96, 1986.

HUETE, A., DIDAN, K., MIURA, T., RODRIGUEZ, E.P., GAO, X., FERREIRA, L.G., 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote sensing of environment**, v. 83, n. 1-2, p. 195-213, 2002.

HUETE, A.; JUSTICE, C.; V. L., WIM. MODIS vegetation index (MOD13). **Algorithm theoretical basis document**, v. 3, p. 213, 1999.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295-309, 1988.

IAG, 2017. **BOLETIM CLIMATOLÓGICO ANUAL DA ESTAÇÃO METEOROLÓGICA DO IAG/USP – 2017.**

IMPERATRIZ-FONSECA, Vera Lucia; NUNES-SILVA, Patrícia. As abelhas, os serviços ecossistêmicos e o Código Florestal Brasileiro. **Biota Neotropica**, v. 10, n. 4, 2010.

INDÚSTRIA BRASILEIRA DE ÁRVORES - IBÁ. **Relatório** Ibá 2015.

**INPE – Instituto Nacional de Pesquisas Espaciais.** Disponível em: <<http://www.inpe.br/>>. Acesso em: 15 dez. 2017.

JAMES, M. R.; QUINTON, J. N. Ultra-rapid topographic surveying for complex environments: the hand-held mobile laser scanner (HMLS). **Earth surface processes and landforms**, v. 39, n. 1, p. 138-142, 2014.

JEGER, Mike J.; PAUTASSO, Marco. Plant disease and global change—the importance of long-term data sets. **New Phytologist**, v. 177, n. 1, p. 8-11, 2008.

JENSEN, J.R, 2010. **Remote sensing of environment: An Earth resource perspective.**

JENSEN, J. R. **Introduction to digital image processing.** A Remote Sensing Perspective, 1996.

JOLY, C. A.; METZGER, J. P.; TABARELLI, M. Experiences from the Brazilian Atlantic Forest: ecological findings and conservation initiatives. **New Phytologist**, v. 204, n. 3, p. 459-473, 2014.

JONES, G.P., PEARLSTINE, L.G., PERCIVAL, H.F., 2006. An assessment of small unmanned aerial vehicles for wildlife research. **Wildl. Soc. Bull.** 34, 750–758.

JONES, H.G., SIRAUT, X.R., 2014. Scaling of thermal images at different spatial resolution: the mixed pixel problem. **Agronomy**, v. 4, n. 3, p. 380-396, 2014.

JORDAN, C.F., 1969. Derivation of leaf area index from quality of light on the forest floor. **Ecology** 50, 663–666.

JORGE, L. A. C. **Determinação da cobertura de solo em fotografias aéreas do Projeto Arara**. 2001. 97 f. Dissertação (Mestrado em Ciências da Computação) - Universidade de São Paulo, São Carlos, 2001.

JORGE, L. A. C.; BRANDÃO, Z. N.; INAMAZU, R. Y. Insights and recommendations of use of UAV platforms in precision agriculture in Brazil. In: **SPIE Remote Sensing**. International Society for Optics and Photonics, p. 923911-923911, 2014

KHANAL, Sami; FULTON, John; SHEARER, Scott. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p. 22-32, 2017.

KARKI, L.; HALLGREN, S. W. Tree-fall gaps and regeneration in old-growth cross timbers forests. **Natural Areas Journal**, v. 35, n. 4, p. 533-541, 2015.

KINIRY, J.R.; WILLIAMS, J.R.; GASSMAN, P.W.; DEBACKE, P. General, process-oriented model for two competing plant species. **Transactions American Society Agricultural Engineering**, v.35, p.801-810, 1992.

KOH, L.P., WICH, S.A., 2012. Dawn of drone ecology: low-cost autonomous aerial vehicles for conservation. **Tropical Conservation Science**, v. 5, n. 2, p. 121-132, 2012.

KOIKE, T., 1990. Autumn coloring, photosynthetic performance and leaf development of deciduous broad-leaved trees in relation to forest succession. **Tree Physiology**. 7:21-32.

KREPS, S., AND J. KAAG. 2012. The use of unmanned aerial vehicles in contemporary conflict: A legal and ethical analysis. **Polity** 44: 260–285.

KUMAR, R. Radiation from plants-reflection and emission: a review. (Research project n.5543). **Purdue Research Foundation**. 1974.

KYPARISSIS, A.; MANETAS, Y., 1993. Seasonal leaf dimorphism in a semi-deciduous Mediterranean shrub: ecophysiological comparisons between winter and summer leaves. **Acta Oecol.** 14:23-32.

LAMPARELLI, R.A.C.; ROCHA, J.V.; BORGHI, E. **Geoprocessamento e agricultura de precisão: fundamentos e aplicações**. Guaíba: Agropecuária, 2001. 118p.

LANDSAT. Disponível em:< <https://landsat.usgs.gov>>. Acessado em dezembro de 2017.

LARCHER, W. **Ecofisiologia vegetal**. Tradução: Carlos Henrique B.A. Prado. São Carlos, RiMa, 2000.

LAURINDO, R. D. S., NOVAES, R. L. M., SOUZA, R. F., SOUZA, V. F., FELIX, F., SOUTO, T. M., CUNHA, R. G. T., & GREGORIN, R. 2017. Mammals in forest remnants of an ecotonal Atlantic Forest Cerrado area from southeastern Brazil. **Neotropical Biology and Conservation**, 12(1), 19–29.

LEE, D.W. Simulating forest shade to study the development ecology of tropical plants: juvenile growth in three vines in India. **Journal of Tropical Ecology**, v.4, p.281-292, 1988.

LEE, H.-T., L.A. MEYN, AND S. KIM. 2013. Probabilistic safety assessment of unmanned aerial system operations. **Journal of Guidance, Control and Dynamics** 36: 610–617.

LEVINE, Jonathan M.; MURRELL, David J. The community-level consequences of seed dispersal patterns. **Annual Review of Ecology, Evolution, and Systematics**, v. 34, n. 1, p. 549-574, 2003.

LILLESAND, T.M.; KIEFER, R.W.; CHIPMAN, J.W. **Remote Sensing and Image Interpretation**. Hoboken: John Wiley & Sons Inc., 6<sup>a</sup> ed., 2008.

LINDON, F. C.; RAMALHO, J. C.; BARREIRO, M. G.; LAURIANO, J. A. Modulation of photosystem 2 reactions mediated by aluminium toxicity in Zea Mays. **Photosynthetica**, v. 34, n. 1, p. 151-156, 1997.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Oficina de Textos, 2015.

LOMBARDI, Vitor Torga et al. Registros notáveis de aves para o sul do estado de Minas Gerais, Brasil. **Cotinga**, v. 34, n. 1012, p. 32-45, 2012.

LORENZI, Harri. Árvores brasileiras: manual de identificação e cultivo de plantas arbóreas nativas do Brasil. **Nova Odessa: Editora Plantarum** 352p.-col. illus.. Por Geog, v. 4, 1992.

LONG, S. P.; POSTL, W.F.; BOLHÁR-NORDENKAMPF, H.R., 1993. Quantum yields for uptake of carbon dioxide in C<sub>3</sub> vascular plants of contrasting habitats. **Planta**. 189:226-234.

LOSS, A. Agregação, matéria orgânica leve e carbono mineralizável em agregados do solo. **Revista de la Facultad de Agronomía**, La Plata, v. 113, n. 1, p. 1-8, 2014

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. **Geocarto International**, v. 16, n. 1, p. 65–70, 1 mar. 2001.

LOWE, David G. Object recognition from local scale-invariant features. In: Computer vision, 1999. **The proceedings of the seventh IEEE international conference on**. Ieee, 1999. p. 1150-1157.

LUO, C., X. LI, AND Q. DAI. 2014. Biology's drones: New and improved. **Science** 344: 1351.

Intergovernmental Panel on Climate Change. (2014). **Climate Change 2014 – Impacts, Adaptation and Vulnerability: Part A: Global and Sectoral Aspects: Working Group II Contribution to the IPCC Fifth Assessment Report**. Cambridge: Cambridge University Press. doi:10.1017/CBO9781107415379

MACHADO, F. S., ALMEIDA, Á. F., BARROS, D. A., PEREIRA, J. A. A., SILVA, R. A., & PEREIRA, A. A. S. 2016. Diversity of medium-sized and large mammals from Atlantic Forest remnants in southern Minas Gerais state, Brazil. **Check List**, 12(5), 1–7.

MACHADO, F. S., MOURA, A. S., SANTOS, K. K., MENDES, P. B., ABREU, T. C. K., & FONTES, M. A. L. 2017. Registros ocasionais de mamíferos de médio e grande porte na

microrregião de Lavras e São João del Rei, Campo das Vertentes, Minas Gerais. **Revista Agrogeoambiental**, 9(1), 35–44.

MALERBO-SOUZA, Darcel Teresinha et al. Atrativo para as abelhas *Apis mellifera* e polinização em café (*Coffea arabica* L.). **Brazilian Journal of Veterinary Research and Animal Science**, p. 272-278, 2003.

MARTINELLI, Luiz A.; FILOSO, Solange. Expansion of sugarcane ethanol production in Brazil: environmental and social challenges. **Ecological applications**, v. 18, n. 4, p. 885-898, 2008.

MARR, D. (1982). **Vision: a Computational Investigation into the Human Representation and Processing of Visual Information**. São Francisco: W. H. Freeman.

MARVIN, David C. et al. Integrating technologies for scalable ecology and conservation. **Global Ecology and Conservation**, v. 7, p. 262-275, 2016.

MAZZA, I., ROSA, C. A., SOUZA, A. C., AXIMOFF, I., & PASSAMANI, M. 2018. Mamíferos de médio e grande porte registrados em florestas dominadas por *Araucaria angustifolia* na RPPN Alto Montana, Serra da Mantiqueira. **Oecologia Australis**, 22(1), 74–88. DOI: 10.4257/oeco.2018.2201.07

MEDEIROS, F. A. **Desenvolvimento de um veículo aéreo não tripulado para aplicação em agricultura de precisão**. 2007. 102 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Santa Maria, Santa Maria, 2007.

MELO, Bruno. **DRONES – REGULAMENTAÇÃO E PERSPECTIVAS, UM NOVO CAPÍTULO NA AVIAÇÃO CIVIL**. 2018. Disponível em: <<http://tmlaw.com.br/es/noticias/drones-regulamentacao-perspectivas-novo-capitulo-aviacao-civil>>. Acesso em: 25 mar. 2018.

MELO-DIAS, Mateus; PASSAMANI, Marcelo. MAMÍFEROS DE MÉDIO E GRANDE PORTE NO CAMPUS DA UNIVERSIDADE FEDERAL DE LAVRAS, SUL DO ESTADO DE MINAS GERAIS, BRASIL. **Oecologia Australis**, v. 22, n. 3.

MENESES, P.R.; ALMEIDA, T. **Introdução ao processamento de imagens de Sensoriamento Remoto**. 1. ed. Brasília: Conselho Nacional de Desenvolvimento Científico e Tecnológico, 2012. v. 1. 266p.

MERINO, L., F. CABALLERO, J. R. MARTÍNEZ-DE-DIOS, I. MAZA, AND A. OLLERO. 2011. “An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement.” **Journal of Intelligent & Robotic Systems** 65 (1–4): 533–548

MOTTA-JUNIOR, J. C. Variação temporal e seleção de presas na dieta do lobo-guará, *Chrysocyon brachyurus* (Mammalia: Canidae), na Estação Ecológica de Jataí, Luiz Antônio, SP. **Estudos integrados em ecossistemas. Estação Ecológica de Jataí**, v. 1, p. 331-346, 2000.

MOZOS, Oscar Martinez et al. Supervised semantic labeling of places using information extracted from sensor data. **Robotics and Autonomous Systems**, v. 55, n. 5, p. 391-402, 2007.

MESAS-CARRASCOSA et al. 2016. An Analysis of the Influence of Flight Parameters in the Generation of Unmanned Aerial Vehicle (UAV) Orthomosaics to Survey Archaeological Areas. **Sensors** 16 (11): 1838.

METZGER, J.P. Tree functional group richness and spatial structure in a tropical fragmented landscape (SE Brazil). **Ecological Applications**, v.10, p. 1147-1161, 2000.

MULUNGU, D. M. M.; MUNISHI, S. E. Simiyu River catchment parameterization using SWAT model. **Physics and Chemistry of the Earth**, v. 32, p. 1032–1039. 2007.

JAPÃO. MLIT. **Japan's safety rules on Unmanned Aircraft (UA)/Drone**. Disponível em: <<http://www.mlit.go.jp/en/koku/uas.html>>. Acesso em: 02 ago. 2018.

MULERO-PAZMANY, M., R. STOLPER, L.D. VAN ESSEN, J.J. NEGRO, AND T. SASSEN. 2014. remotely piloted aircraft systems as a rhinoceros anti-poaching tool in Africa. **PLoS ONE** 9: e83873.

MURAI, Shusuke. Man who landed drone on roof of Japanese prime minister's office gets suspended sentence. **The Japan Times**. Tokyo, fev. 2016. Disponível em: <<https://www.japantimes.co.jp/news/2016/02/16/national/crime-legal/man-landed-drone-roof-japanese-prime-ministers-office-gets-suspended-sentence/#.W7wHomhKjIV>>. Acesso em: 26 fev. 2017.

NACKAERTS, K. Evaluation of a lightweighth UAS-prototype for hyperspectral imaging. International Archives of Photogrammetry, **Remote Sensing and Spatial Information Sciences**, v. 38, n. Part 1, 2010.

NEALE, P.J., 1987. Algal photoinhibition and photosynthesis in the aquatic environment. In: KYLE, D.J., OSMOND, C.B.; ARTZEN, C.J. (eds) Photoinhibition. **Elsevier**, Amsterdam. Pp. 36-64.

NETO, SANTOS D.'ANGELO et al. Avifauna de quatro fisionomias florestais de pequeno tamanho (5-8 ha) no campus da UFLA. **Revista Brasileira de Biologia**, v. 58, n. 3, p. 463-472, 1998.

NEX, Francesco; REMONDINO, Fabio. UAV for 3D mapping applications: a review. **Applied geomatics**, v. 6, n. 1, p. 1-15, 2014.

NEWCOME, L.R. **Unmanned Aviation: A Brief History of Unmanned Aerial Vehicles**; American Institute of Aeronautics and Astronautics, Inc.: Reston, VA, USA, 2004.

NIJLAND, W., COOPS, N.C., MACDONALD, E.S., NIELSEN, S.E., BATER, C.W., JOHN STADT, J., 2015. Comparing patterns in forest stand structure following variable harvests using airborne laser scanning data. **For. Ecol. Manag.** 354, 272–280.

NOLAN, Connor et al. Past and future global transformation of terrestrial ecosystems under climate change. **Science**, v. 361, n. 6405, p. 920-923, 2018.

NOVO, E.M.L.M. **Sensoriamento Remoto: Princípios e Aplicações**. Ed. Edgard Blucher Ltda, 2010.

- OACI – Organização Internacional de Aviação Civil. **Circular ICAO 328-NA/190**, Unmanned Aircraft Systems (UAS). Montreal, Quebec, Canadá, 2011. Disponível em: [http://www.icao.int/Meetings/UAS/Documents/Circular%20328\\_en.pdf](http://www.icao.int/Meetings/UAS/Documents/Circular%20328_en.pdf). Acesso em: 13 Jul. 2015.
- OLSCHEWSKI, Roland; KLEIN, Alexandra-Maria; TSCHARNTKE, Teja. Economic trade-offs between carbon sequestration, timber production, and crop pollination in tropical forested landscapes. **Ecological Complexity**, v. 7, n. 3, p. 314-319, 2010.
- OLIVEIRA, A.; FERREIRA, E. **Fotointerpretação**. Editora UFLA, 2005. 132 p.:il.
- OLIVEIRA, A.H. et al. Caracterização ambiental e predição dos teores de matéria orgânica do solo na Sub-Bacia do Salto, Extrema, MG. **Semina: Ciências Agrárias**, v. 33, n. 1, p. 143-154, 2012.
- OLIVEIRA-FILHO, A. T.; CURI, N.; VILELA, E. A. & CARVALHO, D. A. 2001. Variation in tree community composition and structure with changes in soil properties within a fragment of semideciduous forest in southeastern Brazil. **Edinburgh Journal of Botany** 58(1): 139-158.
- PÁDUA, Luís et al. UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International journal of remote sensing**, v. 38, n. 8-10, p. 2349-2391, 2017.
- PANEQUE-GÁLVEZ, J., McCALL, M., NAPOLETANO, B., WICH, S., KOH, L., 2014. Small drones for community-based forest monitoring: an assessment of their feasibility and potential in tropical areas. **Forests** 5, 1481–1507.
- PEARSON, R.L.; MILLER, L.D. Remote mapping of standing crop biomass for estimation of the productivity of the short grass prairie, In: **8<sup>TH</sup> INTERNATIONAL SYMPOSIUM OF REMOTE SENSING OF ENVIROMENT**, 1972, Pawnee National Grassland, Colorado, Ann Arbor. P. 1.357-1381.
- PEARSON, T. R. H., D. F. R. P. BURSLEM, R. E. GOERIZ, AND J. W. DALLING. 2003. Interactions of gap size and herbivory on establishment, growth, and survival of three species of neotropical pioneer trees. **Journal of Ecology** 91: 785 – 796.
- PEREIRA, S.; OLIVEIRA FILHO, D.; MANTOVANI, E. C.; RAMOS, M. M.; MARTINS, J. H. Reflectometria no domínio do tempo na determinação do conteúdo de água no solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 10, n. 2, p. 306-314, 2006.
- PEREIRA, Israel Marinho et al. Evaluation and proposal of connectivity of remnant fragments in the campus of Universidade Federal de Lavras, Minas Gerais. **Cerne**, v. 16, n. 3, p. 305-321, 2010.
- PEIXOTO, P. H. P.; DA MATTA, F. M.; CAMBRAIA, J. Responses of the photosynthetic apparatus to aluminium stress in two sorghum cultivars. **Journal of Plant Nutrition**, v. 25, n.4, p. 821-832, 2002

PONZONI, F. J.; SHIMAKUBURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da vegetação**, 2ª edição atualizada e ampliada. São Paulo, Oficina dos textos. 2012.

PONZONI, F.J. **Sensoriamento remoto no estudo da vegetação**: diagnosticando a mata Atlântica. São José dos Campos: INPE, 2002.

PRADO, M. R., CÂNDIDO, E. R., & GIUDICE, G. M. L. 2008. Mamíferos de médio e grande porte em um fragmento de Mata Atlântica, Minas Gerais, Brasil. **Revista Árvore**, 32(4), 741–749

POSPIŠILOVÁ, J.; ŠANTRUCEK, J., 1994. Stomatal patchiness. **Biol. Plant.** 36:481-519

QI, J., CABOT, F., MORAN, M.S., DEDIEU, G., 1995. Biophysical parameter estimations using multidirectional spectral measurements. **Remote Sensing of Environment** 54, 71–83.

RANGO, A., LALIBERTE, A., HERRICK, J. E., WINTERS, C., HAVSTAD, K., STEELE, C., & BROWNING, D. Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. **Journal of Applied Remote Sensing**, v. 3, p. 1–15, 2009.

RASI, J. R. **Desenvolvimento de um veículo aéreo não tripulado para aplicação em pulverização agrícola**. 2008.70f. Dissertação (Mestrado em Engenharia Rural) - Universidade Federal de Pelotas, RS. RESEARCH SYSTEMS. What's new in ENVI 4.2. Boulder: Research Systems Inc, 2005. 160 p.

REHFELDT, Gerald E. et al. Empirical analyses of plant-climate relationships for the western United States. **International Journal of Plant Sciences**, v. 167, n. 6, p. 1123-1150, 2006.

REINO UNIDO. CIVIL AVIATION AUTHORITY. **Unmanned Aircraft and Aircraft Systems**. Londres, 2015. Disponível em: <http://www.caa.co.uk/default.aspx?CATID=1995>. Acesso em: 13 jul. 2018.

RICKETTS, T. H. Tropical forest fragments enhance pollinators activity in nearby coffee crops. *Conservation Biology*, **Califórnia**, v.18, n.5, p.1262-1271, 2004.

RISSINI, A. L.; KAWAKAMI, J.; GENÚ, A. M. Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. **Revista Brasileira de Ciência do Solo**, v. 39, n. 6, 2015.

ROCHA, C.F.D., BERGALLO, H.G., SLUYS, M.V., ALVES, M.A.S., 2006. **Biologia da conservação: essências**. Editora Rima.

RODDEN, M.; RODRIGUES, F.; BESTELMEYER, S. Maned wolf (*Chrysocyon brachyurus*). **Canids: Foxes, Wolves, Jackals and Dogs, Status Survey and Conservation Action Plan**. Gland and Cambridge: IUCN/SSC Canid Specialist Group, p. 38-43, 2004.

RODRIGUES, Flávio HG et al. Feeding habits of the maned wolf (*Chrysocyon brachyurus*) in the Brazilian Cerrado. **Mastozoología Neotropical**, v. 14, n. 1, 2007.

ROSA, C. A., CURI, N. H. A., PUERTAS, F., & PASSAMANI, M. 2017. Alien terrestrial mammals in Brazil: current status and management. **Biological Invasions**, 19(7), 2101–2123.

RONDEAUX, G., STEVEN, M., BARET, F., 1996. Optimization of soil adjusted vegetation indices. **Remote Sensing of Environment** 55, 95–107.

RUFINO, I.A. Alves; SILVA, S. T. Análise das relações entre dinâmica populacional, clima e vetores de mudança no semiárido brasileiro: uma abordagem metodológica. **Boletim de Ciências Geodésicas**, v. 23, n. 1, p. 167, 2017.

SANDBROOK, Chris. The social implications of using drones for biodiversity conservation. **Ambio**, v. 44, n. 4, p. 636-647, 2015.

SANKARAN, S. High-Resolution Aerial Imaging Based Estimation of Crop Emergence in Potatoes. **American Journal of Potato Research**, v. 94, n. 6, p. 658-663, 2017.

SANKARAN, S. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. **European Journal of Agronomy**, v. 70, p. 112-123, 2015.

SCARANO, F. R.; CEOTTO, P. Brazilian Atlantic forest: impact, vulnerability, and adaptation to climate change. **Biodiversity and Conservation**, v. 24, n. 9, p. 2319-2331, 2015.

SCHEFFER, M. Catastrophic shifts in ecosystems. **Nature**, v. 413, n. 6856, p. 591, 2001.

SCHLESINGER, W. H., 1997. **Biogeochemistry: An Analysis of Global Change**, 3rd Edition. Academic press 84.

SCHIFFMAN, R. 2014. Wildlife conservation drones flying high as new tool for field biologists. **Science** 344: 459.

SCHREIBER, Louise; OSTIARI, Emmanuelle. 2014. **Game of drones: do civilian applications harbour opportunities for sustainable development?** Disponível em:<[http://www.mirova.com/Content/Documents/Mirova/publications/va/studies/MIROVA\\_Study\\_Game\\_of\\_drones\\_EN.pdf](http://www.mirova.com/Content/Documents/Mirova/publications/va/studies/MIROVA_Study_Game_of_drones_EN.pdf)> Acesso em: 10 jun. 2018.

SENTHILNATH, J. et al. Detection of tomatoes using spectral-spatial methods in remotely sensed RGB images captured by UAV. **Biosystems Engineering**, v. 146, p. 16-32, 2016.

SETTELE, Josef et al. Terrestrial and inland water systems. In: Climate Change 2014 Impacts, Adaptation and Vulnerability: Part A: Global and Sectoral Aspects. **Cambridge University Press**, 2015.

SILVA, F.M., ALVES, M.C., 2013. **Cafecultura de precisão**. Editora UFLA, 2013.

SILVA, F.M.; BORGES, P.H.M. **Mecanização e agricultura de precisão**. Congresso Brasileiro de Engenharia Agrícola, 27, Poços de Caldas, MG. 1998.

SILVA, L. D., & M. PASSAMANI. 2009. Mamíferos de médio e grande porte em fragmentos florestais no município de Lavras, MG. **Revista Brasileira de Zootecias**, 11(2), 137–144.

SILVA, B. B. **Aplicações Ambientais Brasileiras com Geoprocessamento e Sensoriamento Remoto**. 2013.

SILVA, E. L. S.; PONZONI, F.J. Comparação entre a reflectância hemisférica de folhas e a reflectância bidirecional de um dossel. **Revista Árvore**, v. 19, n.4, p. 447-465, 1995.

SIMARD, M. et al. Mapping forest canopy height globally with spaceborne lidar. **J. Geophys. Res.** 116, 2011.

SNITCH, T. 2014. Poachers kill three elephants an hour. Here's how to stop them. **The Telegraph**. Disponível em: <http://www.telegraph.co.uk/news/earth/environment/conservation/10634747/Poachers-kill-three-elephants-an-hour.-Heres-how-to-stop-them.html>. Acesso em: 20 mar. 2017.

SPAROVEK, G.; DE JONG VAN LIER, Q.; DOURADO NETO, D. Computer assisted Koeppen climate classification: a case study for Brazil. **International Journal of Climatology**, v. 27, n. 2, p. 257-266, 2007.

SOUZA, Darklê Luiza; EVANGELISTA-RODRIGUES, Adriana; CALDAS PINTO, Maria do Socorro de. As abelhas como agentes polinizadores. REDVET. **Revista electrónica de Veterinária**, v. 8, n. 3, 2007

STÖCKER, Claudia et al. Review of the current state of UAV regulations. **Remote sensing**, v. 9, n. 5, p. 459, 2017.

STRASSBURG, B. B. N. et al. Moment of truth for the Cerrado hotspot. **Nature Ecology & Evolution**, 1, 0099, 2017.

SUH, J.; CHOI, Y. Mapping hazardous mining-induced sinkhole subsidence using unmanned aerial vehicle (drone) photogrammetry. **Environmental Earth Sciences**, v. 76, n. 4, p. 144, 2017.

SWAIN, K.C., THOMSON, S.J., JAYASURIYA, H.P.W. Adoption of an unmanned helicopter for low-altitude remote sensing to estimate yield and total biomass of a rice crop. **Transactions of the ASABE**, v. 53, n. 1, p. 21-27, 2010.

SWAIN, K.C.; ZAMAN, Q.U. **Rice crop monitoring with unmanned helicopter remote sensing images**. INTECH Open Access Publisher, 2012.

TAGEEVA, S. V.; BRANDT, A. B.; DEREVYANKO, V. S. Changes in optical properties of leaves in the course of the growing season. **Doklady** 135, p. 266-268.

TAIZ, L.; ZEIGER, E. **Plant physiology**. 2nd ed. Sinauer, Sunderland, Massachusetts, 1998.

TIAN, J. Comparison of UAV and WorldView-2 imagery for mapping leaf area index of mangrove forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 61, p. 22-31, 2017.

TORRES SÁNCHEZ, J. et al. Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. **PLoS One**, 8, e58210, 2013.

TOSCANI, P.; IMMITZER, M.; ATZBERGER, C. Wavelet-based texture measures for object-based classification of aerial images. **Photogrammetrie-Fernerkundung-Geoinformation**, v. 2013, n. 2, p. 105-121, 2013.

TUCKER, C.J., 1980. A spectral method for determining the percentage of green herbage material in clipped sample. **Remote Sensing of Environment** 9, 175–181.

TURNER, D.; LUCIEER, A.; WATSON, C. Development of an Unmanned Aerial Vehicle (UAV) for hyper resolution vineyard mapping based on visible, multispectral, and thermal imagery. In: En **Proceedings** of 34 th International Symposium on Remote Sensing of Environment. p. 1-4, 2011.

UFLA, 2016. **Eco Universidade: Plano Ambiental para uma universidade socioambientalmente correta**, 2016

VALAVANIS K. P., VACHTSEVANOS G. J. (Editors and authors of multiple Chapters), **Handbook of Unmanned Aerial Vehicles (UAVs)**, Springer, June/July 2014.

VERMEULEN, C., P. LEJEUNE, J. LISEIN, P. SAWADOGO, AND P. BOUCHE. 2013. Unmanned aerial survey of elephants. **PLoS ONE** 8: e54700.

VESCOVO, L., GIANELLE, D., 2008. Using the MIR bands in vegetation indices for the estimation of grassland biophysical parameters from satellite remote sensing in the Alps region of Trentino (Italy). **Advances in Space Research** 41, 1764–1772.

VIANA, Virgílio M.; TABANEZ, André JA; MARTÍNEZ, Juan LA. Restauração e manejo de fragmentos florestais. **Revista do Instituto Florestal (Brasil)** v. 4 (pt. 2) p. 400-406, 1992.

VIEIRA, Raísa Romênia S. et al. Compliance to Brazil's Forest Code will not protect biodiversity and ecosystem services. **Diversity And Distributions**, [s.l.], v. 24, n. 4, p.434-438, 28 dez. 2017. Wiley.

VINCINI, M.; FRAZZI, E.; D'ALESSIO, P. A broad-band leaf chlorophyll vegetation index at the canopy scale. **Precision Agriculture**, v. 9, n. 5, p. 303-319, 2008.

VITORINO, A. C. T. et al. Uso de energia ultra-sônica e turbidimetria na análise textural de pequenas amostras de solo. **Revista Ciências Técnicas Agropecuárias**, v. 16, p. 43-48, 2007.

WALLACE, L., A. LUCIEER, Z. MALENOVSKÝ, D. TURNER, AND P. VOPĚNKA. 2016.

“Assessment of Forest Structure Using Two UAV Techniques: A Comparison of Airborne Laser Scanning and Structure from Motion (Sfm) Point Clouds.” **Forests** 7 (3): 62.

WALTER. H.; WALTER, E.; 1953. Das Gesetz der relative Standortkontanz: Das wesen der Pflanzengesel-Ischaften. Ber. **Dtsch. Bot. Ges.** 66:228-236

WANG, D.-C., ZHANG, G.-L., PAN, X.-Z., ZHAO, Y.-G., ZHAO, M.-S., WANG, G.-F., 2012. Mapping soil texture of a plain area using fuzzy-c-means clustering method based on land surface diurnal temperature difference. **Pedosphere** 22, 394–403.

WARD, Sean et al. Autonomous UAVs wildlife detection using thermal imaging, predictive navigation and computer vision. **In: Proceedings of the 2016 IEEE Aerospace Conference. IEEE**, 2016. p. 1-8.

WATTS, A.C.; AMBROSIA, V.G.; HINKLEY, E.A. Unmanned aircraft systems in remote sensing and scientific research: Classification and considerations of use. **Remote Sens.** 2012, 4, 1671–1692.

WELLS, A. Atmospheric tracer monitoring and surface plume development at the ZERT pilot test in Bozeman, Montana, USA. **Environmental Earth Sciences**, v. 60, n. 2, p. 299-305, 2010.

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

WOLF, P. R., DEWITT, B. A. **Elements of Photogrammetry with Applications in GIS.** McGraw-Hill, 2000.

YANG, W. Analysis of leaf area index and fraction of PAR absorbed by vegetation products from the terra MODIS sensor: 2000-2005. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 7, p. 1829-1842, 2006.

YANG, Y.C.E., WI, S.W., RAY, P.A., BROWN, C.M., KHALIL, A.F., 2016. The future nexus of the Brahmaputra River Basin: climate, water, energy and food trajectories. **Global Environmental Change**, v. 37, p. 16-30, 2016.

YU, Min; SUN, Osbert Jianxin. Effects of forest patch type and site on herb-layer vegetation in a temperate forest ecosystem. **Forest Ecology and Management**, v. 300, p. 14-20, 2013.

ZARCO-TEJADA, P.J., USTIN, S.L., WHITING, M.L. (2005). Temporal and spatial relationships between within-field yield variability in cotton and high-spatial hyperspectral remote sensing imagery. **Agronomy Journal**, 97, 641–653.

ZHANG, J. et al., 2014. Estimating spatial variation in Alberta forest biomass from a combination of forest inventory and remote sensing data. **Biogeosciences** 11, 2793–2808.

ZHANG, J. et al., 2016. Regional and historical factors supplement current climate in shaping global forest canopy height. **J. Ecol.** 104, 469–478.

## Anexos:

ANEXO A- *Report de processamento de Coffea spp no outono.*

## Survey Data

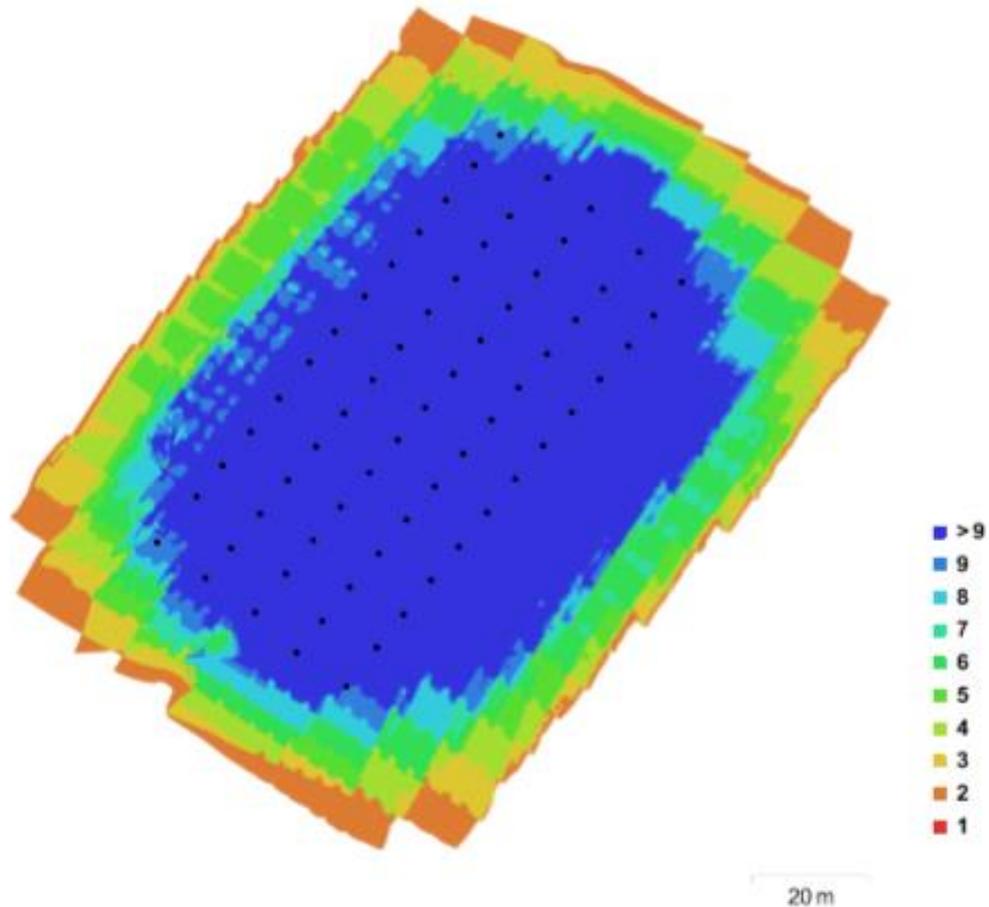


Fig. 1. Camera locations and image overlap.

Number of images:	65	Camera stations:	65
Flying altitude:	34.9 m	Tie points:	77,267
Ground resolution:	1.35 cm/pix	Projections:	224,431
Coverage area:	0.0126 km <sup>2</sup>	Reprojection error:	0.969 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu$ m	No

Table 1. Cameras.

## Camera Calibration

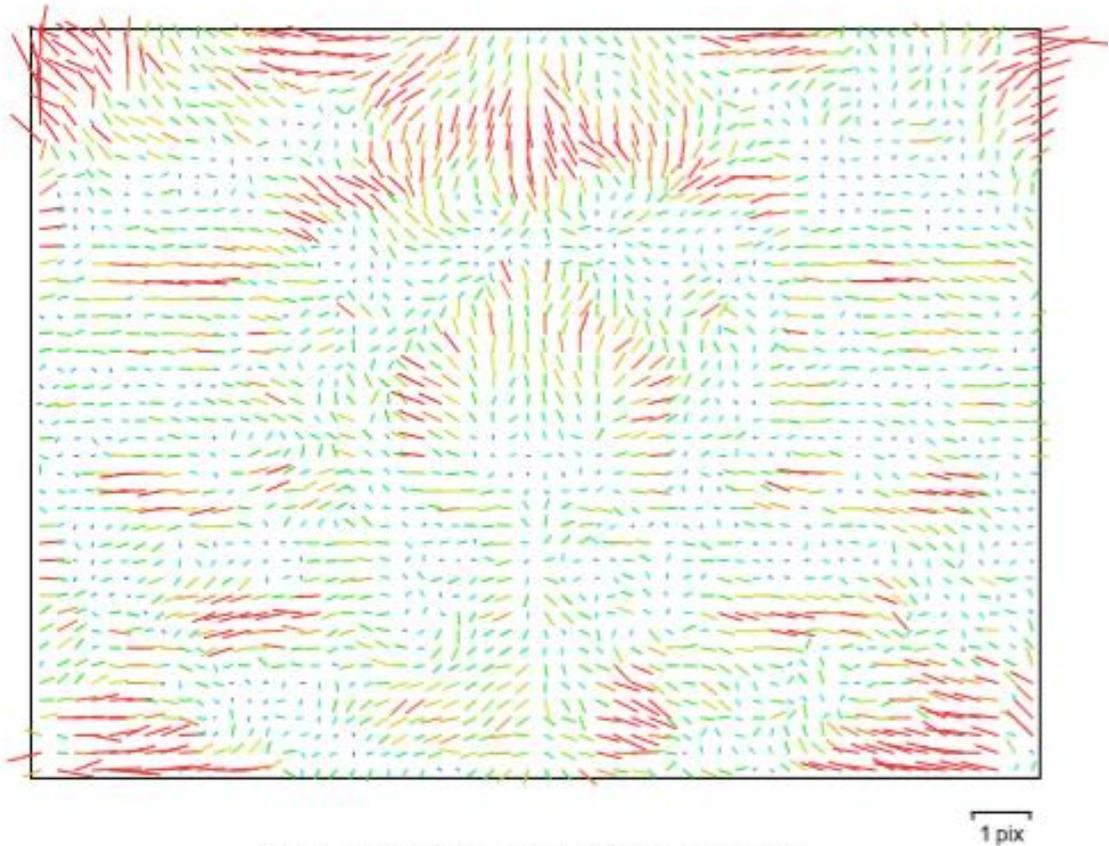


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

65 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-4.74288	B1:	0
Cy:	-21.8744	B2:	9.32241
K1:	-0.0111373	P1:	-2.11335e-05
K2:	0.00916858	P2:	-0.000215473
K3:	0.00501931	P3:	0
K4:	0	P4:	0

## Camera Locations

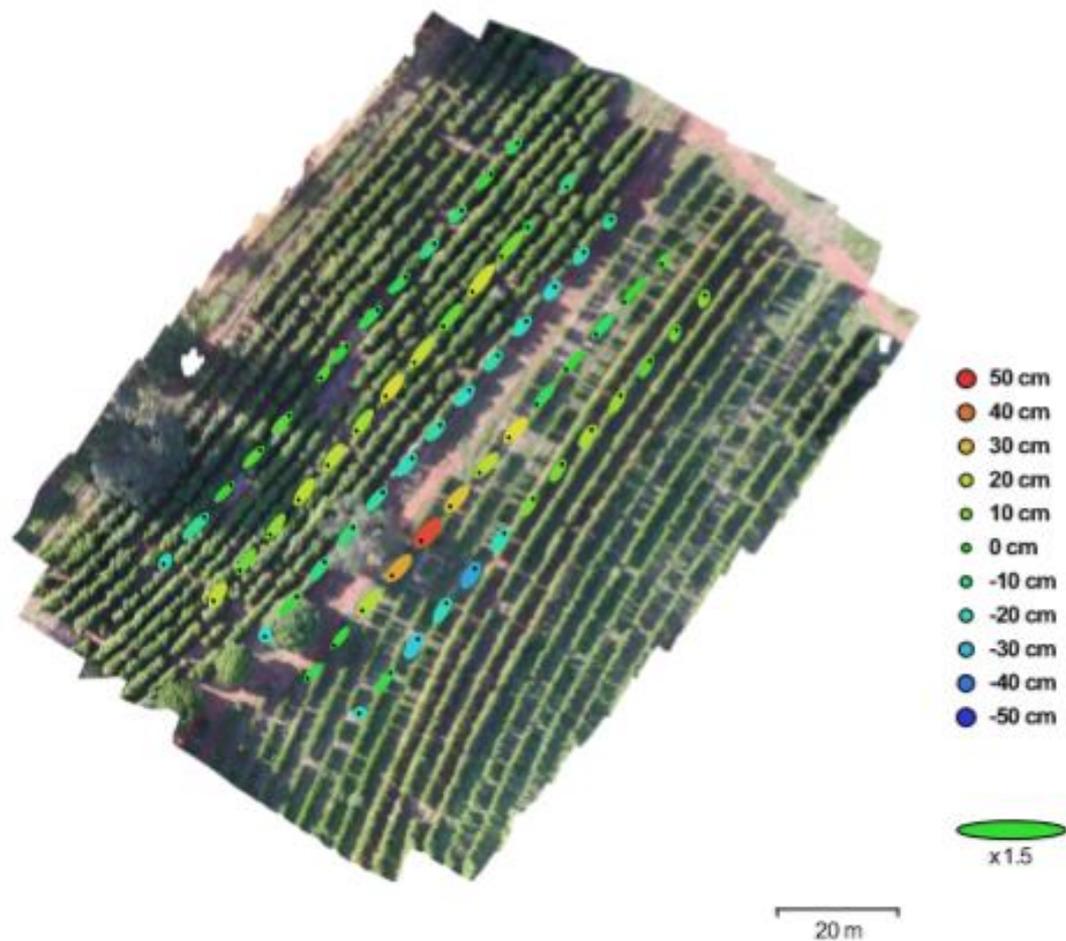


Fig. 3. Camera locations and error estimates.  
 Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.  
 Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.22606	1.51916	0.168403	1.9522	1.95945

Table 2. Average camera location error.

## Digital Elevation Model

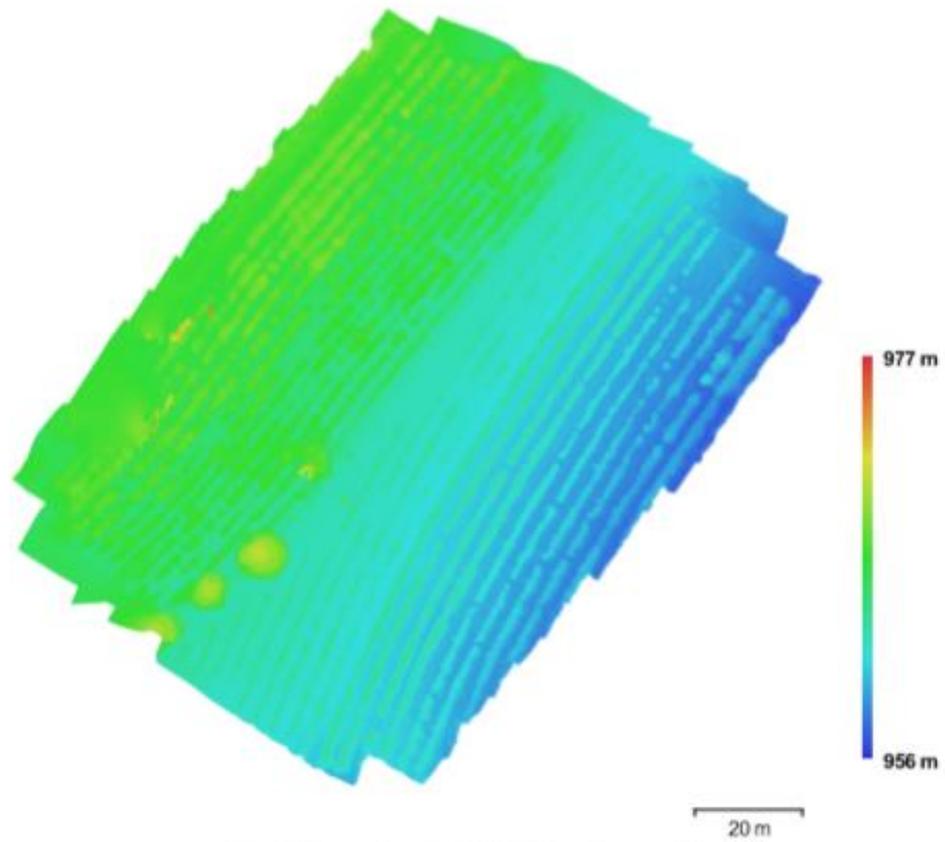


Fig. 4. Reconstructed digital elevation model.

Resolution: 2.71 cm/pix  
Point density: 0.136 points/cm<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	43
Aligned cameras	43
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Point Cloud</b>	
Points	202,869 of 220,764
RMS reprojection error	0.333468 (1.45194 pix)
Max reprojection error	1.01218 (37.7261 pix)
Mean key point size	4.49302 pix
Effective overlap	3.66035
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	11 minutes 1 seconds
Alignment time	1 minutes 6 seconds
<b>Depth Maps</b>	
Count	43
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	6 minutes 21 seconds
<b>Dense Point Cloud</b>	
Points	4,094,899
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	6 minutes 21 seconds
Dense cloud generation time	1 minutes 14 seconds
<b>Model</b>	
Faces	803,874
Vertices	403,269
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	818,979
Processing time	8 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UVmapping time	3 seconds
Blending time	24 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	31 minutes 28 seconds
<b>DEM</b>	
Size	6,457 x 6,698
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	23 seconds
<b>Orthomosaic</b>	
Size	11,124 x 10,742
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 37 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO B- *Report de processamento de Coffea spp no inverno.*

## Survey Data

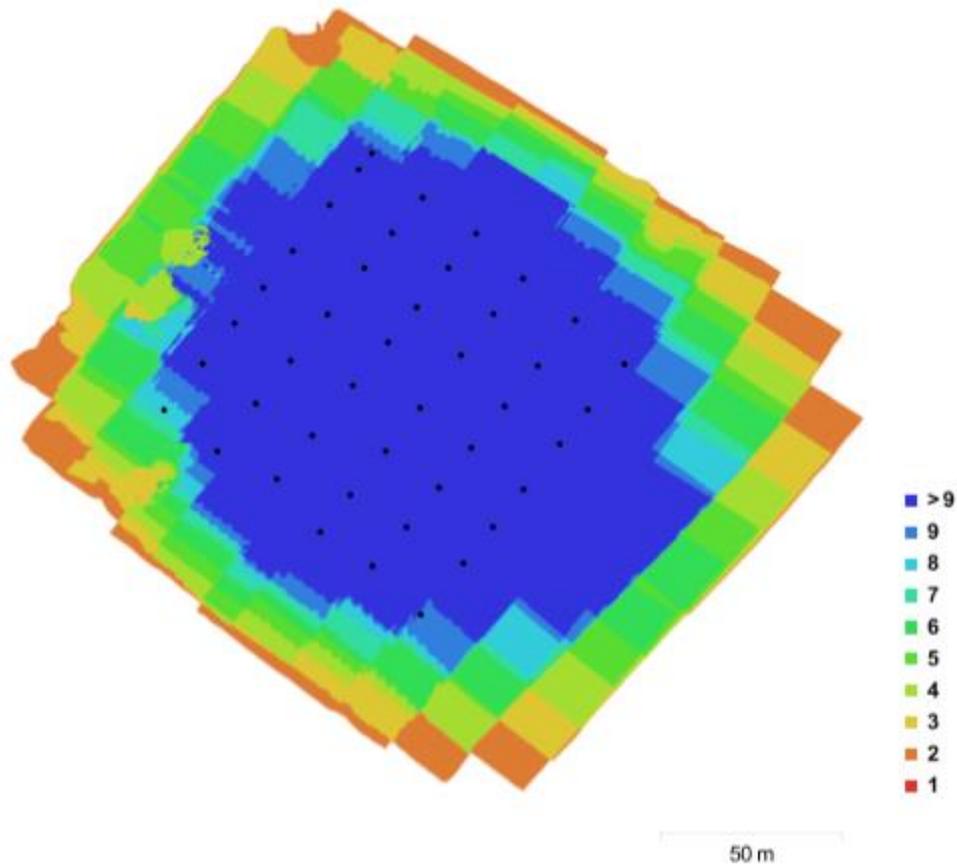


Fig. 1. Camera locations and image overlap.

Number of images:	43	Camera stations:	43
Flying altitude:	67.1 m	Tie points:	202,869
Ground resolution:	2.51 cm/pix	Projections:	693,413
Coverage area:	0.0301 km <sup>2</sup>	Reprojection error:	1.45 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu$ m	No

Table 1. Cameras.

## Camera Calibration

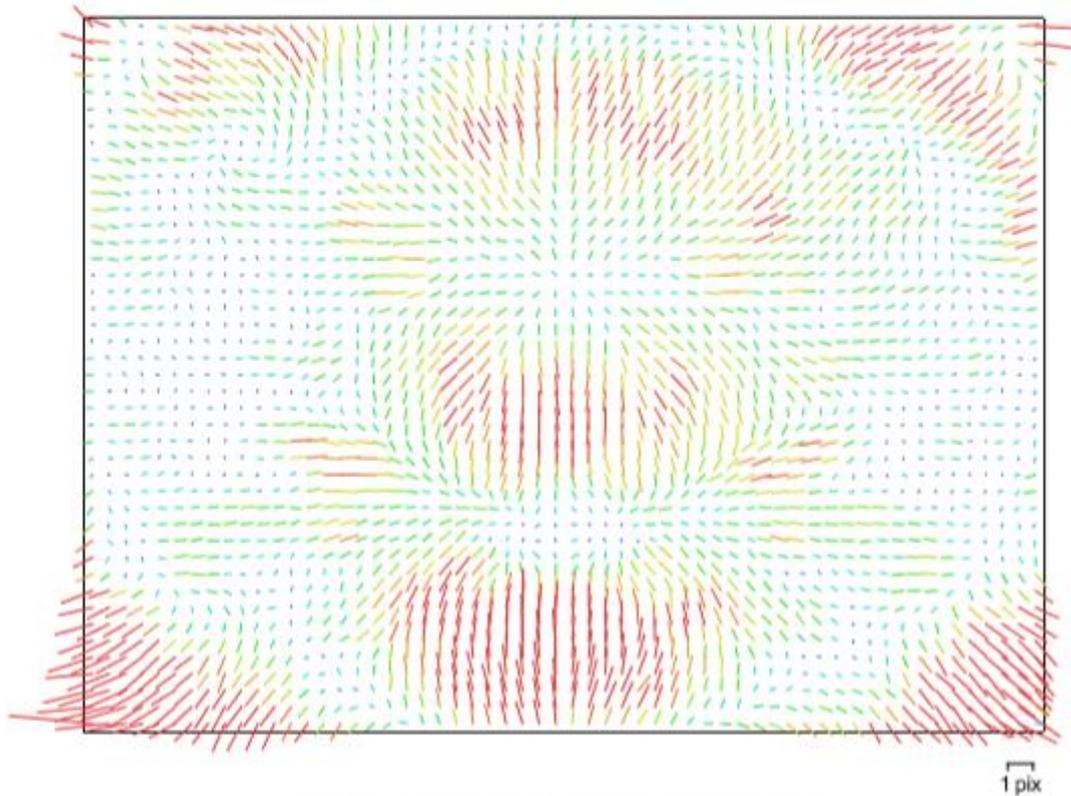


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

43 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-5.58292	B1:	-5.13861
Cy:	100.222	B2:	7.7227
K1:	0.0134553	P1:	-0.000484704
K2:	-0.00340342	P2:	0.00290677
K3:	0.0180356	P3:	0
K4:	0	P4:	0

## Camera Locations

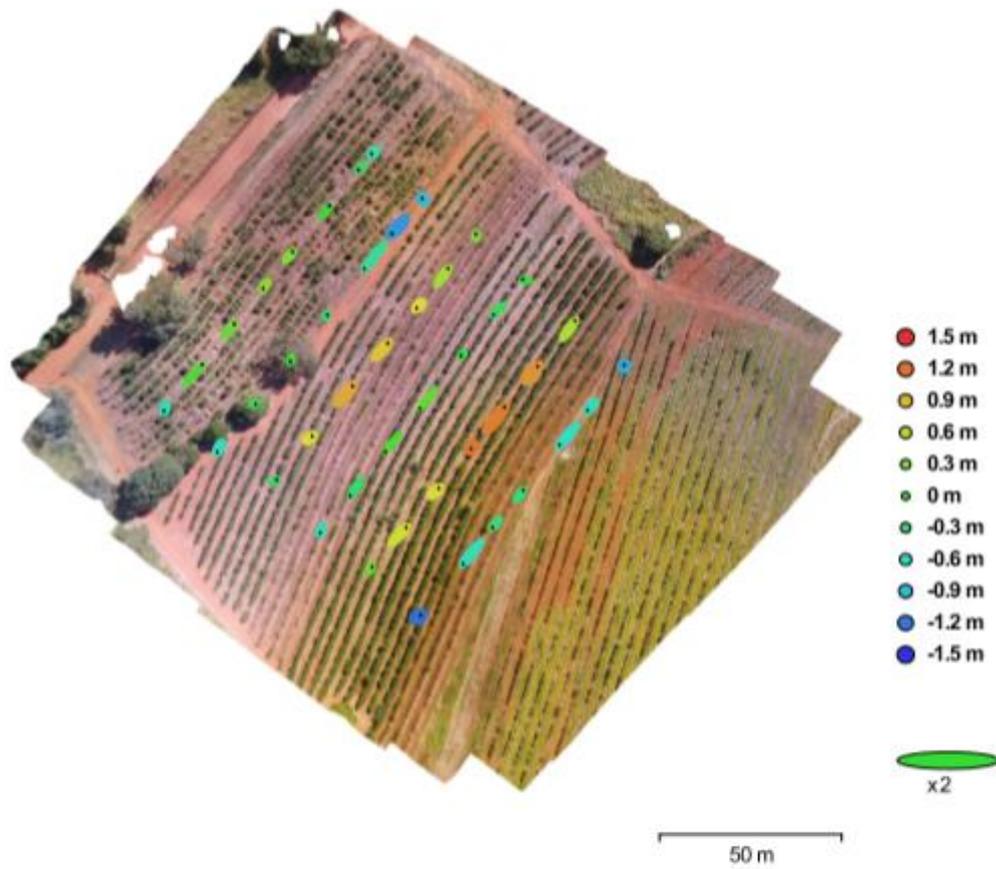


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.28935	1.58011	0.617756	2.0394	2.13091

Table 2. Average camera location error.

## Digital Elevation Model

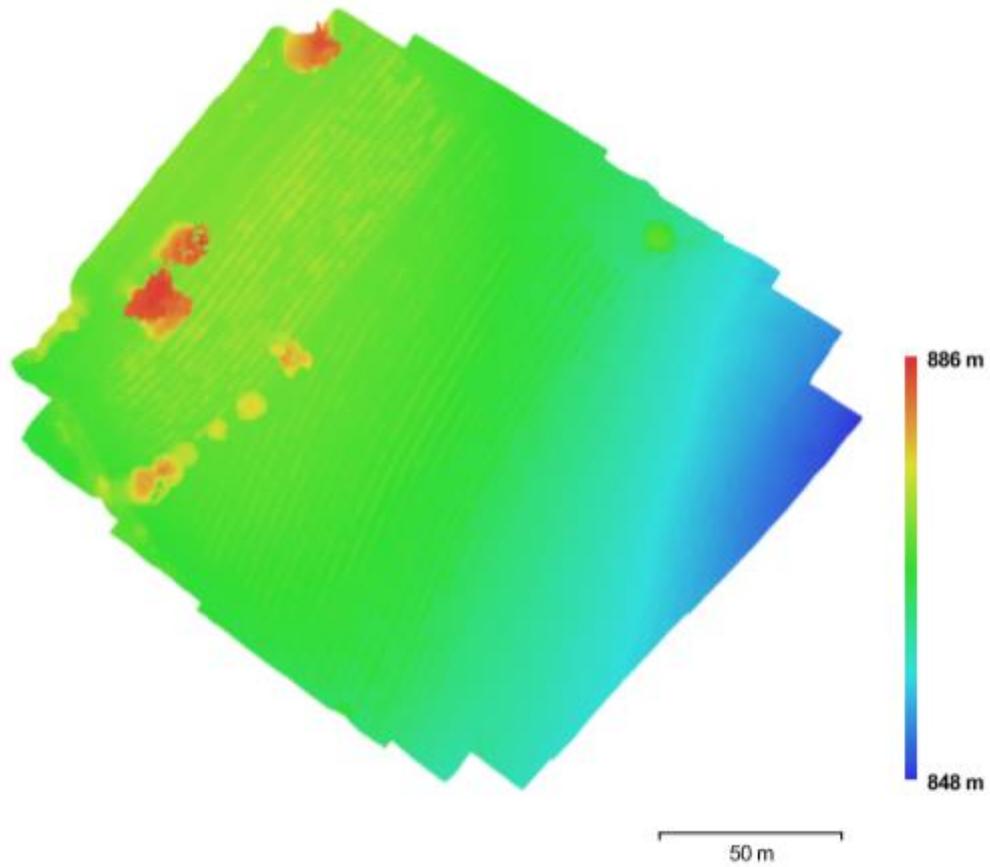


Fig. 4. Reconstructed digital elevation model.

Resolution: 10 cm/pix  
Point density: 99.2 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	43
Aligned cameras	43
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Point Cloud</b>	
Points	202,869 of 220,764
RMS reprojection error	0.333468 (1.45194 pix)
Max reprojection error	1.01218 (37.7261 pix)
Mean key point size	4.49302 pix
Effective overlap	3.66035
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	11 minutes 1 seconds
Alignment time	1 minutes 6 seconds
<b>Depth Maps</b>	
Count	43
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	6 minutes 21 seconds
<b>Dense Point Cloud</b>	
Points	4,094,899
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	6 minutes 21 seconds
Dense cloud generation time	1 minutes 14 seconds
<b>Model</b>	
Faces	803,874
Vertices	403,269
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	818,979
Processing time	8 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UVmapping time	3 seconds
Blending time	24 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	5 minutes 32 seconds
<b>DEM</b>	
Size	2,955 x 2,976
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	4 seconds
<b>Orthomosaic</b>	
Size	9,328 x 8,624
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	56 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO C- *Report de processamento de Coffea spp na primavera.*

## Survey Data

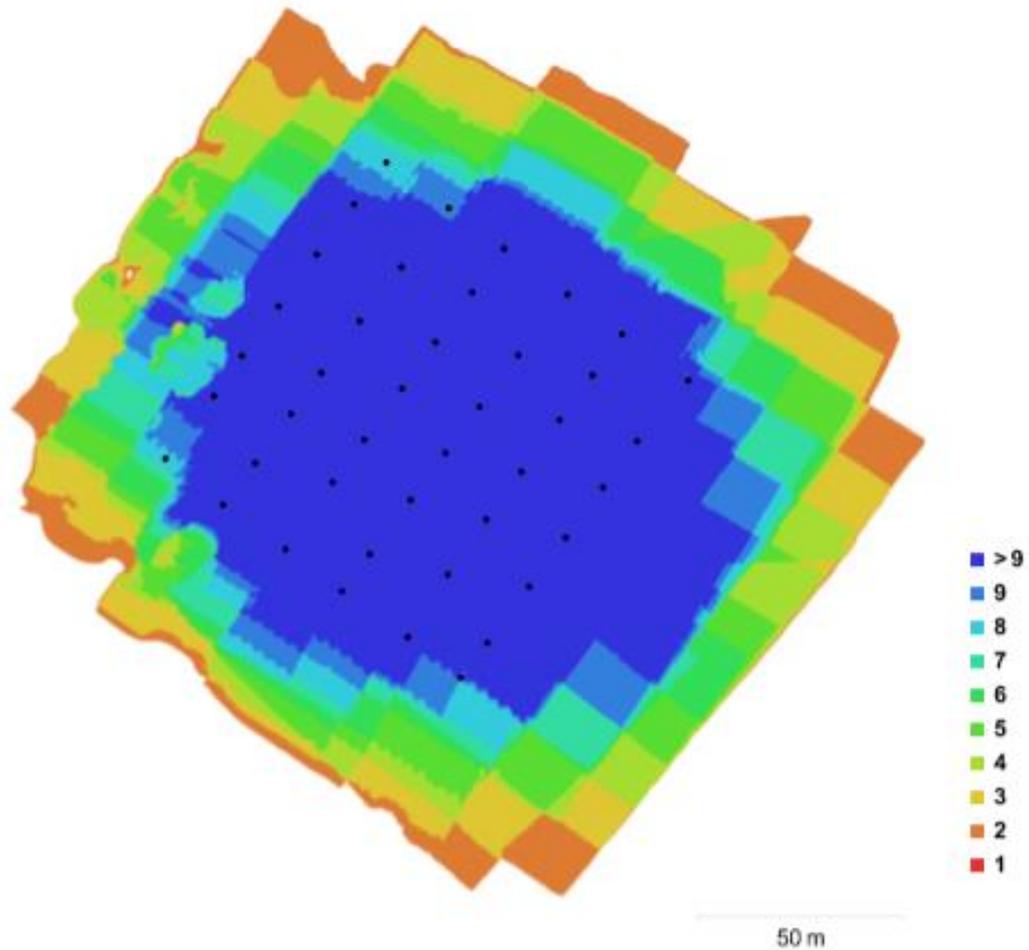


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	68.5 m	Tie points:	133,255
Ground resolution:	2.5 cm/pix	Projections:	380,407
Coverage area:	0.0298 km <sup>2</sup>	Reprojection error:	1.48 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu$ m	No

Table 1. Cameras.

## Camera Calibration

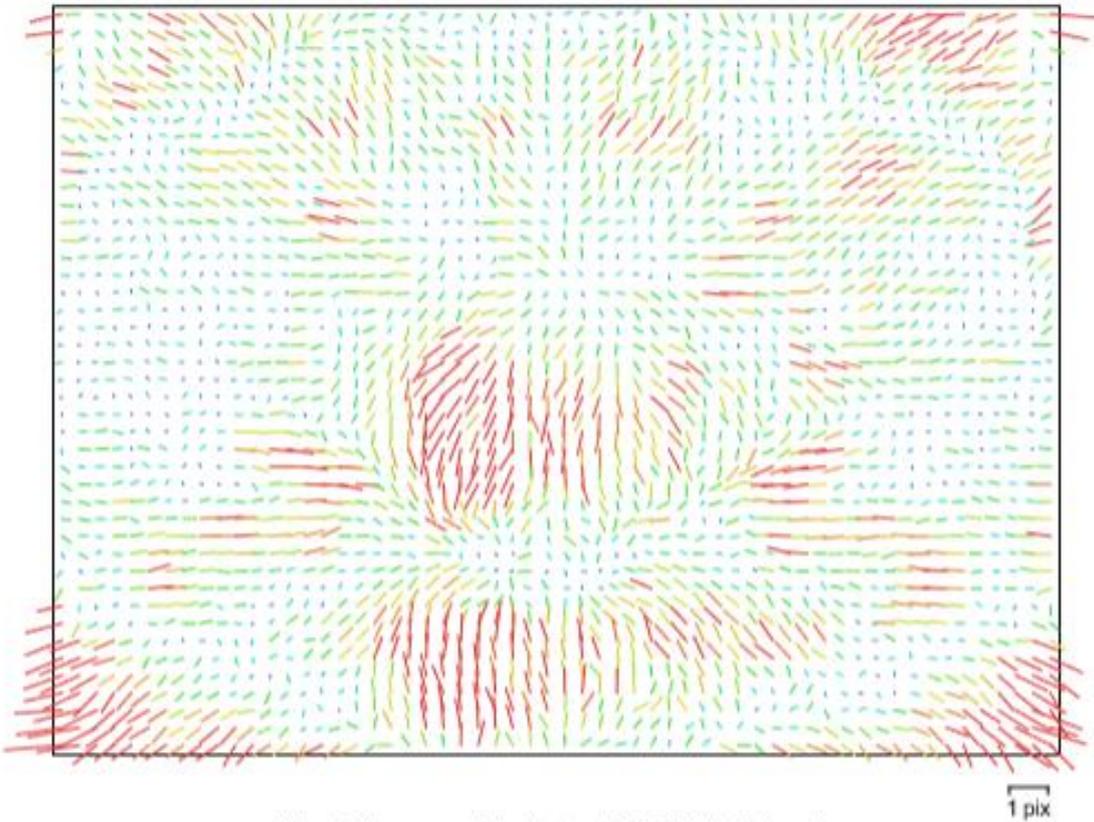


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-7.59253	B1:	-4.02053
Cy:	98.3613	B2:	-0.599332
K1:	0.0147244	P1:	-0.000537749
K2:	0.00977719	P2:	0.00261545
K3:	0.00995062	P3:	0
K4:	0	P4:	0

## Camera Locations

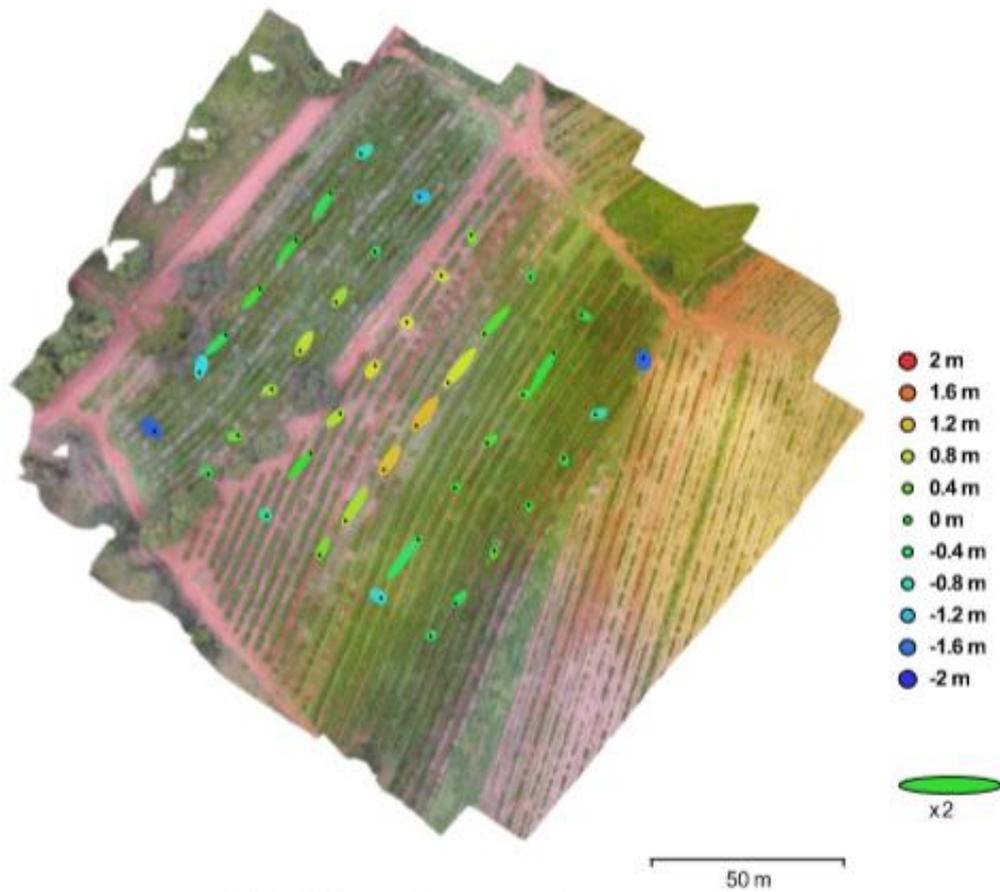


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.4533	1.92021	0.705014	2.40817	2.50925

Table 2. Average camera location error.

## Digital Elevation Model

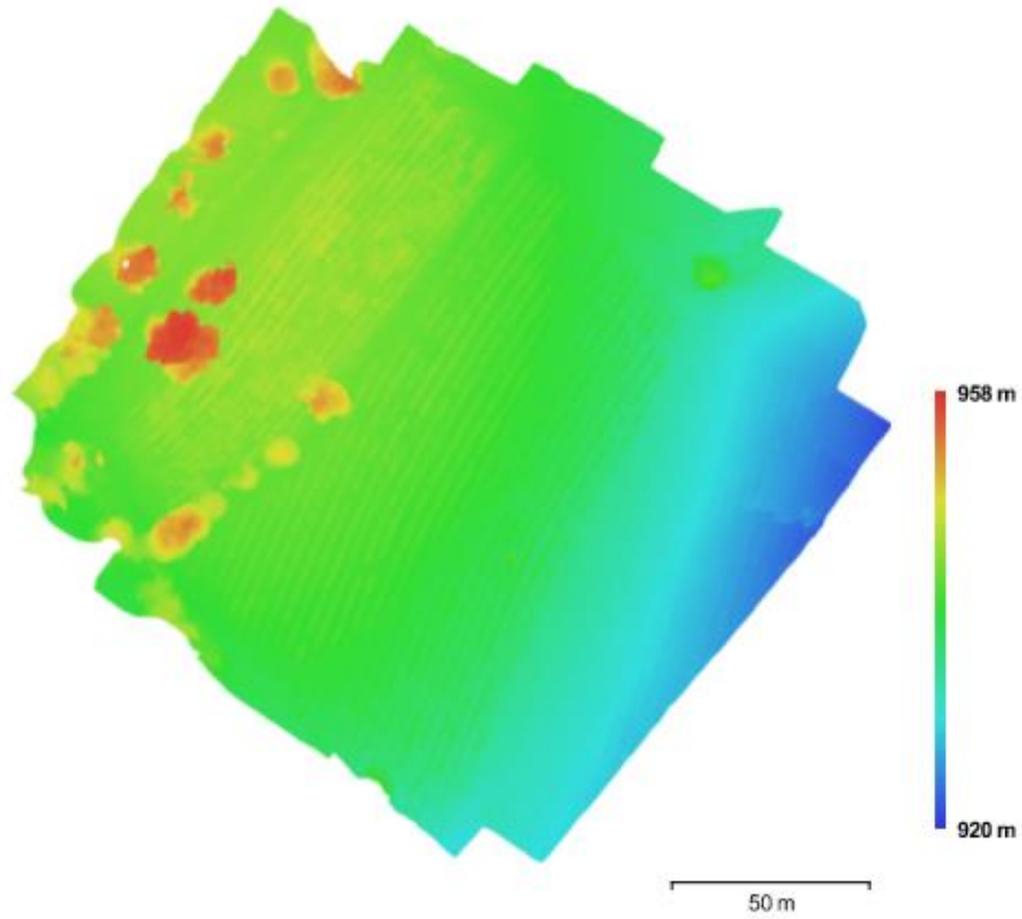


Fig. 4. Reconstructed digital elevation model.

Resolution: 10 cm/pix  
Point density: 99.7 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	43
Aligned cameras	43
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Point Cloud</b>	
Points	202,869 of 220,764
RMS reprojection error	0.333468 (1.45194 pix)
Max reprojection error	1.01218 (37.7261 pix)
Mean key point size	4.49302 pix
Effective overlap	3.66035
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	11 minutes 1 seconds
Alignment time	1 minutes 6 seconds
<b>Depth Maps</b>	
Count	43
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	6 minutes 21 seconds
<b>Dense Point Cloud</b>	
Points	4,094,899
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	6 minutes 21 seconds
Dense cloud generation time	1 minutes 14 seconds
<b>Model</b>	
Faces	803,874
Vertices	403,269
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	818,979
Processing time	8 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	3 seconds
Blending time	24 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	5 minutes 53 seconds
<b>DEM</b>	
Size	2,984 x 2,924
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	4 seconds
<b>Orthomosaic</b>	
Size	8,892 x 8,724
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	53 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO D - *Report* de processamento do Cerradinho no outono

## Survey Data

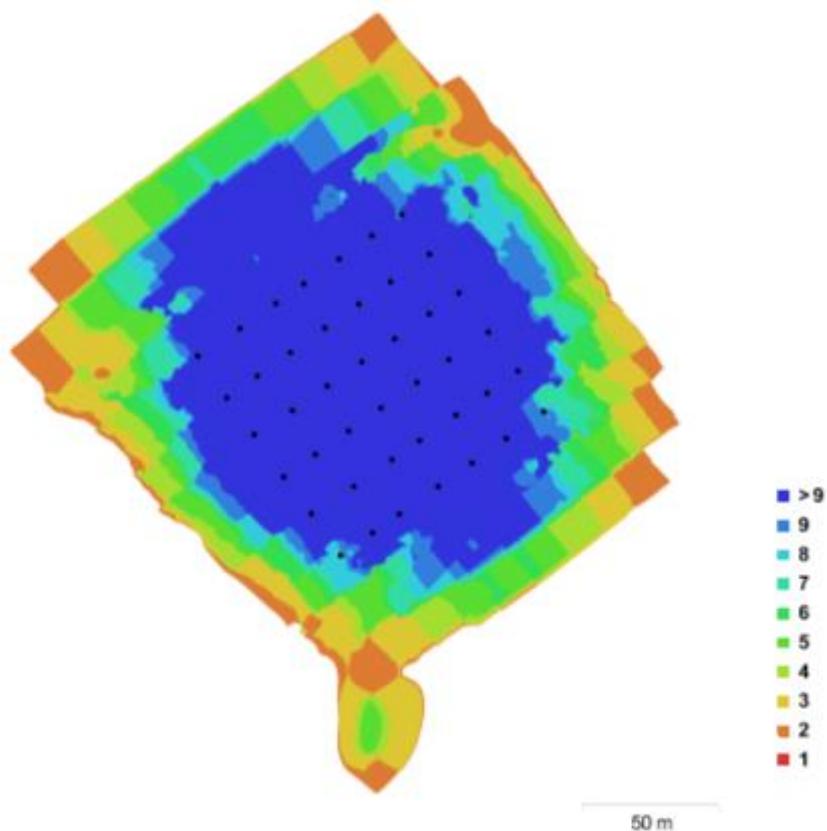


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	78.3 m	Tie points:	118,362
Ground resolution:	2.68 cm/pix	Projections:	360,945
Coverage area:	0.036 km <sup>2</sup>	Reprojection error:	1.58 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu$ m	No

Table 1. Cameras.

## Camera Calibration

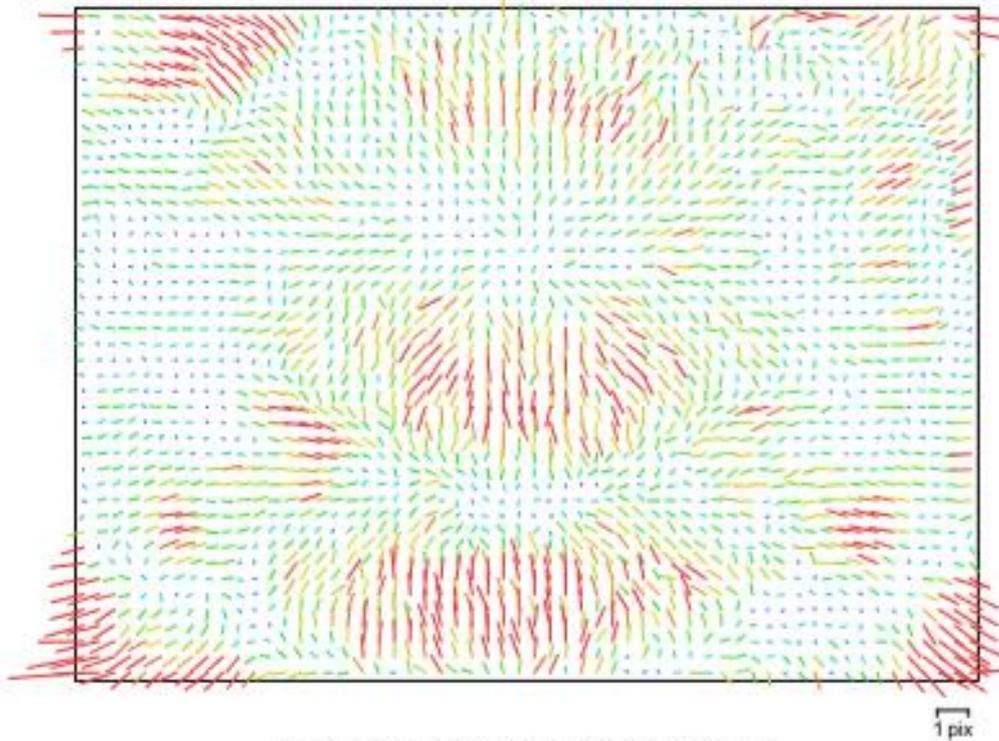


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-5.31479	B1:	5.03624
Cy:	101.258	B2:	9.41125
K1:	0.0110827	P1:	-0.000555439
K2:	0.00763985	P2:	0.00284793
K3:	0.0101657	P3:	0
K4:	0	P4:	0

## Camera Locations

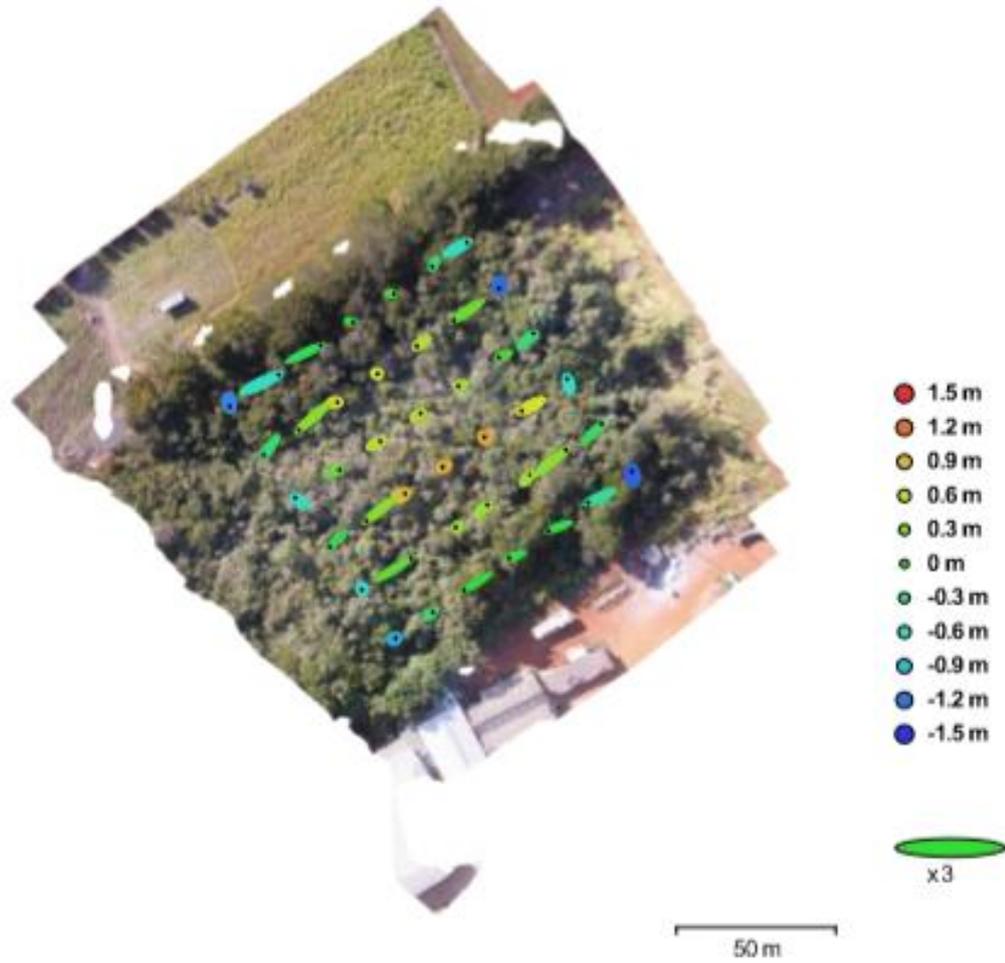


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.65294	1.17484	0.596442	2.02792	2.11381

Table 2. Average camera location error.

# Digital Elevation Model

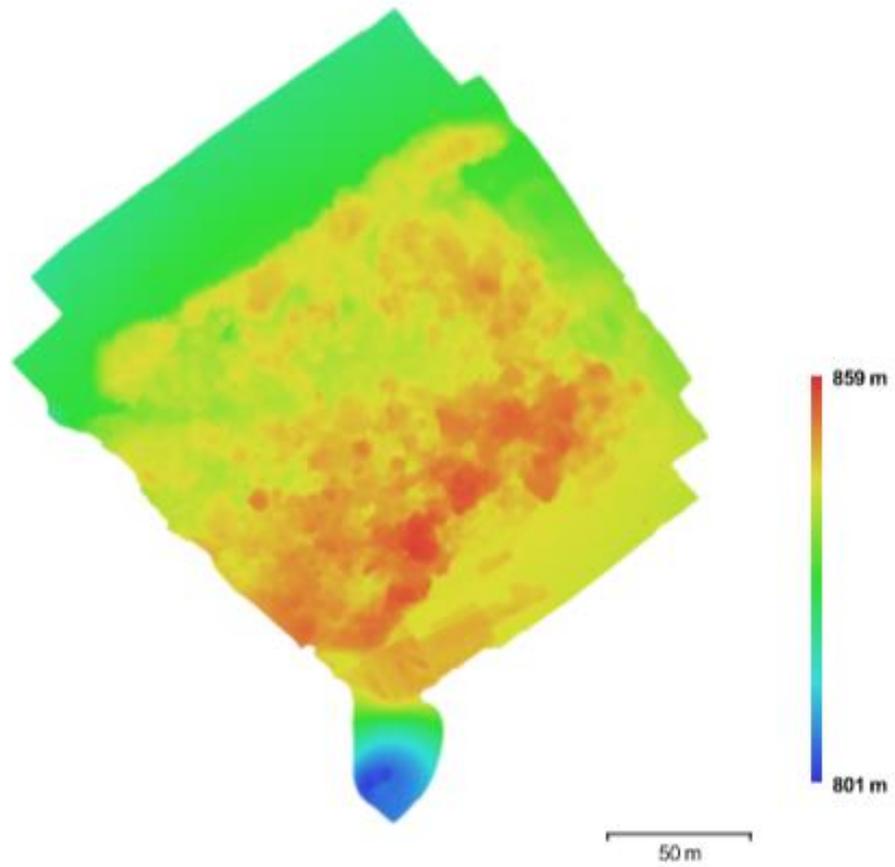


Fig. 4. Reconstructed digital elevation model.

Resolution: 10.7 cm/pix  
Point density: 87 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (61.7817 pix)
Mean key point size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Key point limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	6 minutes 9 seconds
<b>DEM</b>	
Size	3,205 x 3,354
Coordinate system	WGS 84 (EPSG:4326)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	5 seconds
<b>Orthomosaic</b>	
Size	9,124 x 10,728
Coordinate system	WGS 84 (EPSG:4326)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 7 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

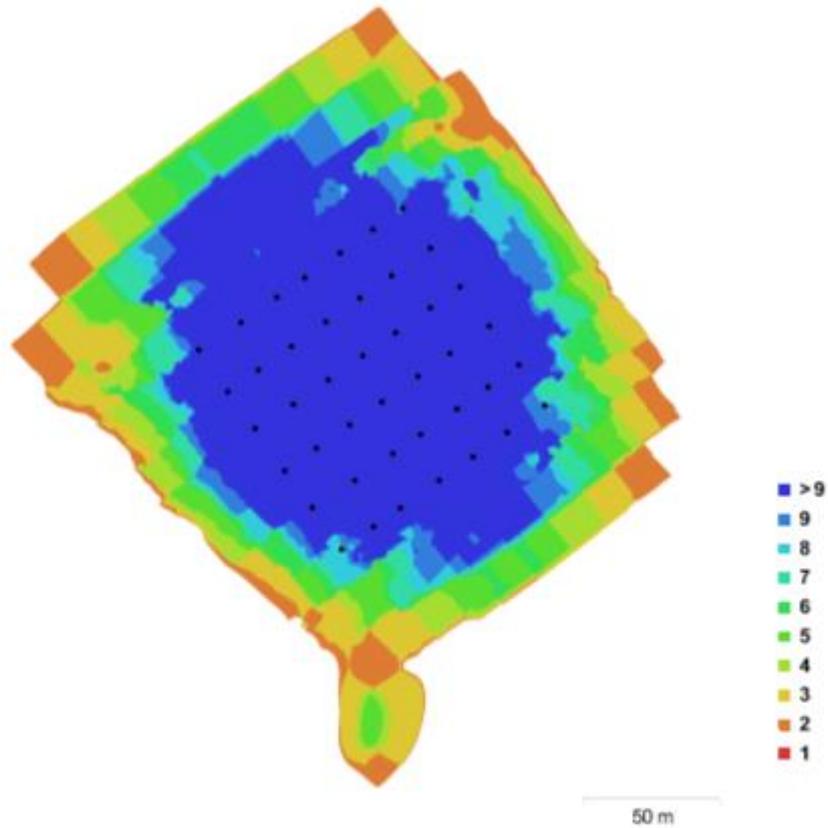
ANEXO E - *Report de processamento do Cerradinho no inverno.***Survey Data**

Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	78.3 m	Tie points:	118,362
Ground resolution:	2.68 cm/pix	Projections:	360,945
Coverage area:	0.036 km <sup>2</sup>	Reprojection error:	1.58 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu\text{m}$	No

Table 1. Cameras.

## Camera Calibration

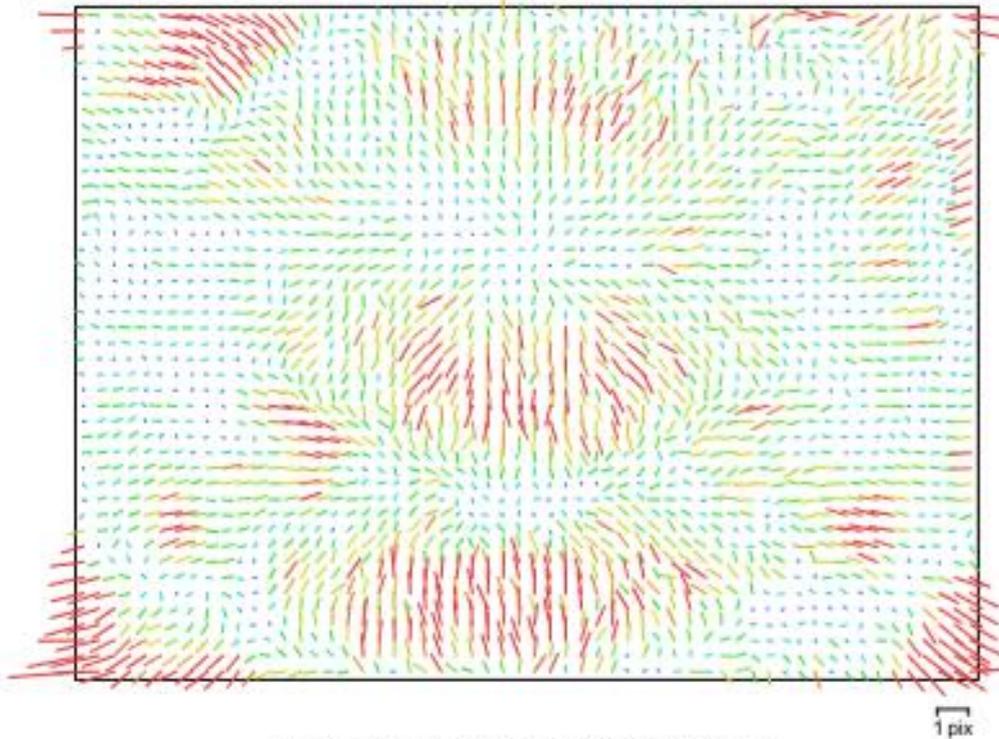


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution <b>4000 x 3000</b>	Focal Length <b>3.61 mm</b>	Pixel Size <b>1.56 x 1.56 <math>\mu\text{m}</math></b>	Precalibrated <b>No</b>
Type:	Frame	F:	2311.25
Cx:	-5.31479	B1:	5.03624
Cy:	101.258	B2:	9.41125
K1:	0.0110827	P1:	-0.000555439
K2:	0.00763985	P2:	0.00284793
K3:	0.0101657	P3:	0
K4:	0	P4:	0

## Camera Locations

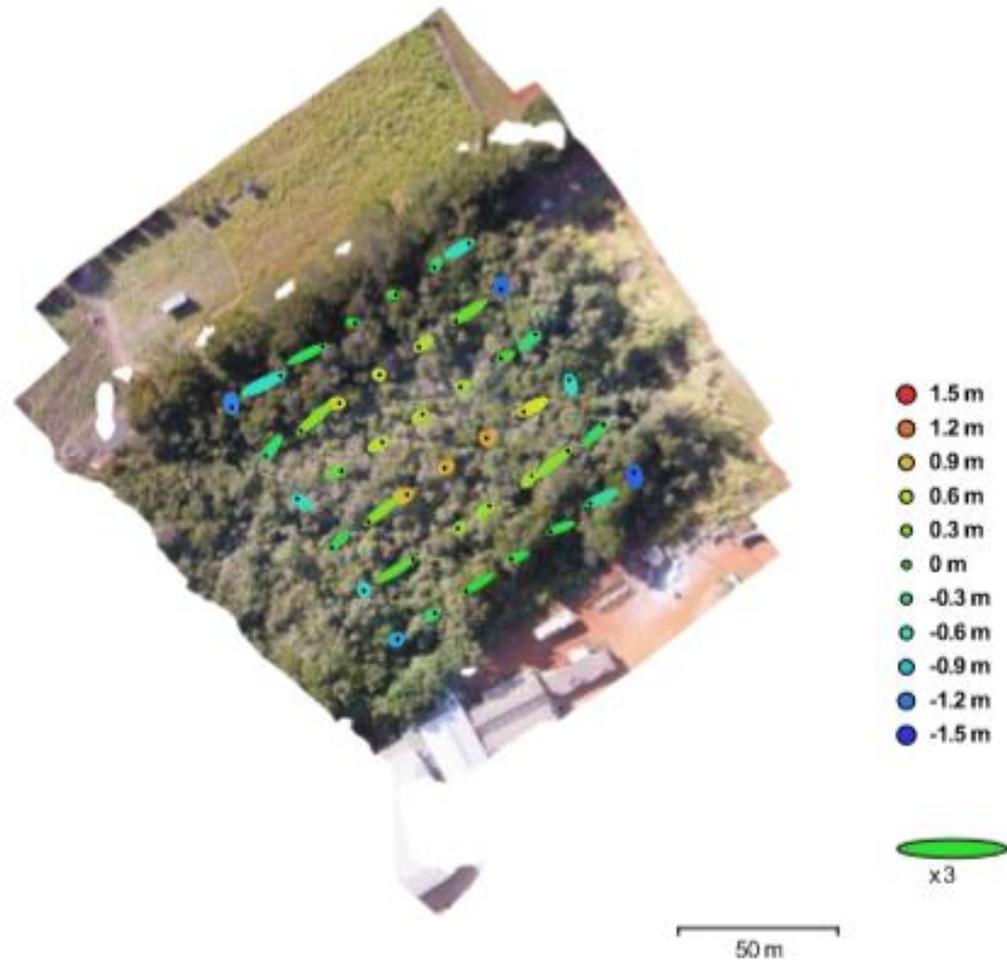


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.65294	1.17484	0.596442	2.02792	2.11381

Table 2. Average camera location error.

## Digital Elevation Model

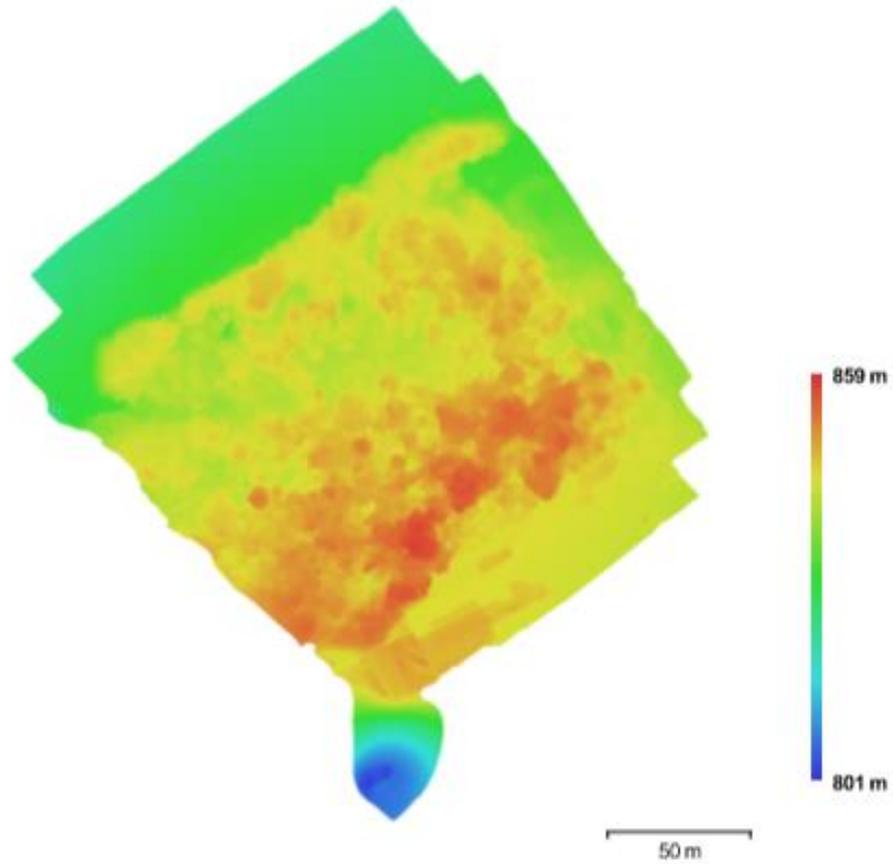


Fig. 4. Reconstructed digital elevation model.

Resolution: 10.7 cm/pix  
Point density: 87 points/m<sup>2</sup>

## Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (81.7817 pix)
Mean keypoint size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Key point limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	6 minutes 9 seconds
<b>DEM</b>	
Size	3,205 x 3,354
Coordinate system	WGS 84 (EPSG:4326)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	5 seconds
<b>Orthomosaic</b>	
Size	9,124 x 10,728
Coordinate system	WGS 84 (EPSG:4326)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 7 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO E - *Report* de processamento do Cerradinho na primavera.

## Survey Data

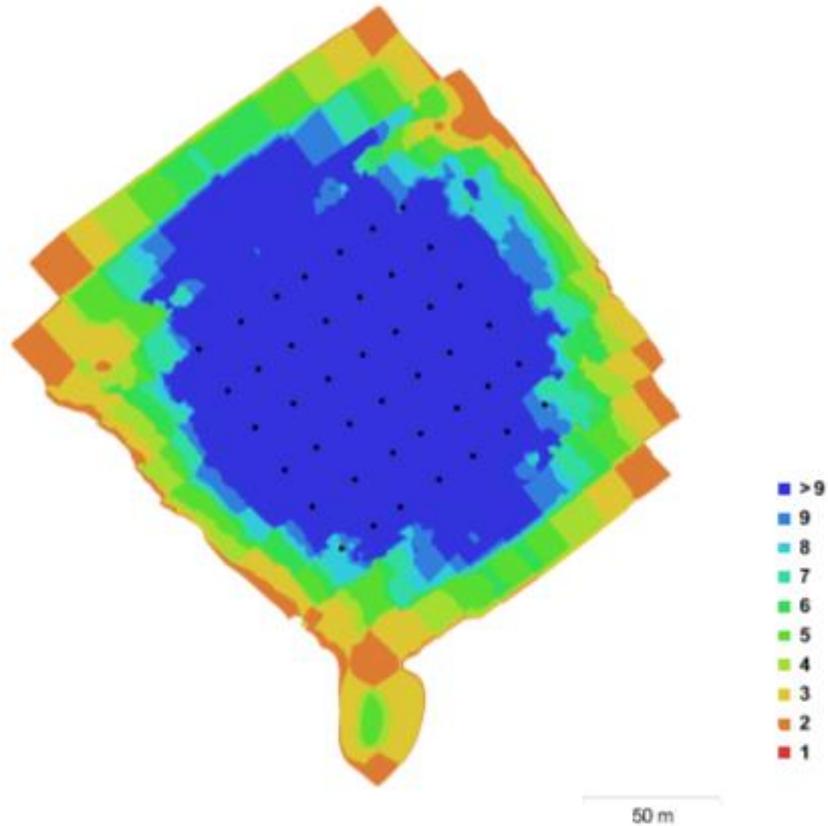


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	78.3 m	Tie points:	118,362
Ground resolution:	2.68 cm/pix	Projections:	360,945
Coverage area:	0.036 km <sup>2</sup>	Reprojection error:	1.58 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu$ m	No

Table 1. Cameras.

## Camera Calibration

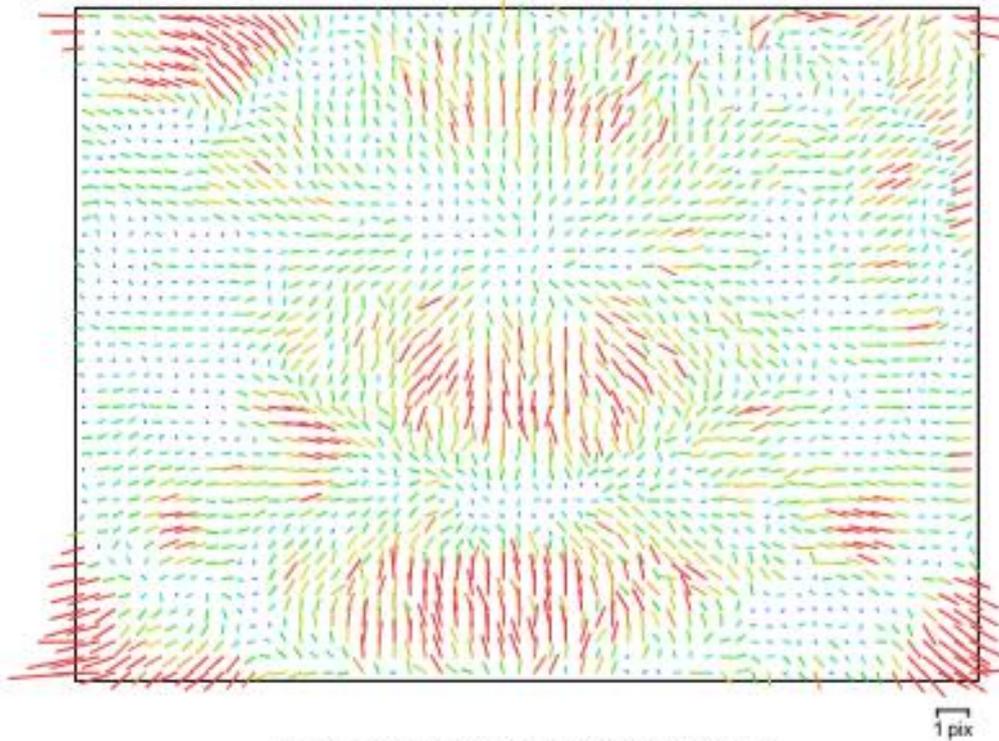


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-5.31479	B1:	5.03624
Cy:	101.258	B2:	9.41125
K1:	0.0110827	P1:	-0.000555439
K2:	0.00763985	P2:	0.00284793
K3:	0.0101657	P3:	0
K4:	0	P4:	0

## Camera Locations

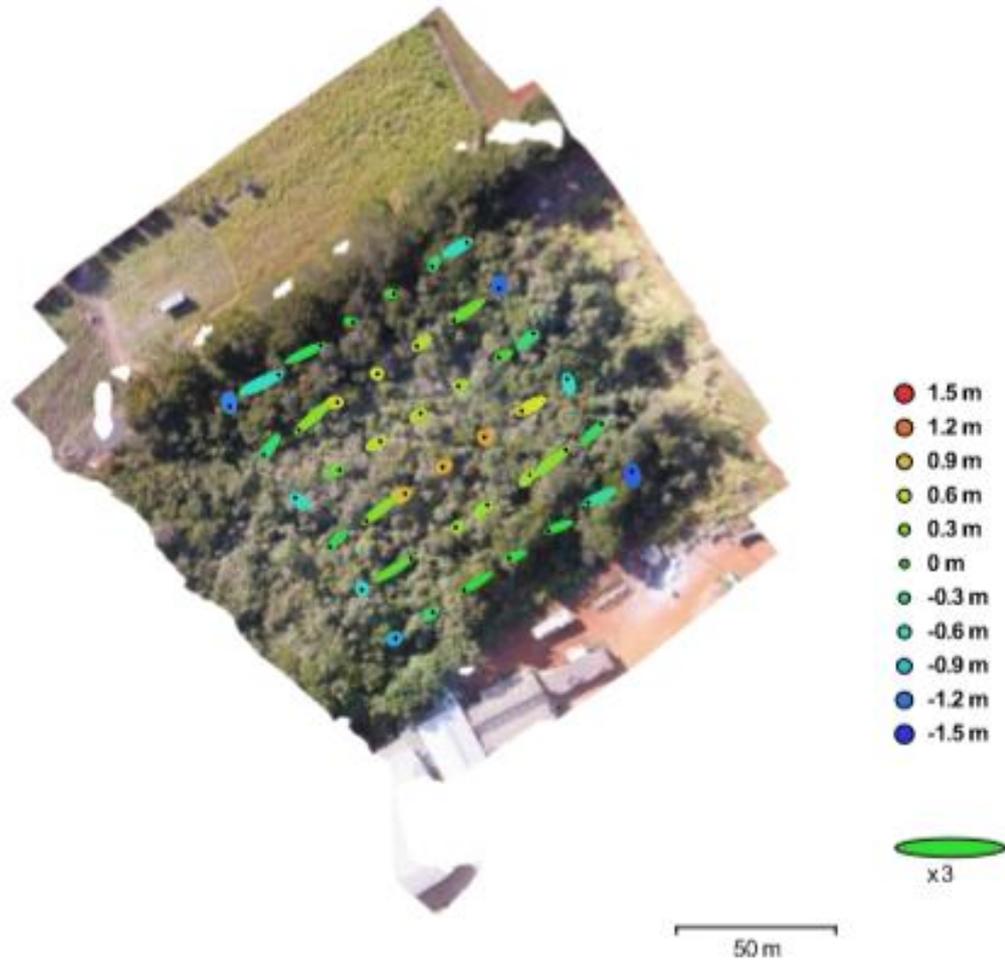


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.65294	1.17484	0.596442	2.02792	2.11381

Table 2. Average camera location error.

## Digital Elevation Model

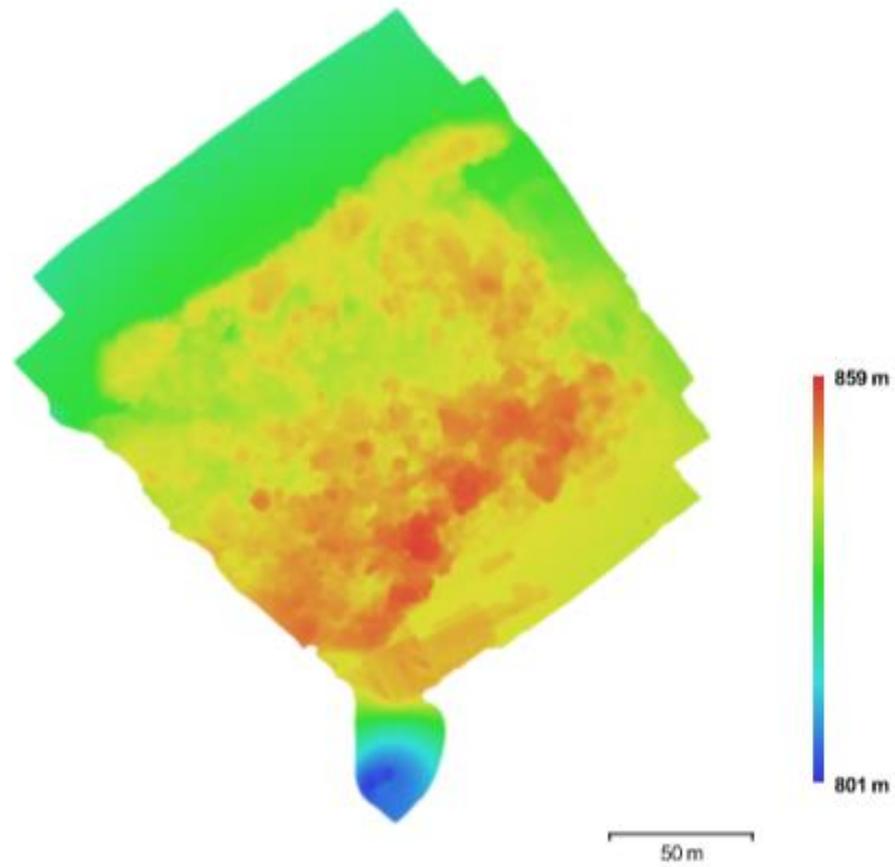


Fig. 4. Reconstructed digital elevation model.

Resolution: 10.7 cm/pix  
Point density: 87 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (61.7817 pix)
Mean keypoint size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UVmapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	6 minutes 9 seconds
<b>DEM</b>	
Size	3,205 x 3,354
Coordinate system	WGS 84 (EPSG:4326)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	5 seconds
<b>Orthomosaic</b>	
Size	9,124 x 10,728
Coordinate system	WGS 84 (EPSG:4326)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 7 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO F - *Report* de processamento do Cerradinho no verão.

## Survey Data

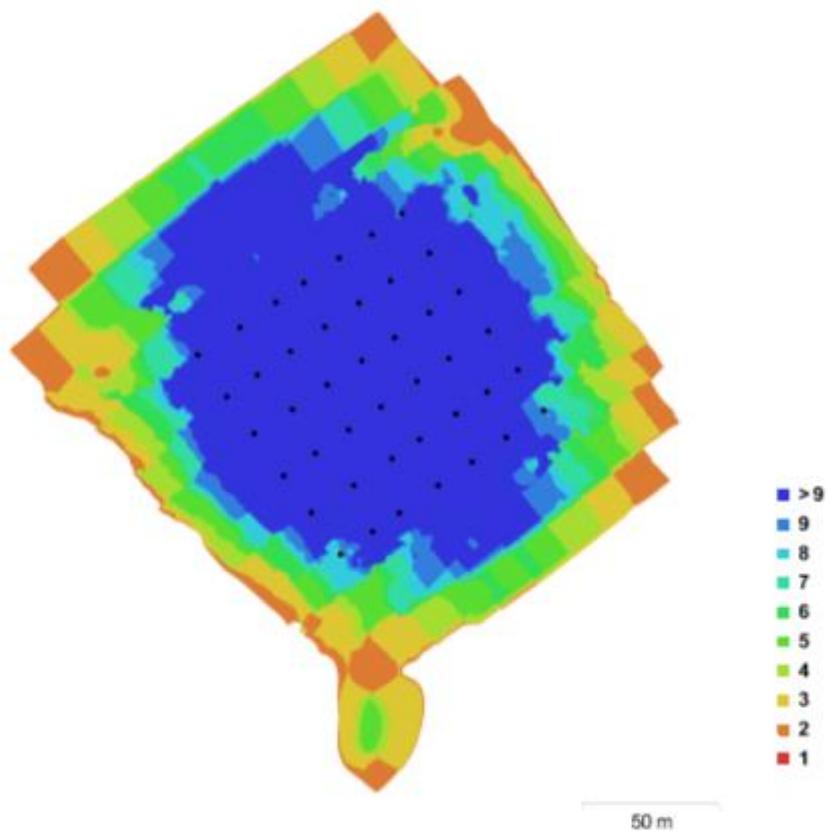


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	78.3 m	Tie points:	118,362
Ground resolution:	2.68 cm/pix	Projections:	360,945
Coverage area:	0.036 km <sup>2</sup>	Reprojection error:	1.58 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC300X (3.61 mm)	4000 x 3000	3.61 mm	1.56 x 1.56 $\mu$ m	No

Table 1. Cameras.

## Camera Calibration

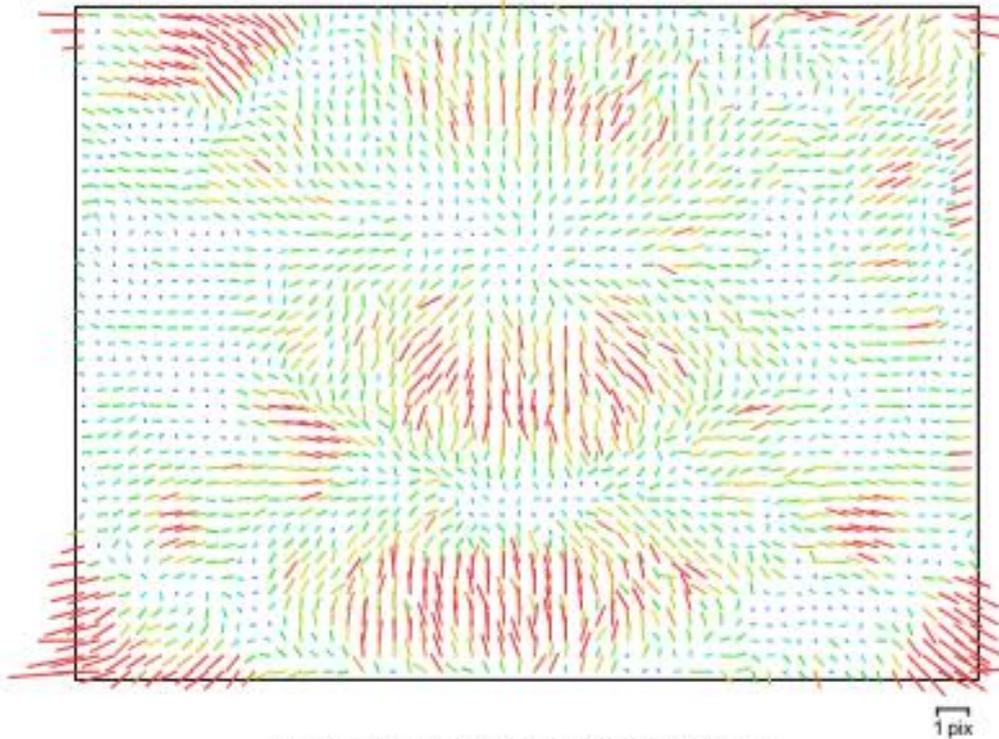


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution <b>4000 x 3000</b>	Focal Length <b>3.61 mm</b>	Pixel Size <b>1.56 x 1.56 <math>\mu\text{m}</math></b>	Precalibrated <b>No</b>
Type:	Frame	F:	2311.25
Cx:	-5.31479	B1:	5.03624
Cy:	101.258	B2:	9.41125
K1:	0.0110827	P1:	-0.000555439
K2:	0.00763985	P2:	0.00284793
K3:	0.0101657	P3:	0
K4:	0	P4:	0

# Camera Locations

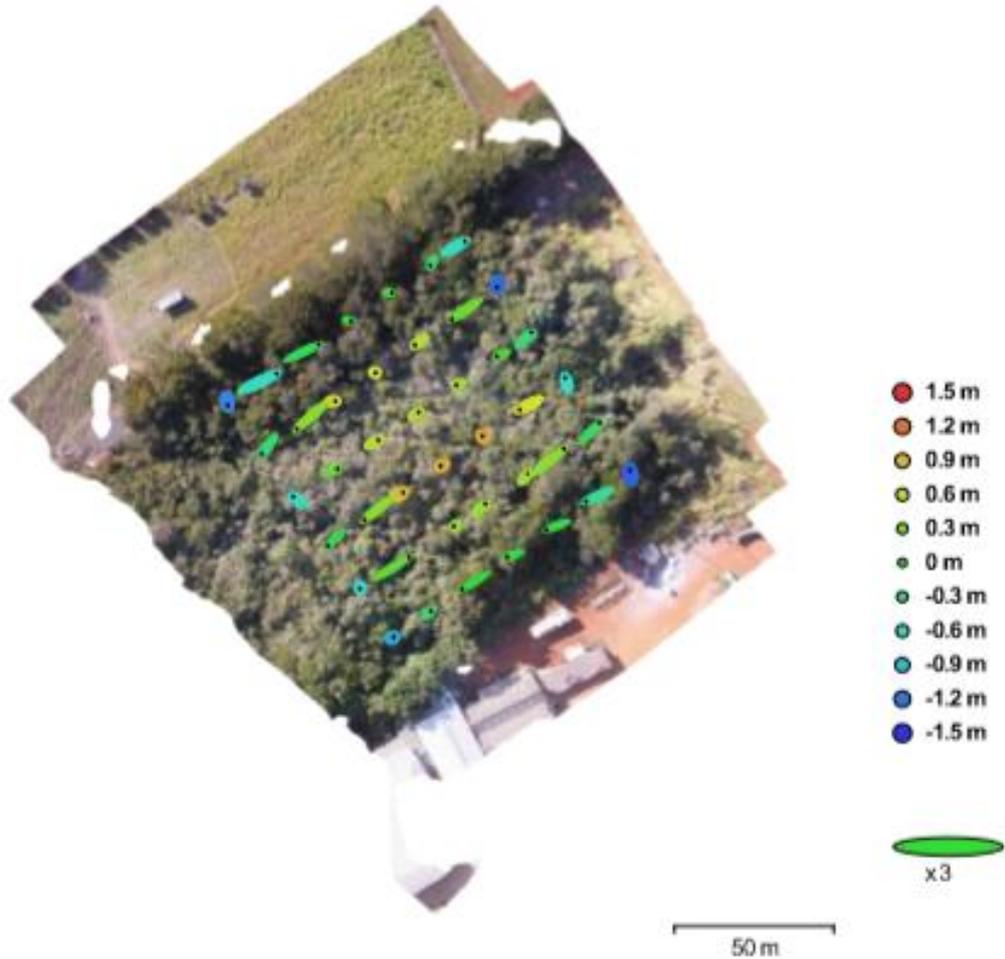


Fig. 3. Camera locations and error estimates.  
 Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.  
 Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.65294	1.17484	0.596442	2.02792	2.11381

Table 2. Average camera location error.

## Digital Elevation Model

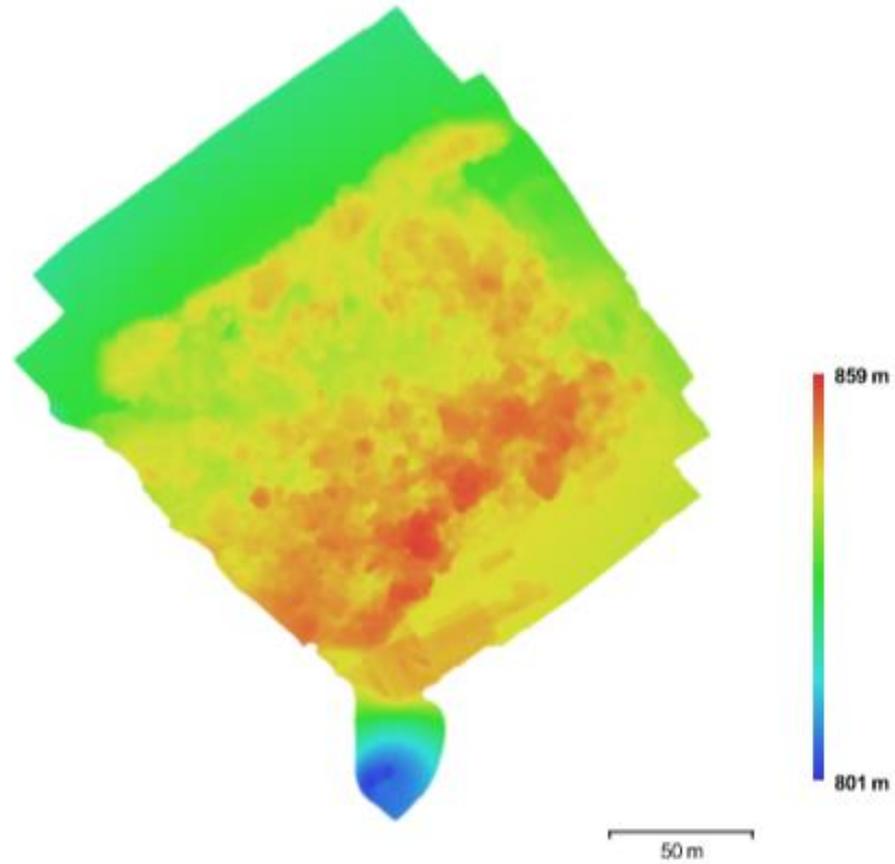


Fig. 4. Reconstructed digital elevation model.

Resolution: 10.7 cm/pix  
Point density: 87 points/m<sup>2</sup>

## Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (81.7817 pix)
Mean keypoint size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Key point limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

Processing time	6 minutes 9 seconds
<b>DEM</b>	
Size	3,205 x 3,354
Coordinate system	WGS 84 (EPSG:4326)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	5 seconds
<b>Orthomosaic</b>	
Size	9,124 x 10,728
Coordinate system	WGS 84 (EPSG:4326)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 7 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO G - *Report* de processamento da Matinha no outono.

## Survey Data

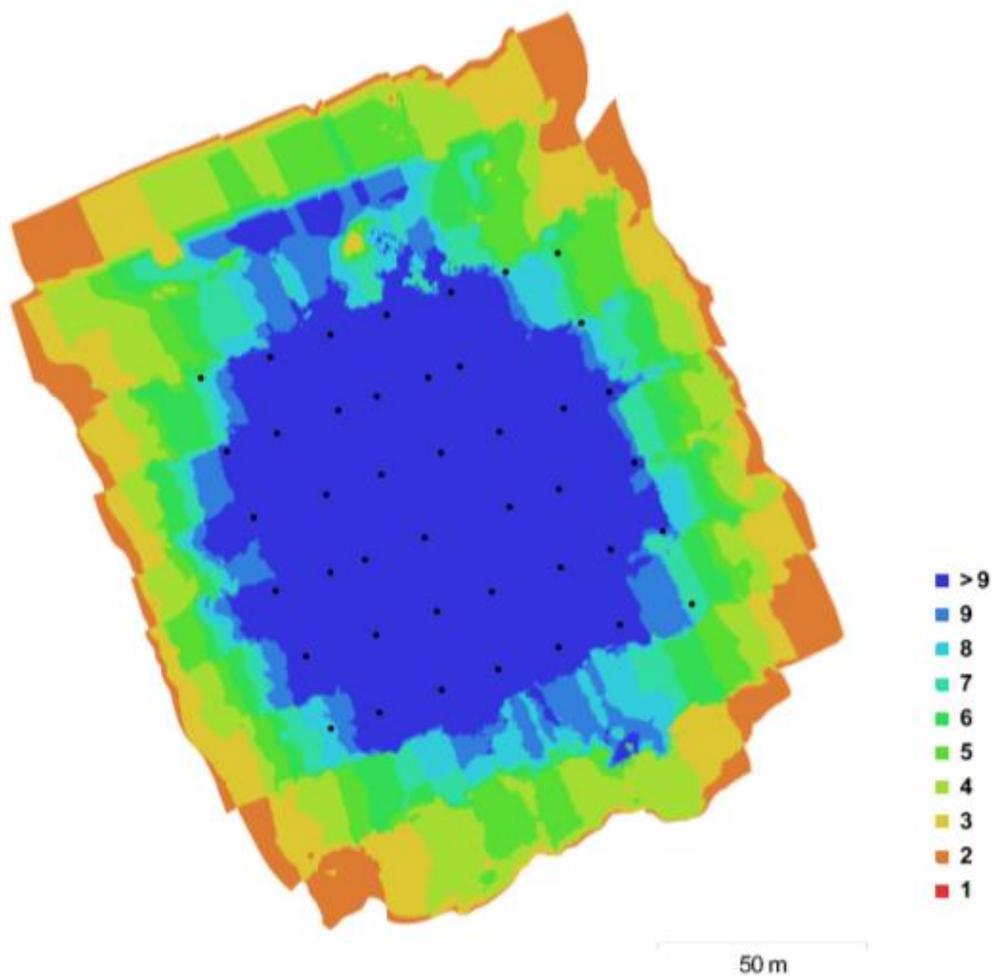


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	55.8 m	Tie points:	54,134
Ground resolution:	2.05 cm/pix	Projections:	132,586
Coverage area:	0.0275 km <sup>2</sup>	Reprojection error:	1.21 pix

## Camera Calibration

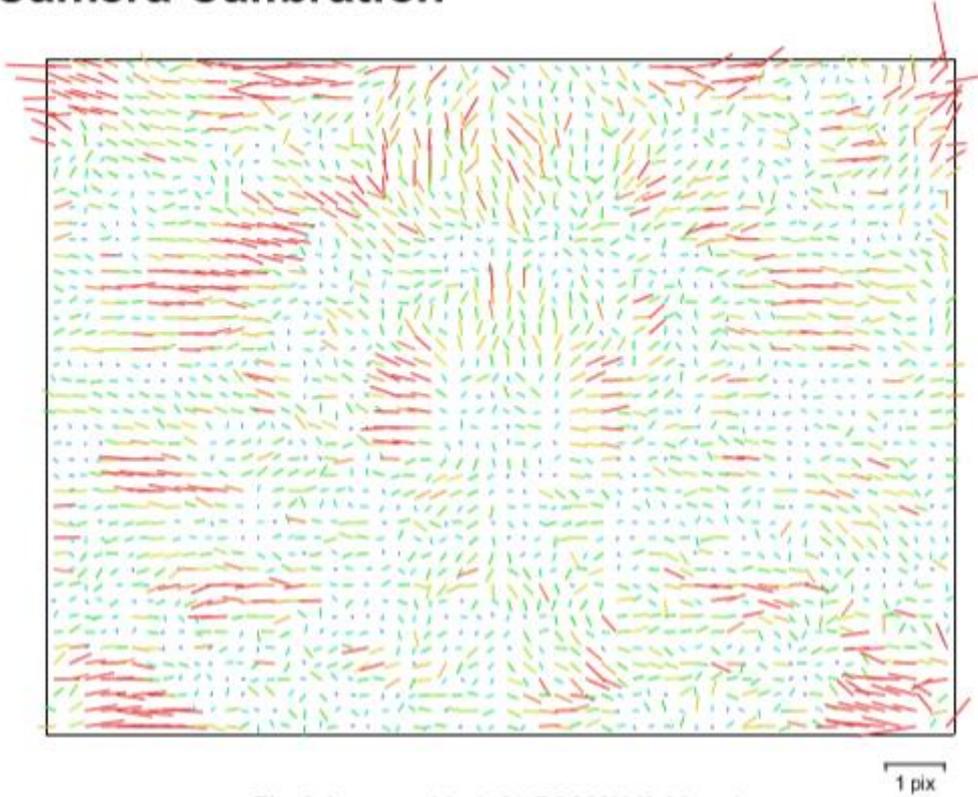


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-2.13741	B1:	-4.24597
Cy:	-22.5674	B2:	0
K1:	-0.012997	P1:	0.000121894
K2:	0.0178849	P2:	-0.000445218
K3:	0	P3:	0
K4:	0	P4:	0

## Camera Locations

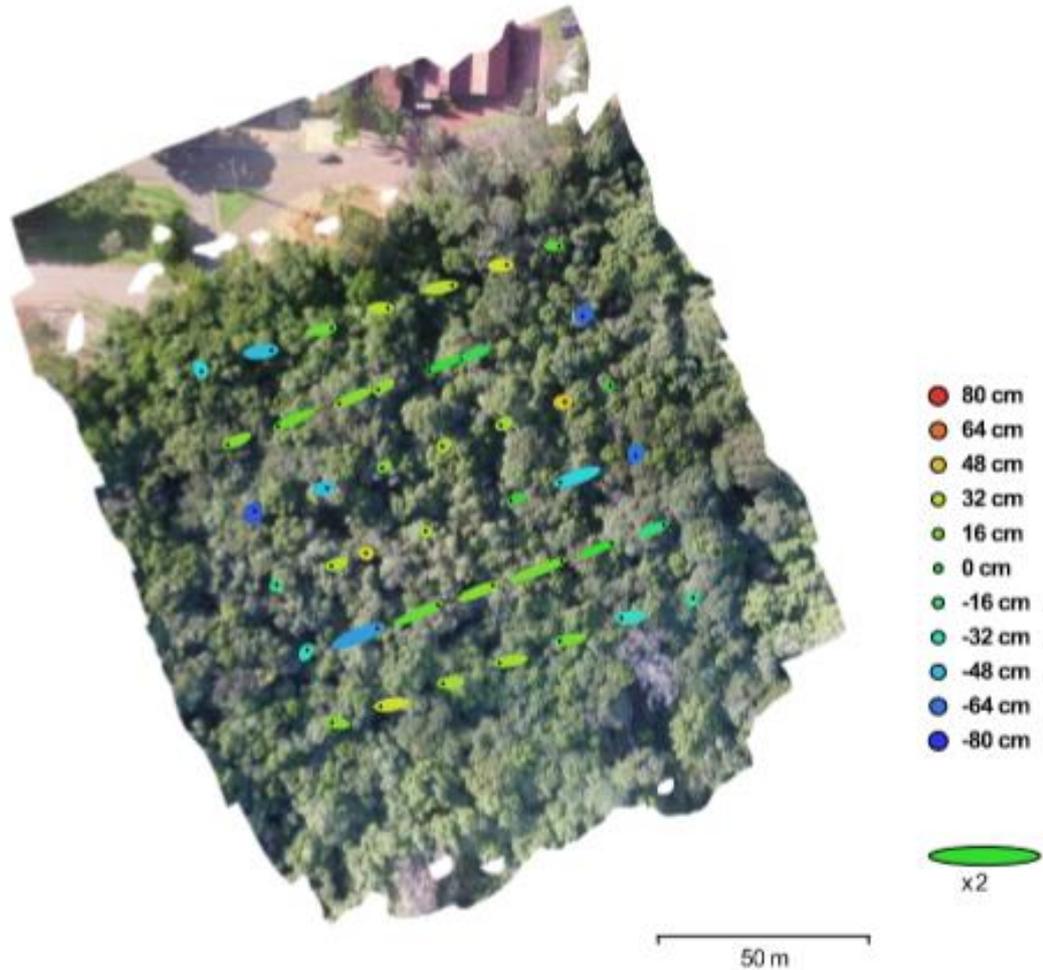


Fig. 3. Camera locations and error estimates.  
 Z error is represented by ellipse color, X,Y errors are represented by ellipse shape.  
 Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
2.36019	0.903835	0.32647	2.52733	2.54833

Table 2. Average camera location error.

## Digital Elevation Model

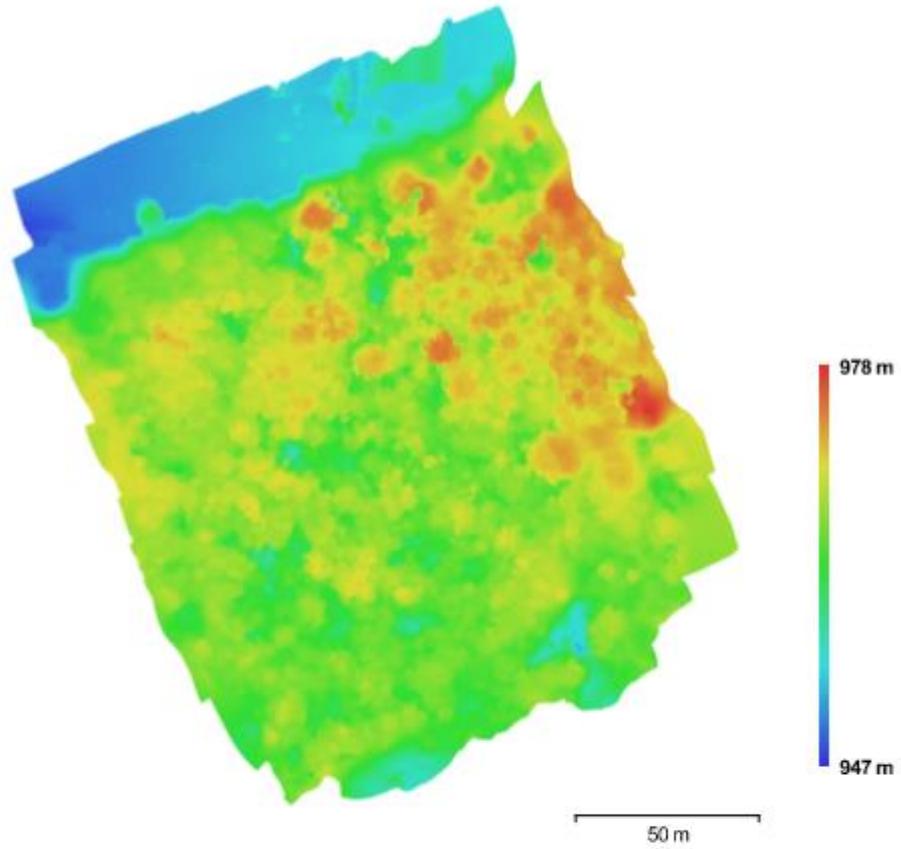


Fig. 4. Reconstructed digital elevation model.

Resolution: 4.1 cm/pix  
Point density: 594 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Mix reprojection error	0.799787 (61.7817 pix)
Mean keypoint size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

<b>DEM</b>	
Size	5,539 x 6,621
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	17 seconds
<b>Orthomosaic</b>	
Size	9,670 x 10,736
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 14 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO H - *Report* de processamento da Matinha no inverno.

## Survey Data

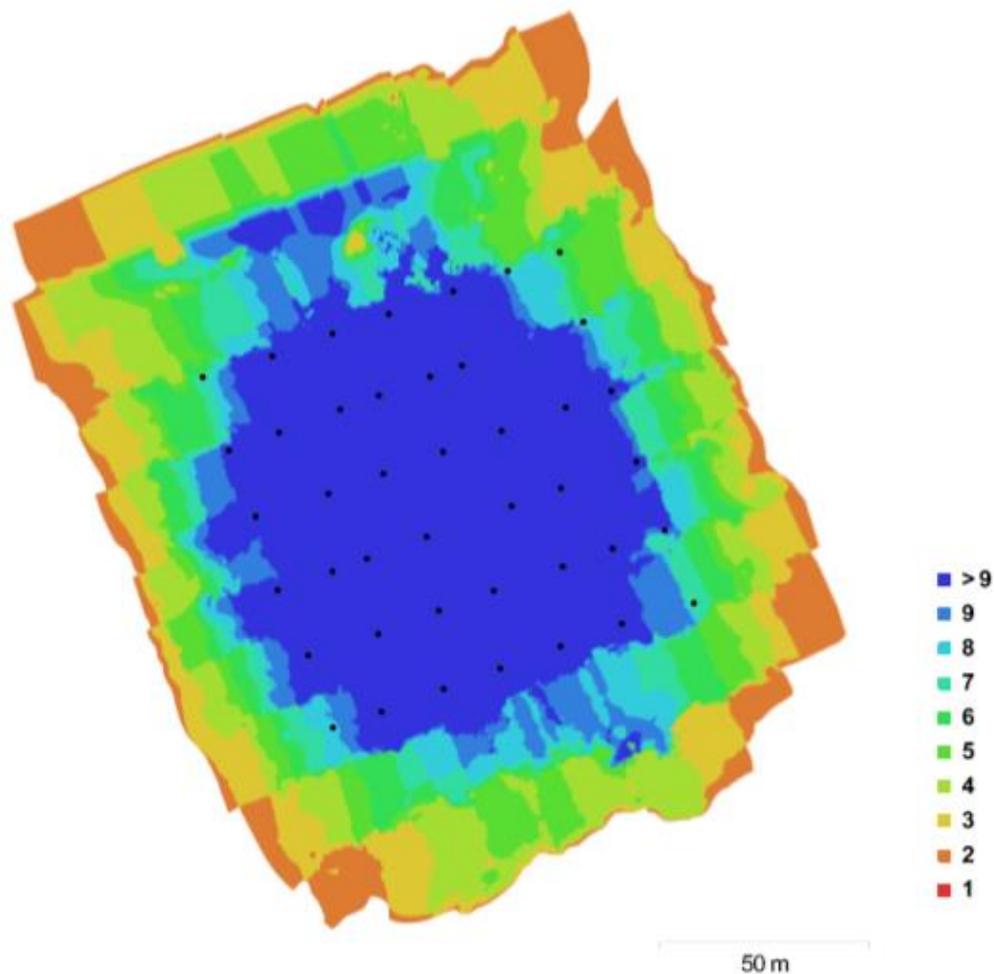


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	55.8 m	Tie points:	54,134
Ground resolution:	2.05 cm/pix	Projections:	132,586
Coverage area:	0.0275 km <sup>2</sup>	Reprojection error:	1.21 pix

## Camera Calibration

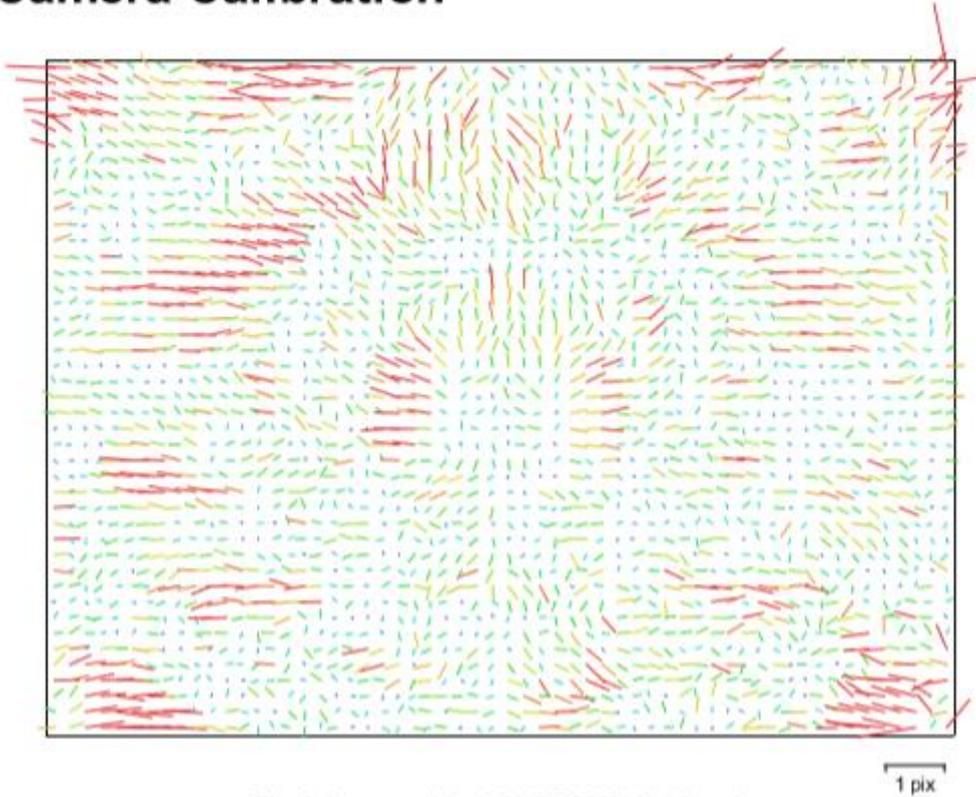


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution <b>4000 x 3000</b>	Focal Length <b>3.61 mm</b>	Pixel Size <b>1.56 x 1.56 <math>\mu\text{m}</math></b>	Precalibrated <b>No</b>
Type:	Frame	F:	2311.25
Cx:	-2.13741	B1:	-4.24597
Cy:	-22.5674	B2:	0
K1:	-0.012997	P1:	0.000121894
K2:	0.0178849	P2:	-0.000445218
K3:	0	P3:	0
K4:	0	P4:	0

## Camera Locations

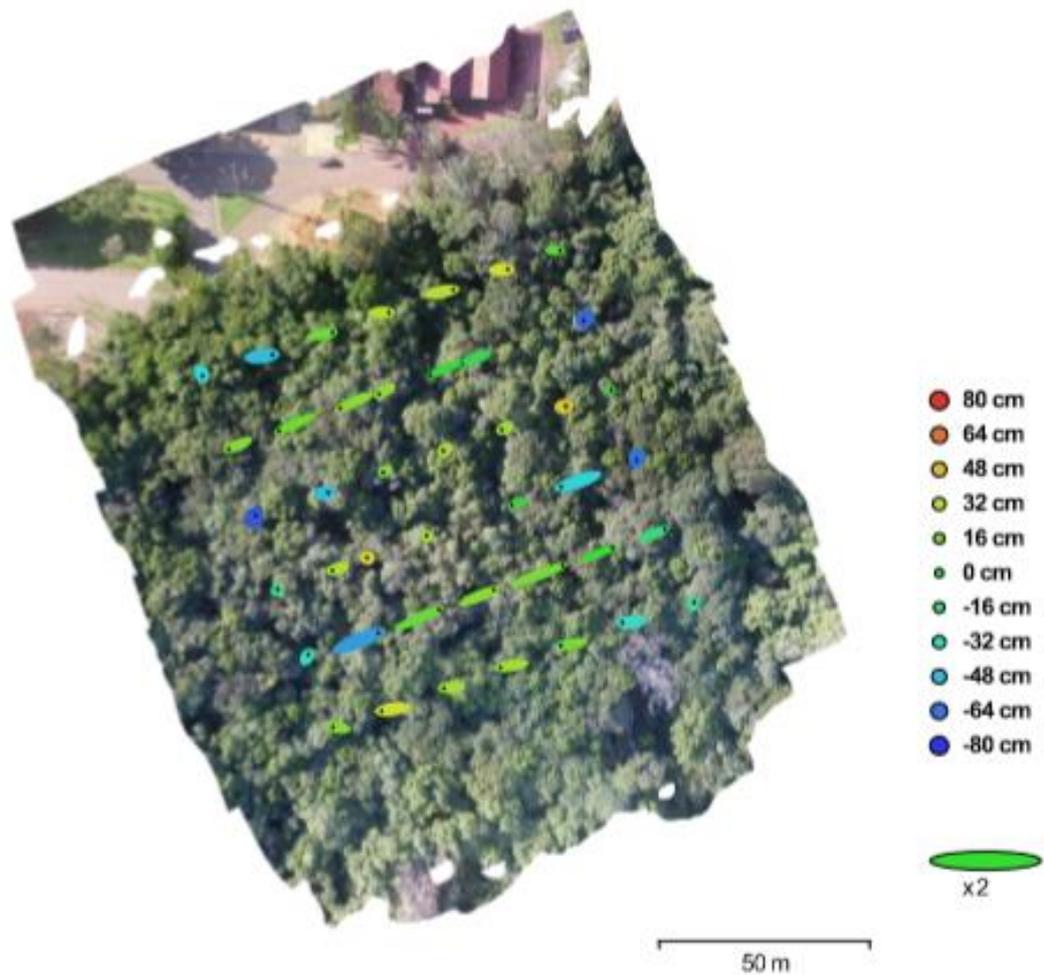


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
2.36019	0.903835	0.32647	2.52733	2.54833

Table 2. Average camera location error.

## Digital Elevation Model

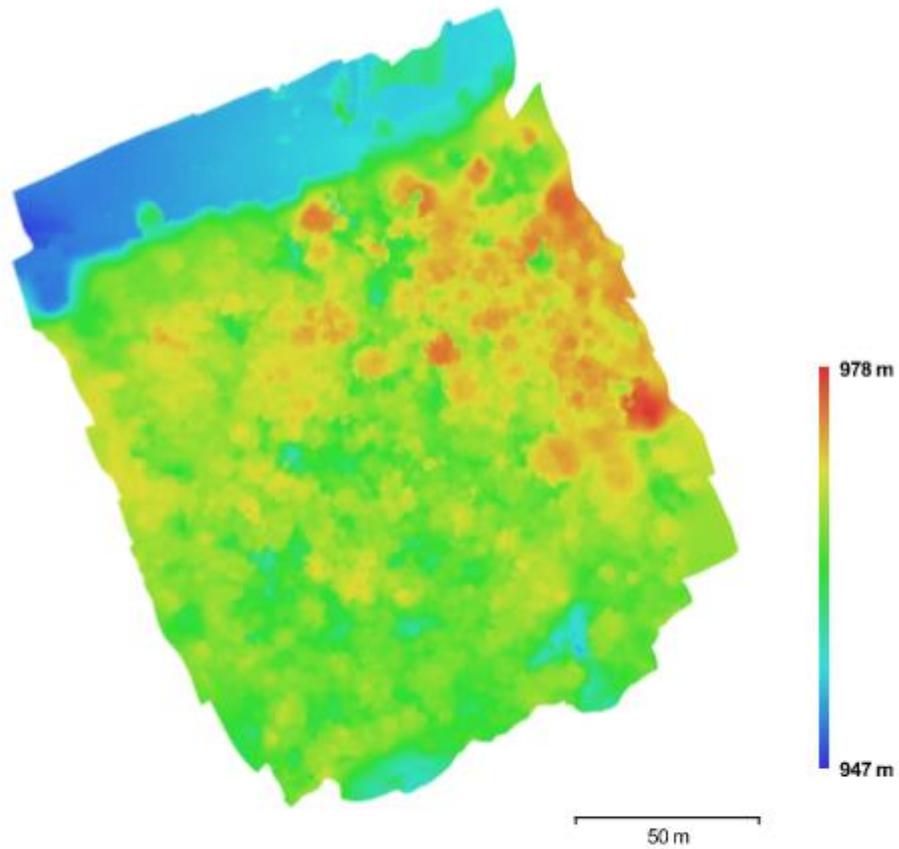


Fig. 4. Reconstructed digital elevation model.

Resolution: 4.1 cm/pix  
Point density: 594 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (61.7817 pix)
Mean keypoint size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

<b>DEM</b>	
Size	5,539 x 6,621
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	17 seconds
<b>Orthomosaic</b>	
Size	9,670 x 10,736
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 14 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO I - *Report* de processamento da Matinha na primavera.

## Survey Data

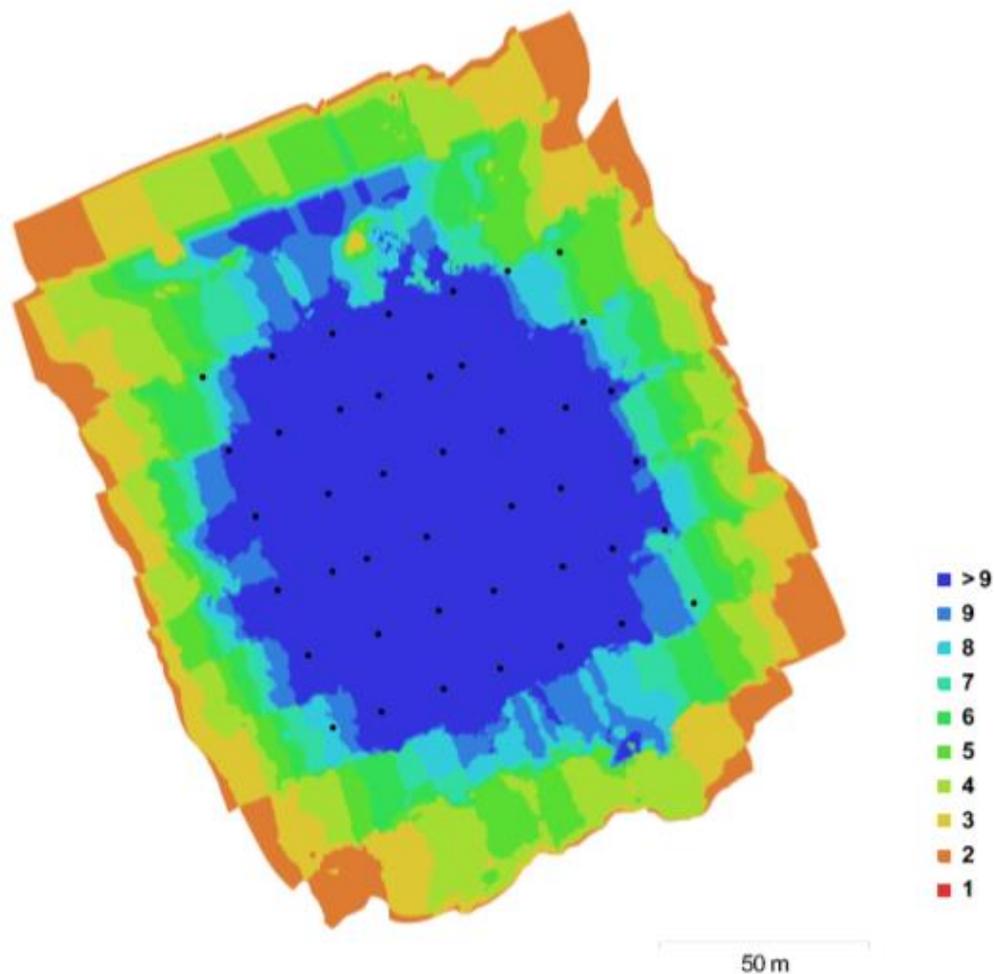


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	55.8 m	Tie points:	54,134
Ground resolution:	2.05 cm/pix	Projections:	132,586
Coverage area:	0.0275 km <sup>2</sup>	Reprojection error:	1.21 pix

## Camera Calibration

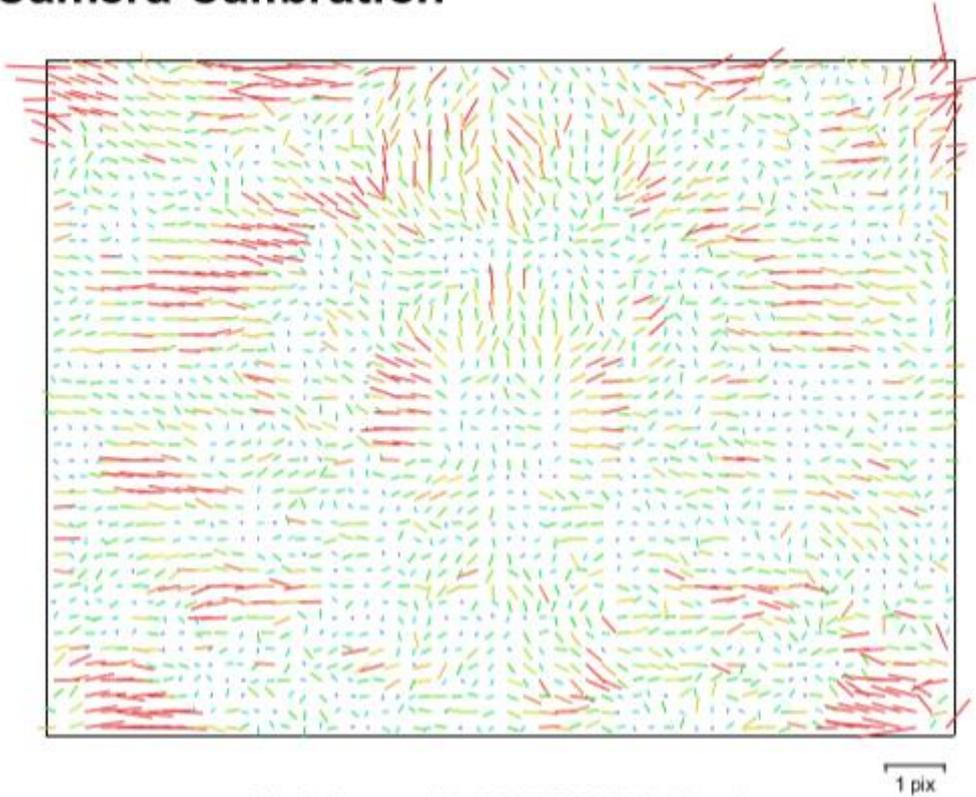


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-2.13741	B1:	-4.24597
Cy:	-22.5674	B2:	0
K1:	-0.012997	P1:	0.000121894
K2:	0.0178849	P2:	-0.000445218
K3:	0	P3:	0
K4:	0	P4:	0

## Camera Locations

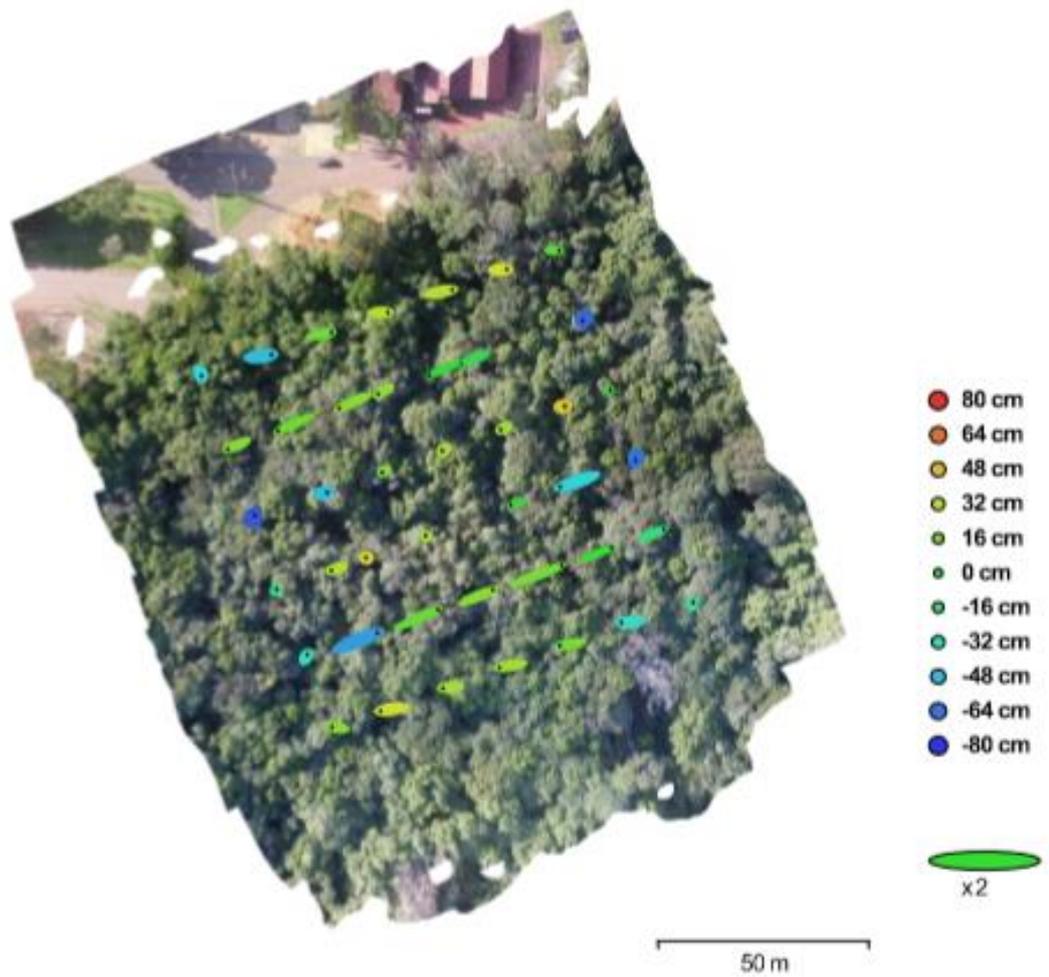


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
2.36019	0.903835	0.32647	2.52733	2.54833

Table 2. Average camera location error.

## Digital Elevation Model

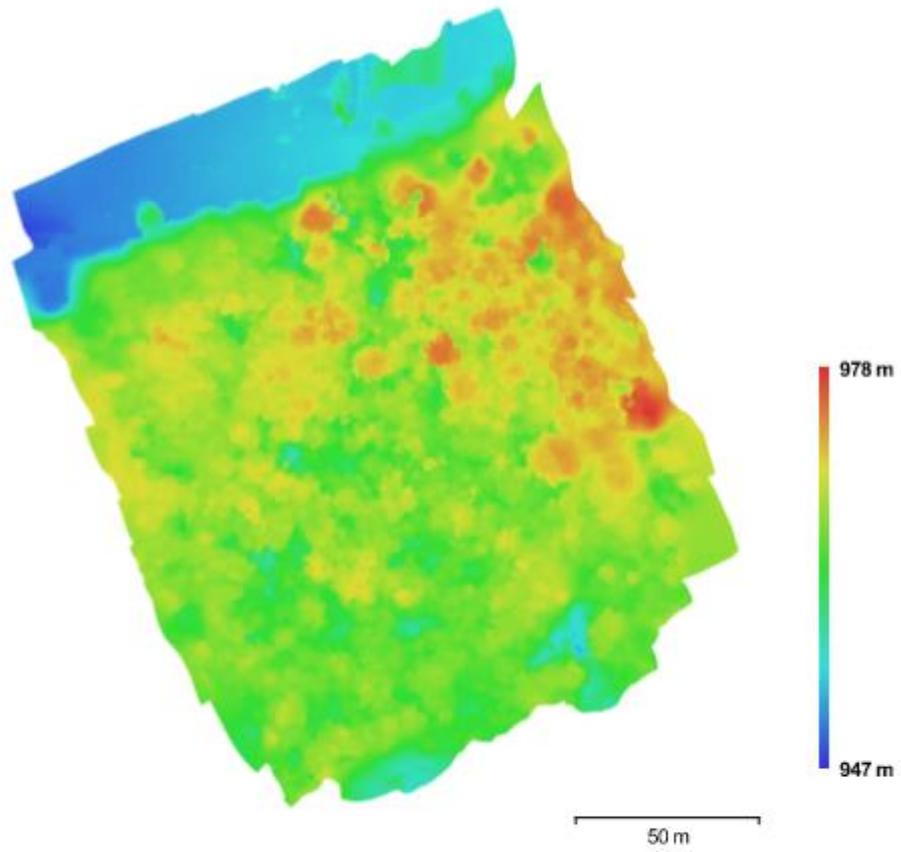


Fig. 4. Reconstructed digital elevation model.

Resolution: 4.1 cm/pix  
Point density: 594 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (61.7817 pix)
Mean keypoint size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Keypoint limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

<b>DEM</b>	
Size	5,539 x 6,621
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	17 seconds
<b>Orthomosaic</b>	
Size	9,670 x 10,736
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 14 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit

ANEXO J - *Report* de processamento da Matinha no verão.

## Survey Data

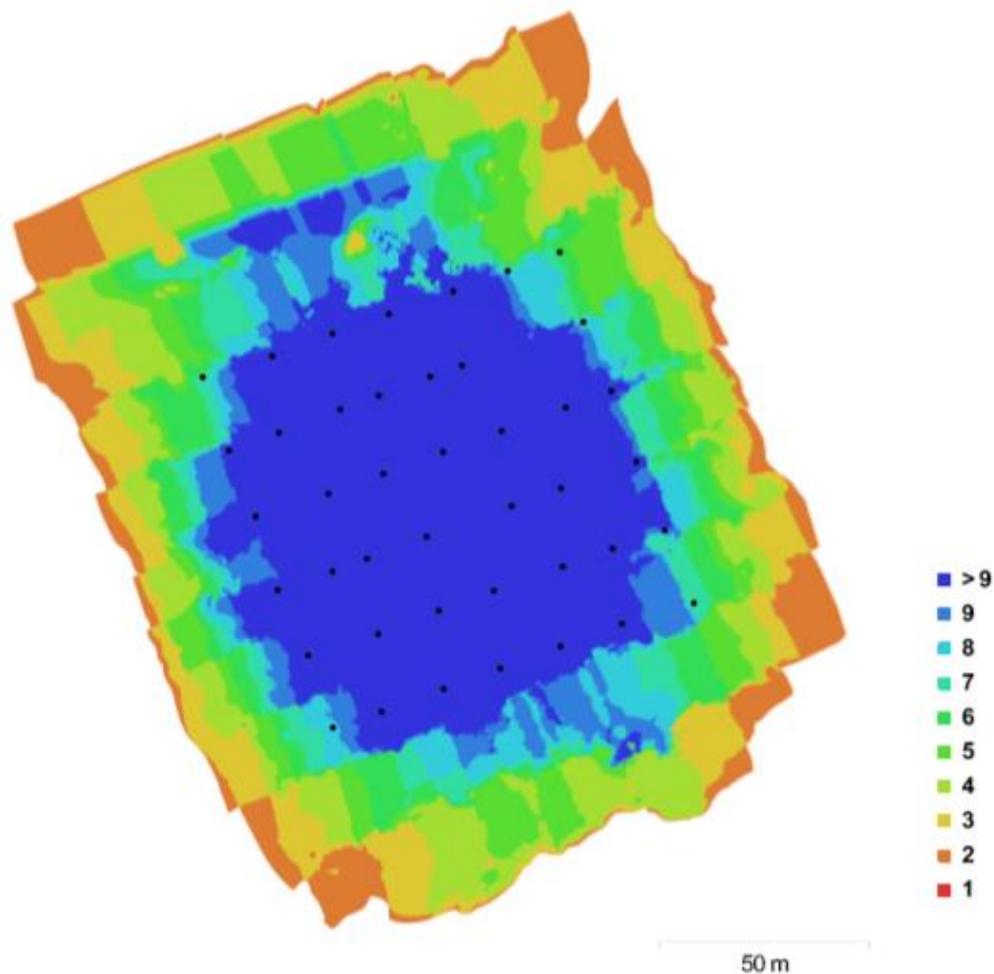


Fig. 1. Camera locations and image overlap.

Number of images:	42	Camera stations:	42
Flying altitude:	55.8 m	Tie points:	54,134
Ground resolution:	2.05 cm/pix	Projections:	132,586
Coverage area:	0.0275 km <sup>2</sup>	Reprojection error:	1.21 pix

## Camera Calibration

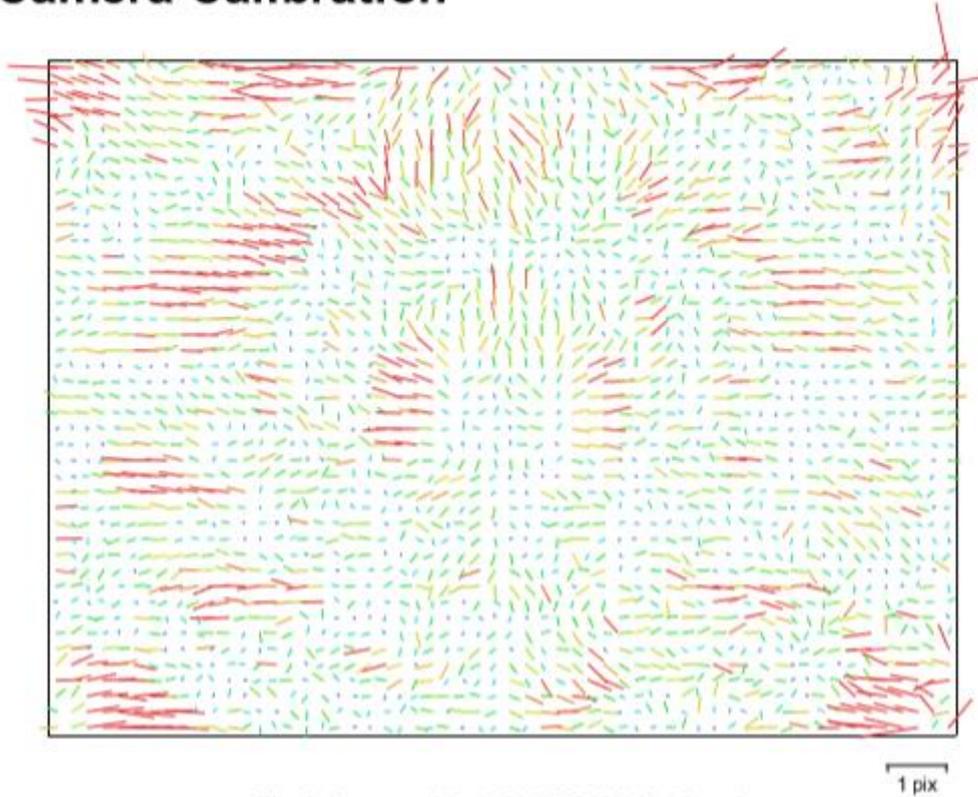


Fig. 2. Image residuals for FC300X (3.61 mm).

### FC300X (3.61 mm)

42 images

Resolution	Focal Length	Pixel Size	Precalibrated
<b>4000 x 3000</b>	<b>3.61 mm</b>	<b>1.56 x 1.56 <math>\mu\text{m}</math></b>	<b>No</b>
Type:	Frame	F:	2311.25
Cx:	-2.13741	B1:	-4.24597
Cy:	-22.5674	B2:	0
K1:	-0.012997	P1:	0.000121894
K2:	0.0178849	P2:	-0.000445218
K3:	0	P3:	0
K4:	0	P4:	0

## Camera Locations

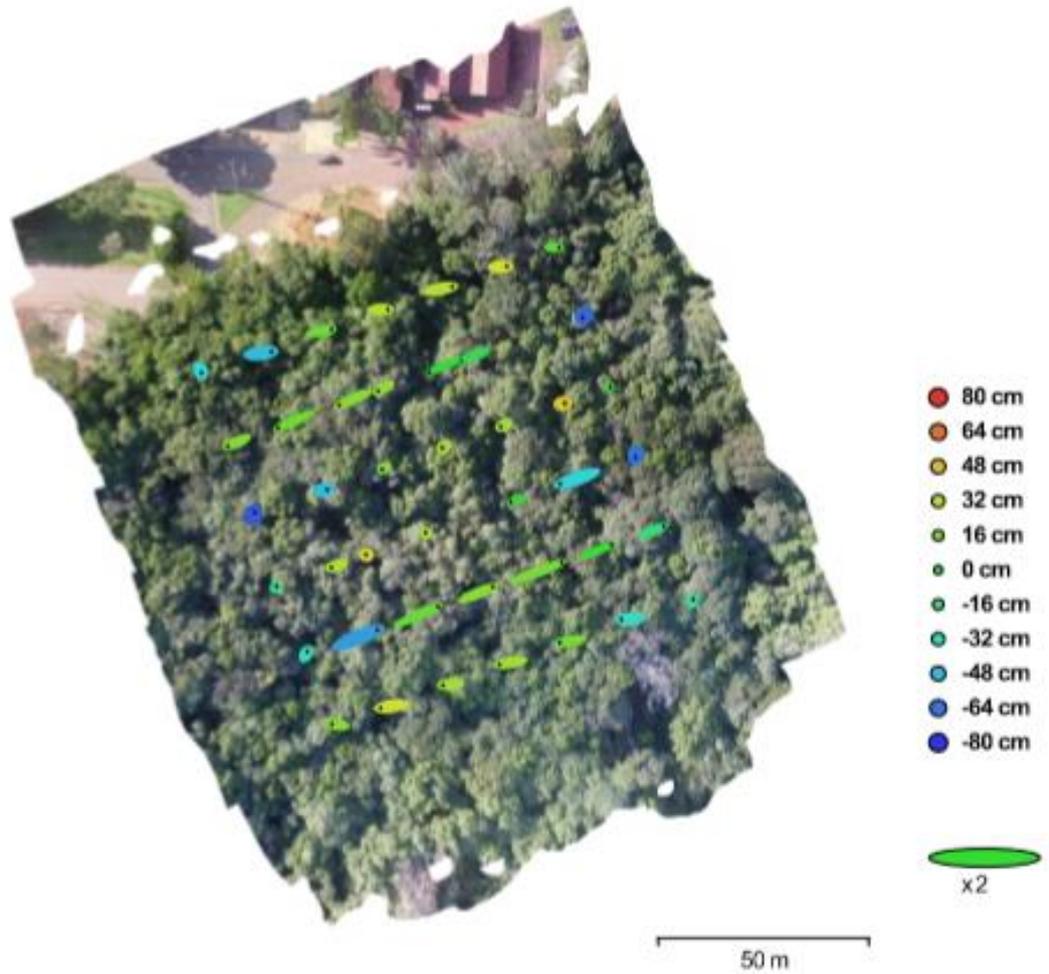


Fig. 3. Camera locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
2.36019	0.903835	0.32647	2.52733	2.54833

Table 2. Average camera location error.

## Digital Elevation Model

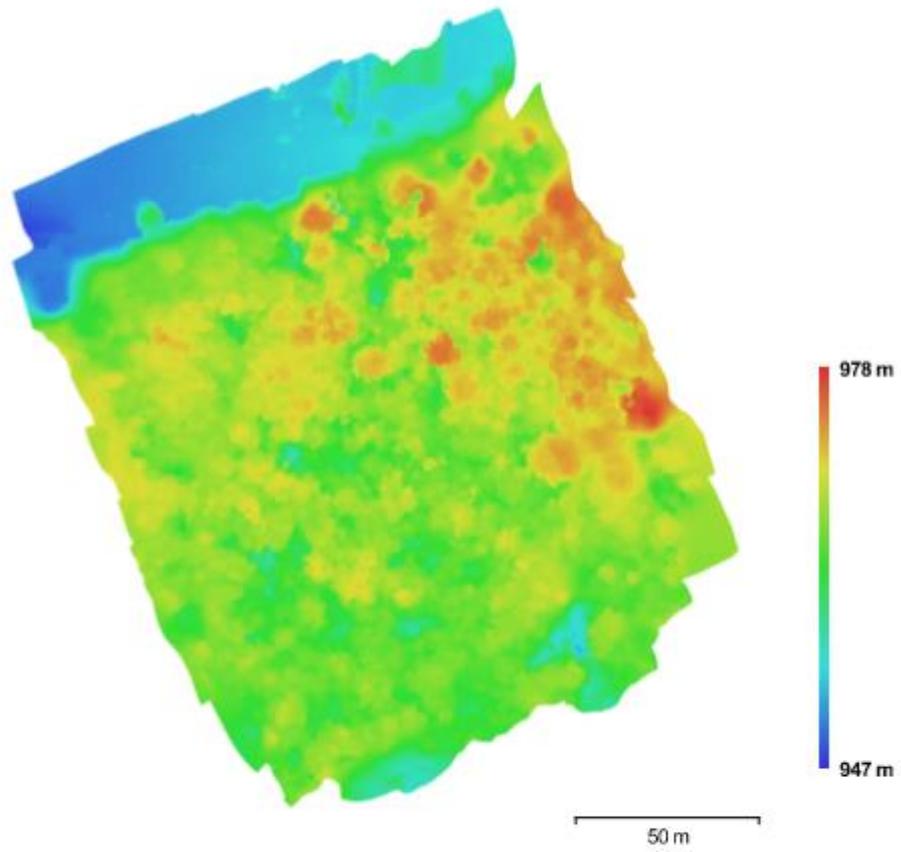


Fig. 4. Reconstructed digital elevation model.

Resolution: 4.1 cm/pix  
Point density: 594 points/m<sup>2</sup>

# Processing Parameters

<b>General</b>	
Cameras	42
Aligned cameras	42
Coordinate system	WGS 84 (EPSG:4326)
<b>Point Cloud</b>	
Points	118,362 of 131,643
RMS reprojection error	0.262965 (1.57715 pix)
Max reprojection error	0.799787 (61.7817 pix)
Mean key point size	5.36262 pix
Effective overlap	3.18135
<b>Alignment parameters</b>	
Accuracy	High
Pair preselection	Disabled
Key point limit	40,000
Tie point limit	10,000
Constrain features by mask	No
Adaptive camera model fitting	Yes
Matching time	13 minutes 26 seconds
Alignment time	41 seconds
<b>Depth Maps</b>	
Count	42
<b>Reconstruction parameters</b>	
Quality	Medium
Filtering mode	Aggressive
Processing time	4 minutes 22 seconds
<b>Dense Point Cloud</b>	
Points	3,993,186
<b>Reconstruction parameters</b>	
Quality	Medium
Depth filtering	Aggressive
Depth maps generation time	4 minutes 22 seconds
Dense cloud generation time	1 minutes 17 seconds
<b>Model</b>	
Faces	784,840
Vertices	393,507
Texture	4,096 x 4,096, uint8
<b>Reconstruction parameters</b>	
Surface type	Height field
Source data	Dense
Interpolation	Enabled
Quality	Medium
Depth filtering	Aggressive
Face count	798,637
Processing time	11 seconds
<b>Texturing parameters</b>	
Mapping mode	Orthophoto
Blending mode	Mosaic
Texture size	4,096 x 4,096
Enable color correction	No
Enable hole filling	Yes
UV mapping time	5 seconds
Blending time	23 seconds
<b>Tiled Model</b>	
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Tile size	256

<b>DEM</b>	
Size	5,539 x 6,621
Coordinate system	SIRGAS 2000 (EPSG:4674)
<b>Reconstruction parameters</b>	
Source data	Dense cloud
Interpolation	Enabled
Processing time	17 seconds
<b>Orthomosaic</b>	
Size	9,670 x 10,736
Coordinate system	SIRGAS 2000 (EPSG:4674)
Channels	3, uint8
Blending mode	Mosaic
<b>Reconstruction parameters</b>	
Surface	DEM
Enable color correction	No
Processing time	1 minutes 14 seconds
<b>Software</b>	
Version	1.2.7 build 3100
Platform	Windows 64 bit