**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Estimativa da altura e produtividade da cana-de-açúcar utilizando
imagens obtidas por aeronave remotamente pilotada**

Maurício Martello

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração: Engenharia
de Sistemas Agrícolas

**Piracicaba
2017**

Maurício Martello
Engenheiro Ambiental

**Estimativa da altura e produtividade da cana-de-açúcar utilizando
imagens obtidas por aeronave remotamente pilotada**
versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **PETERSON RICARDO FIORIO**

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração:
Engenharia de Sistemas Agrícolas

Piracicaba
2017

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Martello, Maurício

Estimativa da altura e produtividade da cana-de-açúcar utilizando imagens obtidas por aeronave remotamente pilotada / Maurício Martello. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2017.

80 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Câmera digital 2. Nuvem de pontos 3. Variabilidade espacial 4. Altura do dossel 5. Sensoriamento remoto I. Título

AGRADECIMENTOS

À Deus por me guiar nessa caminhada em busca do conhecimento.

À meu orientador professor Dr. Peterson Ricardo Fiorio, por todo apoio e dedicação, essencial para o meu desenvolvimento pessoal e acadêmico e também pela amizade e confiança durante os meus anos de mestrado.

Aos professores com quem eu tive contato durante o curso, que gentilmente compartilharam os seus conhecimentos, permitindo o amadurecimento teórico necessário à escrita desta dissertação, em especial os professores Rubens Angulo Filho e Carlos Alberto Vettorazzi.

À Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo, que por meio do Programa de Pós-Graduação em Engenharia de Sistemas Agrícolas, pela possibilidade de realização de meu curso de mestrado, também aos funcionários do departamento de Engenharia de Biossistemas, pela afetividade e suporte, especialmente a Davilmar Collevatti e Lúcia Monteiro.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), por fomentar o projeto de pesquisa nº 2013/22435-9, no qual este trabalho faz parte.

Aos pesquisadores Heitor Cantarella e Zaqueu Fernando Montezano, e à equipe de pesquisa do Instituto Agrônomo de Campinas, que possibilitaram o desenvolvimento deste trabalho, junto às áreas experimentais referentes ao projeto temático BIOEN/FAPESP 2008/56147-1.

À CAPES pela concessão da bolsa de estudo.

À minha família, em especial ao meus pais, Mauri e Jaqueline pelo amor incondicional e por todo apoio prestado.

Aos meus irmãos Filipe, João e Antônio que a cada retorno à Concórdia sempre me receberam com alegria.

Ao meu grande amor, Graciele Angnes que esteve ao meu lado me incentivando desde os primeiros dias do meu mestrado, se não fosse pela sua presença em minha vida, talvez eu não teria vivido essa experiência enriquecedora.

À Milton L. Massolini, pelo apoio e ensinamentos transmitidos durante este período.

Aos amigos do TopoGeo, da Casa 1872, do LAP, do GeoCis, em especial a Tiago R. Tavares, Taila F. Strabeli, Wanderlei Bieluczyk e Juan José Quiriós Vargas pela amizade verdadeira que foi contruída durante o mestrado.

EPIGRAFE

“O verdadeiro homem mede a sua força, quando se defronta com o obstáculo.”

Antoine de Saint-Exupéry

SUMÁRIO

RESUMO.....	7
ABSTRACT.....	8
1. INTRODUÇÃO	9
2. REVISÃO BIBLIOGRÁFICA.....	11
2.1. A CULTURA DA CANA-DE-AÇÚCAR E AVALIAÇÃO DO DESENVOLVIMENTO.....	11
2.2. SENSORIAMENTO REMOTO APLICADO À VEGETAÇÃO.....	12
2.3. AERONAVE REMOTAMENTE PILOTADA (RPA) COMO PLATAFORMA DE SR.....	14
2.4. USO DE AERONAVES REMOTAMENTE PILOTADAS (RPAS) PARA OBTENÇÃO DE DADOS AGRÍCOLAS	15
2.5. MODELOS DIGITAIS DA SUPERFÍCIE E DO TERRENO	17
2.6. MODELAGEM DA ALTURA DA CULTURA.....	18
3. MATERIAL E MÉTODOS	21
3.1. ÁREA DE ESTUDO	21
3.2. DELIMITAÇÃO DO EXPERIMENTO	21
3.3. EQUIPAMENTOS UTILIZADOS PARA COLETA DE DADOS	23
3.3.1. Descrição do RPA utilizado.....	23
3.3.2. Estação de controle.....	23
3.4. OBTENÇÃO DAS IMAGENS AÉREAS.....	24
3.4.1. Plano de voo	25
3.5. AQUISIÇÃO DE DADOS	26
3.6. PROCESSAMENTO DOS DADOS.....	27
3.6.1. Georreferenciamento das imagens	27
3.6.2. Geração dos modelos digitais	27
3.6.3. Geração do MDT Mensal	29
3.6.4. MDT inicial e final	30
3.6.5. MDT de referência obtido por levantamento planialtimétrico	30
3.7. ANÁLISE DOS DADOS.....	30
3.7.1. Avaliação dos MDTs	30
3.7.2. Avaliação dos MDS	31
3.7.3. Análise da relação entre modelo de altura da cultura e dados biométricos	31
3.7.4. Estimativa da produtividade utilizando dados de altura.....	33
3.7.5. Análise da variabilidade espacial	33
4. RESULTADOS E DISCUSSÃO	35
4.1. ANÁLISE DOS MDTs	35
4.1.1. MDT inicial e final	35
4.1.2. MDT Mensal RGB e IVP	38
4.2. MODELOS DIGITAIS DE SUPERFÍCIE (MDS), PARA DADOS RGB E IVP.....	46
4.3. GERAÇÃO DOS MODELOS DE ALTURA DA CULTURA - MAC	49
4.4. RELAÇÃO ENTRE A ALTURA E A PRODUTIVIDADE FINAL.....	53
4.5. AVALIAÇÃO DA VARIABILIDADE ESPACIAL DA CANA-DE-AÇÚCAR POR MEIO DO MAC.....	55
4.5.1. Comparação entre o MAC e Mosaico RGB.....	55
4.5.2. Avaliação da variabilidade espacial do MAC com relação a dose de N.....	58

4.5.3. Avaliação da variabilidade espacial do MAC com relação ao fechamento de dossel	61
4.5.4. Estimativa da produtividade por meio do MAC	65
5. CONCLUSÃO.....	67
6. CONSIDERAÇÕES FINAIS	69
REFERÊNCIAS	71

RESUMO

Estimativa da altura e produtividade da cana-de-açúcar utilizando imagens obtidas por aeronave remotamente pilotada

Nos últimos anos, acompanhar o desenvolvimento de uma cultura tem se tornado cada vez mais imprescindível para a tomada de decisões. Sistemas aéreos remotamente pilotados são muito promissores em aplicações de monitoramento. Sua flexibilidade, facilidade de operação e construção relativamente barata os tornam os melhores candidatos para monitorar atividades na agricultura de precisão, onde as reações imediatas de manejo às doenças das plantas, à falta de nutrientes das plantas e às mudanças ambientais são o ponto focal para eficiência e produtividade das plantações. No entanto, no Brasil a utilização desta tecnologia ainda é limitada e o número de publicações científicas sobre o assunto é escasso. No caso específico da cana-de-açúcar, a utilização de aeronave remotamente pilotada (RPA) é bastante promissora e publicações científicas internacionais são limitadas. O objetivo deste trabalho foi avaliar a potencialidade de imagens obtidas a partir de câmeras com diferentes bandas espectrais embarcadas em RPA para obtenção de modelos tridimensionais para estimativa de altura, produtividade e variabilidade espacial. As coletas foram realizadas ao longo da safra 2014/2015, durante o período de um ano. Foi utilizada uma aeronave remotamente pilotada equipada com uma câmera digital com sensibilidade na região espectral do visível (RGB) e outra na região espectral do infravermelho próximo (IVP) sincronizadas com um sistema de navegação global por satélite (GNSS). Este sistema possibilitou a aquisição de imagens com altíssima resolução (3 cm pixel⁻¹) e permitiu a geração de orto-mosaicos e modelos digitais de superfícies (MDS) através de métodos de reconstrução automática em 3D, ajustados por pontos de controle em solo. O RPA seguiu um plano de voo pré-determinado sobre o local do estudo para garantir a aquisição de imagens com cruzamento e sobreposição superior a 90%. O método de validação foi conduzido a partir das medidas de altura obtidas a campo com o auxílio de régua topográfica. Após o processamento das imagens aéreas foi possível a identificação das áreas com ausência de fechamento de dossel, observando também a relação desses locais com o baixo desenvolvimento da altura das plantas ao longo de seu ciclo. A regressão entre os valores da estimativa de altura obtidas com as simulações apresentou erro relativo inferior a 13%, já a estimativa da produtividade apresentou erro na faixa de 6%. A estimativa de altura e produtividade demonstram o alto potencial para o monitoramento e avaliação de talhões de cana-de-açúcar, podendo ser uma ferramenta utilizada no apoio a gestão destas áreas.

Palavras-chave: Câmera digital; Nuvem de pontos; Variabilidade espacial; Altura do dossel; Sensoriamento remoto

ABSTRACT

Height and productivity estimation of sugarcane using images obtained by remotely piloted aircraft

In the last few years, monitoring the development of a culture has become increasingly imperative for decision-making. Remotely piloted aircraft systems (RPA) are very promising in monitoring applications. Their flexibility, ease of operation, and relatively inexpensive construction make them the best candidates to monitor precision farming activities where immediate management responses to plant diseases, lack of plant nutrients, and environmental changes are the focal point for efficiency and productivity of plantations. However in Brazil the use of this technology is still limited and the number of scientific publications on the subject is scarce. In the specific case of sugarcane the use of RPA is very promising and international scientific publications are limited. The objective of this work was to evaluate the potentiality of images obtained from cameras with different spectral bands embedded in RPA to obtain three-dimensional models for estimation of height, productivity and spatial variability. The collections were carried out during the 2014/2015 harvest, during a period of one year, using a remotely piloted aircraft equipped with a digital camera with sensitivity in the visible spectral region (RGB) and another in the near infrared spectral region (NIR) Synchronized with a GNSS. This system allowed the acquisition of images with very high resolution (3 cm pixel⁻¹) allowing the generation of ortho-mosaics and digital surface models (DSM), through automatic 3D reconstruction methods adjusted by control points in soil. The RPA followed a pre-determined flight plan on the study site to ensure cross-over and overlapping acquisition of over 90%. The validation method was carried out from the height measurements obtained in the field with the aid of topography. After the aerial images processing, it was possible to identify the areas of crop failure, also observing the relation of these locations with the low development of plant height throughout its cycle. The regression between the values of the height estimation obtained with the simulations resulted in a relative error of less than 13%. The results obtained demonstrate the high potential of this technique for monitoring and evaluation of sugarcane fields, and can be a tool used to support the management of these areas.

Keywords: Digital camera; Point cloud; Spatial variability; Canopy height; Remote sensing

1. INTRODUÇÃO

O Brasil tem seguido a tendência mundial de busca por inovações que proporcionem melhores resultados de produção afim de atender à crescente necessidade mundial de alimentos e energia. A cana-de-açúcar se destaca no cenário nacional, além de ser uma fonte direta de alimento (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2015), é também fonte para a produção de etanol. Em dezembro de 2016 foi estimada a produção de 694,54 milhões de toneladas para a safra 2015/2016, em uma área de 9,1 milhões de hectares, correspondendo a um incremento de 4,4% em relação a última safra (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2016).

A demanda mundial por etanol tende a aumentar cada vez mais, de 80 bilhões de litros produzidos em 2013, estima-se produção de 200 bilhões de litros em 2021 (GOLDEMBERG et al., 2014). Essa necessidade pelo aumento da produção de etanol requer que o plantio e o processamento industrial da cana-de-açúcar sejam extremamente eficientes para alcançar os objetivos de produtividade. Tal fato gera para o setor sucroalcooleiro alta demanda por novas tecnologias que visem ao aumento do rendimento da produtividade.

O geoprocessamento, em especial, o sensoriamento remoto são ferramentas potenciais para o correto diagnóstico e intervenção no manejo das culturas. O conhecimento de parâmetros agronômicos obtidos direta ou indiretamente permite a observação da heterogeneidade espacial e podem refletir consideravelmente no processo produtivo com potencial retorno econômico. Entre esses parâmetros agronômicos, a altura da planta merece destaque já que além de indicar o desenvolvimento da mesma, apresenta-se como um parâmetro com alta correlação com a produtividade.

O sensoriamento remoto permite a obtenção de imagens multiespectrais e hiperespectrais que são empregadas em diversas atividades relacionadas ao monitoramento de fenômenos que ocorrem na superfície do terreno. Esse tipo de dado é empregado com sucesso na agricultura, pois a vegetação possui comportamento espectral que permite detectar variações em suas características físicas. Imagens multiespectrais de satélite têm sido usadas no mapeamento de lavouras como a de cana-de-açúcar, pois fornecem uma previsão da estimativa de área plantada da cultura, permitindo discriminar áreas de cana-de-açúcar preparadas para colheita ou cultivo, áreas de reforma e áreas em expansão. Além disso, o sensoriamento remoto através do uso de imagens de satélite tem sido utilizado por empresas para o acompanhamento da cultura e construção do histórico das áreas cultivadas.

A utilização de informações oriundas de sensores orbitais já é consagrada como uma ferramenta na agricultura, porém ainda existem algumas limitações em utilizações específicas, como na identificação de falhas nas lavouras e avaliação de variabilidade com alto nível de detalhamento, que necessitam de alta precisão e alta resolução espacial. Além disso, o monitoramento mais detalhado do desenvolvimento de culturas agrícolas necessita de imagens obtidas em levantamentos aéreos que possam ser realizados conforme a disponibilidade de janela (céu livre de cobertura de nuvens), mesmo porque ao verificar a ocorrência de doenças ou pragas na cultura é importante a rapidez na detecção do fenômeno para realizar o manejo adequado.

A utilização de sensores embarcados em uma aeronave remotamente pilotada (RPA) pode responder bem a essas demandas, uma vez que possibilita obter informações ao nível aéreo, porém em distâncias mais próximas aos alvos. Além disso, o baixo custo de operação e flexibilidade das plataformas RPA torna esta tecnologia interessante para ser aplicada na agricultura, sendo possível coletar dados quantas vezes forem necessárias, sem a dependência da resolução temporal do sistema orbital ou os altos custos de um sobrevoo com avião convencional.

Outra informação de grande relevância que pode ser obtida pelas imagens dos RPAs é a modelagem tridimensional da área de estudo que permite estimar a altura da cultura. Para a cana-de-açúcar essa informação é importante na estimativa da produtividade, conforme foi descrito por Portz, Amaral e Molin (2012). Além disso, estudos internacionais já identificaram a praticidade e rapidez de obtenção da altura da cultura por meio de imagens obtidas por RPAs em comparação a outras tecnologias. Holman et al. (2016) observaram que a utilização do RPA e a modelagem tridimensional resulta em uma coleta de dados 72 vezes mais rápida quando comparada a tecnologia LiDAR (Laser Scanner) embarcada em um trator, por exemplo.

O RPA, portanto, se caracteriza como uma plataforma que tem como única função elevar os sensores ao nível aéreo, respeitando um plano de voo pré-definido. Dependendo da categoria de tamanho dos RPAs, é possível embarcar os mais diversos sensores para suprir várias necessidades de campo. Apesar do seu potencial, o uso desta tecnologia ainda é incipiente no Brasil, havendo necessidade de mais pesquisa e desenvolvimento metodológico para a utilização destes veículos de forma operacional.

A partir do exposto, a hipótese levantada neste trabalho foi que as imagens obtidas com câmeras de baixo custo embarcadas em plataformas aéreas remotamente pilotadas podem ser utilizadas na estimativa da altura, produtividade e variabilidade espacial da lavoura de cana-de-açúcar. Levando em consideração esta hipótese, surge o interesse do presente trabalho, o qual acompanhou com as imagens obtidas por RPA o desenvolvimento do dossel de cana-de-açúcar, objetivando avaliar temporalmente a relação entre a altura da cultura, estimativa da produtividade, identificação da variabilidade e definição do melhor momento para as coletas das imagens para a geração da modelagem tridimensional.

2. REVISÃO BIBLIOGRÁFICA

2.1. A cultura da Cana-de-açúcar e avaliação do desenvolvimento

A cana-de-açúcar (*Saccharum spp.*) é uma gramínea com metabolismo fotossintético C4, de porte alto, pertencente à família Poaceae. É uma cultura robusta, eficiente na produção de biomassa e que devido a sua rebrota possui comportamento semiperene. Devido ao grande acúmulo de sacarose nos colmos sua principal finalidade é para a produção de etanol e açúcar (DINARDO MIRANDA; VASCONCELOS; LANDELL, 2008).

A cana-de-açúcar tem papel importante na economia brasileira, o Brasil é o maior produtor de cana do mundo e o primeiro na produção de açúcar e etanol (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2016). A alta demanda dos mercados interno e externo pelos produtos obtidos através da cana e a expansão das áreas de produção em diversas regiões do País, tem intensificado a necessidade de obter informações que apresentam relação direta com a produtividade e permitem a avaliação do desenvolvimento da cultura (ANDRADE et al., 2014).

A importância do conhecimento do ciclo da cultura e dos padrões de crescimento e desenvolvimento das plantas é fundamental para o manejo correto, pois visando-se a máxima produtividade econômica, toda e qualquer produção vegetal, deve fundamentar-se na interação de três fatores: a planta, o ambiente de produção e o manejo. Assim sendo, no caso específico do processo canavieiro a finalidade deve ser a produtividade, qualidade da matéria prima e a longevidade do canavial (CÂMARA, 1993).

A análise de crescimento em plantas é considerada um método padrão para se medir a produtividade biológica de uma cultura em seu ambiente de produção (MAGALHÃES, 1985). Além disso, permite identificar as prováveis variações no desenvolvimento que ocorrem durante o ciclo da cultura, tornando-se fundamental para modelar e quantificar o crescimento nos diferentes estádios de desenvolvimento (TERUEL; BARBIERI; FERRARO JR., 1997).

A identificação da capacidade produtiva é possível a partir da avaliação de algumas variáveis morfológicas das plantas, como altura, diâmetro, plantas m^{-1} , área foliar (SILVA; JERONIMO; LÚCIO, 2008). Essa identificação permite também a investigação dos efeitos do manejo da cultura (MARTINS; LANDELL, 1995).

O desenvolvimento da cana-de-açúcar é dividido, em quatro fases segundo Diola e Santos, (2010). A primeira fase é caracterizada pelo crescimento lento e tem dependência da umidade do solo, chama-se, brotação e estabelecimento e para a ocorrência de brotação são necessários 20 a 30 dias; A segunda fase, denominada perfilhamento, tem início em torno de 40 dias após o plantio e pode durar até 120 dias; o crescimento dos colmos é a terceira fase, começa a partir dos 120 dias após o plantio (ou corte) e dura por até 270 dias em um cultivo de 12 meses. Esta fase é a mais importante do cultivo, acumulando aproximadamente 75% da matéria seca total. A última fase é a maturação dos colmos, quando ocorrem reduções nas taxas de crescimento da planta e aumento no acúmulo de sacarose nos colmos, tendo início de 270 a 360 dias após o plantio e podendo se prolongar por até 6 meses.

Para reduzir custos de produção, o conhecimento do desenvolvimento temporal das variáveis agrônômicas da cana-de-açúcar é um aspecto importante, pois permite o desenvolvimento de modelos de entendimento e predição da produção da cultura (MARAFON, 2012).

Em relação aos modelos para prever e simular o crescimento e a produtividade da cana-de-açúcar destacam-se os parâmetros fenológicos (MARIN; JONES, 2014). Ferreira et al., (2007) destacam que a biometria das cultivares de cana-de-açúcar são importantes para o estudo de correlação fenotípica, pois permite a identificação de cultivares mais responsivos garantindo maior produtividade. A altura foi avaliada como um componente que possui relação direta com a produção da cana-de-açúcar por Silva et al., (2009). Além disso, outro estudo realizado por Santana, Oliveira e Melo, (2010) com variedades comerciais de cana-de-açúcar demonstrou que a altura é fator determinantes para estimativa da produção de cana-de-açúcar, e os autores destacaram que características biométricas podem permitir a identificação da variedade que melhor se adapta a determinada região.

Diante da importância do conhecimento de dados que possuam relação com o desenvolvimento da cultura, são necessárias ferramentas que forneçam informações para obter estimativas confiáveis, possibilitando a criação de cenários que facilitem a tomada de decisão quanto ao manejo localizado, à logística de colheita, planejamento das operações nas usinas, armazenamento e escoamento da produção (MAGALHÃES et al., 2013). No entanto, para Rocha (2002), somente com o Sensoriamento Remoto aliado a Agricultura de Precisão é possível implantar o gerenciamento localizado nas áreas agrícolas.

2.2. Sensoriamento Remoto aplicado à vegetação

O sensoriamento remoto é a ciência que permite obter informações da superfície ou alvos terrestres por meio da captação e do registro da energia refletida ou emitida pela superfície através de sensores instalados em plataformas terrestres, orbitais ou aéreas (FLORENZANO, 2002; ANDRADE, 2011). No contexto agrícola, a aplicação do Sensoriamento Remoto é baseada na interação da radiação eletromagnética (REM) com o solo, vegetação e água (MULLA, 2013).

A REM é caracterizada como uma forma dinâmica de energia que se manifesta a partir da sua interação com o alvo, é por meio desta que a informação é transferida do objeto ao sensor (NOVO, 2010). A REM pode ser obtida por diferentes fontes, naturais e artificiais (ROSA, 2009). Sensores que não possuem sua própria fonte de REM são classificados como passivos, e sensores que possuem a sua própria fonte de REM são classificados como ativos (JENSEN, 2009).

Desde a década de 1960, cientistas vêm extraindo e modelando muitos parâmetros biofísicos da vegetação com o uso do Sensoriamento Remoto através da interação REM com a vegetação. Assim, o Sensoriamento Remoto permite obter informações que possuem relação direta com dados obtidos em campo, além de possibilitar amostrar áreas com maior rapidez e recobrimento (JENSEN, 2009).

Os sensores podem ser embarcados em diferentes plataformas, portanto a distância do sensor em relação ao alvo pode ser classificada de acordo com os níveis de altitude, sendo orbital, aéreo e terrestre (FLORENZANO, 2002).

Especificamente na cultura da cana-de-açúcar trabalhos foram desenvolvidos utilizando sensores nos três níveis de coleta.

Estudos tem demonstrado a eficiência do sensoriamento remoto a nível terrestre aliado a técnicas da agricultura de precisão para monitorar e avaliar a cultura da cana-de-açúcar. Trabalhos utilizando sensores de reflectância multiespectrais ativos já foram usados para identificação da variabilidade espacial do nitrogênio e biomassa da cana-de-açúcar (PORTZ; MOLIN; JASPER, 2012; AMARAL et al., 2014), na quantificação da resposta a doses de nitrogênio (MOLIN et al., 2010; ROSA et al., 2015), bem como servindo de aporte para a aplicação de nitrogênio em taxa variável (AMARAL; MOLIN; SCHEPERS, 2015). No entanto, um entrave desta técnica para predição da biomassa e do nitrogênio é a saturação do sinal que começa a estar presente quando a planta apresenta altura acima de 0,6 metros dificultando a predição desses atributos (PORTZ; AMARAL; MOLIN, 2012b). Além da avaliação da resposta ao nitrogênio e predição de biomassa os sensores ativos também são empregados para avaliar a qualidade do plantio, quantificando as áreas de falhas e na avaliação do comportamento temporal através de índices de vegetação na fase inicial do cultivo (FRASSON et al., 2007).

Sensores de reflectância hiperespectrais passivos VisNIR (350 a 2500 nm), são utilizados para a predição do teor relativo de clorofila da cana-de-açúcar (FIORIO et al., 2015), na diferenciação de doses de nitrogênio (MIPHOKASAP et al., 2012; TAVARES et al., 2015) e para avaliação da resposta da cultura em relação ao ambiente de produção (MARTINS et al., 2015).

Já o sensoriamento remoto ao nível aéreo/orbital, é capaz de obter informações de extensas áreas apresentando um grande potencial no monitoramento da variabilidade espacial na área de estudo. Estudo realizado nas principais empresas produtoras de cana-de-açúcar do estado de São Paulo comprovou que a utilização das imagens obtidas por sensores orbitais e por aeronaves convencionais estão entre as principais tecnologias para aplicação da agricultura de precisão em cana-de-açúcar (SILVA; DE MORAES; MOLIN, 2011).

A aplicação de imagens orbitais em áreas cultivadas com cana se apresenta como uma alternativa de baixo custo e possibilita a obtenção de informações importantes para o manejo da cultura, graças aos sensores embarcados que registram a resposta da interação da radiação eletromagnética (REM) com o dossel da cultura, obtendo a resposta espectral (FORTES; DEMATTÊ, 2006). Essa resposta espectral pode fornecer através das imagens e os índices de vegetação (IVs) algumas informações, como estimativa da evapotranspiração (YANG; ZHOU; MELVILLE, 1997), monitoramento do crescimento da cultura e predição da produtividade (LEE-LOVICK; KIRCHNER, 1991) e classificação da resposta espectral para diferenciação das variedades de cana-de-açúcar (GALVÃO; FORMAGGIO; TISOT, 2005).

Como alternativa ao aerolevantamento convencional, tem crescido o uso de câmaras digitais profissionais de pequeno e médio formato por serem, leves, de fácil manejo e custo reduzido. Apesar destas vantagens, nos levantamentos convencionais, normalmente, não é adquirida a banda

do infravermelho próximo. As câmaras digitais com essa característica não são comuns e seu custo é elevado comparado com câmaras digitais. Uma alternativa é adaptar as câmaras digitais eliminando o filtro interno responsável pelo bloqueio da região do infravermelho próximo e substituir por um filtro bloqueador da região do visível (RGB) (ROIG et al., 2013).

As câmeras digitais possuem um sensor imageador, que pode ser CCD (charge-coupled device) ou CMOS (complementary metal-oxide semiconductor), ambos têm uma sensibilidade espectral de cerca de 350nm a 1.100nm, a maioria das câmeras digitais usam o filtro de Bayer para obter as imagens somente na faixa do visível (RGB), este filtro pode ser removido permitindo a detecção de radiação infravermelha refletida pela vegetação (MILTON, 2002; LEBOURGEOIS et al., 2008). Para a discriminação e estudo de determinados alvos utilizando técnicas de Sensoriamento Remoto é imprescindível a utilização da banda do infravermelho próximo. Conforme Jensen (2009), a banda do infravermelho próximo é útil para a identificação da cultura e realça o contraste entre cultura/solo e terra/água.

Resultados satisfatórios obtidos com câmaras digitais convencionais com filtros adaptados, possibilitam realizar mapeamentos temático, delimitação das coberturas vegetais, delimitação de corpos d'água com uma alta resolução espacial quando comparada a resultados obtidos pelos sistemas orbitais (MAROTTA et al., 2015; ROIG et al., 2013). Outros estudos apresentam resultados no monitoramento de culturas, indicando que este sistema pode ser utilizado na agricultura para otimização da produção, bem como na tomada de decisão (PETACH et al., 2014). A grande vantagem de se utilizar uma câmera modificada é a possibilidade de serem acopladas em aeronaves remotamente pilotadas (RPA) e obter imagens a qualquer momento, com alta resolução espacial e temporal (HUNT et al., 2010; CANDIAGO et al., 2015; SANKARAN et al., 2015).

2.3. Aeronave Remotamente Pilotada (RPA) como plataforma de SR

O avanço tecnológico está introduzindo ao ambiente agrícola novas ferramentas que, até pouco tempo, não eram observadas no campo. Na agricultura, um dos novos instrumentos que têm ganhado espaço são as aeronaves remotamente pilotadas (RPAs), popularmente conhecida como "drones". Dentro deste contexto agrícola, as pequenas aeronaves são utilizadas para o embarque de sensores que, neste caso, trabalham coletando dados sobre o solo ou a planta e ou como um implemento para execução de algumas operações específicas de campo (COLOMINA; MOLINA, 2014). Quando aplicadas de maneira integrada com sensores, as RPAs operam com o objetivo de se obter informações úteis a respeito da cultura ou do solo e, neste caso, são consideradas uma plataforma aérea de Sensoriamento Remoto (COLOMINA; MOLINA, 2014; SANKARAN et al., 2015; SU; CHOU, 2015).

A principal vantagem de se utilizar o RPA como uma plataforma de coleta de dados é a flexibilidade, quando comparada a plataformas orbitais de Sensoriamento Remoto (imagens de satélites) (GÓMEZ-CANDÓN; DE CASTRO; LÓPEZ-GRANADOS, 2014). A flexibilidade na coleta de dados com RPA permite a obtenção de dados no campo no momento em que julgar apropriado e

quantas vezes for necessária, diferentemente dos dados obtidos com satélites, onde o tomador de decisão fica refém do momento em que o satélite irá sobrevoar a sua área (resolução temporal) para a coleta dos dados (BENDIG et al., 2013). Outro ponto a destacar é o alto nível de detalhes que os sensores embarcados nas pequenas aeronaves são capazes de coletar, visto que a altitude de voo é menor comparado aos sensores embarcados em um satélite ou aeronave tripulada. O sensoriamento utilizando um RPA pode ser considerado barato, prático e rápido comparado ao o que já vem sendo utilizado no campo (HOLMAN et al., 2016).

A maioria dos RPAs possuem um sistema de controle por rádio frequência que permite controlar a aeronave durante seu voo (HUANG et al., 2013), um sistema para o controle automático do voo que permite a realização do planejamento de voo e ainda, memória interna para armazenamento de dados como altura de voo, distância e coordenadas geográficas do percurso executado pela aeronave (TURNER; LUCIEER; WATSON, 2012; SANKARAN et al., 2015). Além da distinção entre componentes os RPAs podem possuir tamanho e formas diferentes, não existindo um modelo único adequado para todos os usos. Geralmente o modelo e tamanho do RPA é definido de acordo com a finalidade proposta (COLOMINA; MOLINA, 2014; SANKARAN et al., 2015).

As informações obtidas acerca do solo ou da planta está relacionada ao sensor que foi embarcado no RPA. A câmera fotográfica é um exemplo clássico de sensor imageador que, inclusive, é uma das opções possíveis de se embarcar em um RPA (BARETH et al., 2015b). Também recebem destaque e são uma possibilidade de sensores embarcados, os sensores multi e hiperespectrais, sensíveis à radiação eletromagnética em diferentes regiões do espectro eletromagnético (HONKAVAARA et al., 2013; AASEN et al., 2015), sensores termais, sensíveis à radiação eletromagnética na região do infravermelho termal (ZARCO-TEJADA; GONZÁLEZ-DUGO; BERNI, 2012) e os LIDARs, sensores que emitem um pulso laser em alta frequência para obtenção da distância entre o sensor e o alvo (LIN; HYYPPÄ; JAAKKOLA, 2011; TULLDAHL et al., 2015). Portanto, como cada sensor trabalha com estímulos e princípios de funcionamento diferentes, a escolha do sensor dependerá da informação que se deseja obter do solo ou da planta.

Hoje, muitos sensores leves estão disponíveis para uso em pequenos sistemas RPA para várias aplicações de monitoramento de culturas. Os sistemas de sensores variam de amadores, com baixo custo, a sensores profissionais, projetados especialmente para uso em RPAs, sendo o peso e o custo os principais fatores limitantes para o uso de um sensor em uma aeronave remotamente pilotada (BARETH et al., 2015a).

2.4. Uso de aeronaves remotamente pilotadas (RPAs) para obtenção de dados agrícolas

Nos últimos anos, tem crescido o número de estudos utilizando RPAs para diversas aplicações na agricultura, estudos internacionais destacam diversas aplicações, entre elas, identificar o tempo de colheita de uvas para vinho (JOHNSON; HERWITZ, 2003) e monitoramento da maturação do café (HERWITZ et al., 2004). Trabalhos mais recentes apontam potencial uso para estimar altura

do dossel de árvores de oliveira (DÍAZ-VARELA et al., 2015), monitorar o crescimento da cultura do arroz e cevada (BENDIG et al., 2013; BARETH et al., 2015a), variabilidade do status de água em vinhedos (SANTESTEBAN et al., 2017), e estimativa de produção de biomassa em plantações de milho (LI et al., 2016). Para Bendig et al. (2015) a coleta de dados com RPAs preenche um hiato na escala observacional em sensoriamento remoto, fornecendo dados de alta resolução espacial e temporal que são necessários no monitoramento do crescimento das culturas. Além disso, para estes autores o monitoramento do crescimento da cultura faz parte da agricultura de precisão e facilita a detecção e quantificação da variabilidade dentro do campo para apoiar decisões de gestão agrícola.

As informações que vão desde a preparação do terreno para o plantio até o monitoramento e a avaliação de variabilidade do rendimento da cultura são de extrema importância para os sistemas de cultivo. Assim, ao utilizar o sensoriamento remoto baseado em RPA, Rokhmana, (2015) destacou o atendimento de algumas características para adequada aquisição das informações, tais como: custo, facilidade de operação, boa repetibilidade e alta resolução das imagens.

A obtenção de informação para o uso na agricultura tem se intensificado nos últimos anos. Muitos trabalhos utilizaram câmeras com sensibilidade na região espectral do visível (RGB) como principal sensor imageador para avaliação de culturas (CRIMMINS; CRIMMINS, 2008; BARETH et al., 2015b; POSSOCH et al., 2015; SANKARAN et al., 2015). Torres-Sánchez, López-Granados e Peña, (2015) avaliaram um método automático de detecção e classificação de três culturas (milho, girassol e trigo) no estágio inicial, com a utilização de duas câmeras uma RGB e a outra multiespectral embarcadas em um RPA. Já Lelong et al. (2008) ao avaliar o uso de câmeras com diferentes filtros embarcadas em um RPA encontraram resultados promissores na estimativa de parâmetros biofísicos da cultura do trigo. Jorge, Brandão e Inamasu (2014) destacam o uso de câmeras RGB para a contagem de plantas e determinação das linhas de plantio. Júnior et al. (2015) utilizaram imagens RGB na estimativa da fração coberta de solo em canavial. Encontram-se também trabalhos desenvolvidos para o monitoramento de pastagem (BARETH et al., 2015b), bem como na contagem de árvores na área florestal (MARTELLO et al., 2015).

Imagens RGB, com alta resolução, também podem ser utilizadas para obtenção de modelos tridimensionais capazes de extrair informações passíveis de quantificar a altura da cultura. Díaz-Varela et al. (2015) utilizando um RPA e uma câmara IVP modificada na cultura da oliveira, testaram diferentes alturas de voo para avaliar a resolução das imagens e a precisão dos modelos 3D gerados para obtenção da altura do dossel das oliveiras. O estudo salientou que o método é uma abordagem barata e pode fornecer precisões comparáveis àquelas já consagradas através dos sensores LiDAR, por exemplo. Wallace et al. (2016) realizaram a comparação entre os dados de sensor LiDAR e a modelagem 3D obtida pelas imagens RGB em um povoamento florestal na Austrália. O mesmo concluiu que apesar do sensor LiDAR fornecer estimativas mais precisas da estrutura vertical das florestas, a técnica utilizando imagens obtidas por RPA para o geração de modelo tridimensional foi considerada uma alternativa adequada e de baixo custo para levantamentos florestais.

Alguns trabalhos avaliaram a obtenção de dados da altura do dossel da cultura, entre eles, Li et al. (2016) avaliaram a cultura do milho considerando altura do dossel e sua biomassa. Os autores verificaram que os parâmetros estimados eram comparáveis às medições de campo com um

erro médio (ME) de 0,11 m para altura do dossel e 0,05 kg⁻¹.m² para a produtividade. Semelhante aos trabalhos que foram desenvolvidos para obter a variabilidade do crescimento das culturas de arroz e cevada (BENDIG et al., 2013, 2015).

Ristoro et al. (2015) avaliaram o desempenho e custos da utilização de RPA em campos de arroz utilizando dois diferentes tipos de sensores comerciais, sendo um deles sensor ativo para avaliação das culturas e o outro um sensor scanner hiperespectral.

Algumas outras aplicações também já foram apresentadas na literatura, como por exemplo a utilização de imagens termais obtidas através de RPA para estimar a variabilidade sazonal do status de água em parreiras (SANTESTEBAN et al., 2017). A utilização de câmeras hiperespectrais e térmicas embarcadas em RPA juntamente com medidas a campo da fluorescência, permitiram detectar focos de stress hídrico em pomares de citrus em Sevilha na Espanha (ZARCO-TEJADA; GONZÁLEZ-DUGO; BERNI, 2012). Outra utilização de imagens térmicas e hiperspectrais foram apresentadas por Madrid et al. (2014) que, através das imagens obtidas pelo RPA, buscaram identificar a presença de fungos que causam danos severos nas culturas da oliveira e da papoula. Quemada, Gabriel e Zarco-Tejada (2014) utilizaram imagens térmicas e hiperespectrais para estimativa do nível de nitrogênio na cultura do milho, juntamente com dados coletados a campo, destacando a confiabilidade dos dados obtidos pelas imagens aéreas.

No Brasil, os trabalhos publicados utilizando RPA ainda são incipientes, a maior parte das publicações diz respeito ao georreferenciamento e acurácia de mosaicos gerados com imagens obtidas por RPA (MEDEIROS et al., 2008; PERIN et al., 2016; SILVA et al., 2016). De forma mais limitada, alguns trabalhos foram recentemente publicados com foco voltado na utilização de RPA para a cana-de-açúcar, como o trabalho desenvolvido por Barbosa et al. (2015) que buscou identificar as áreas que apresentaram falhas de plantio na cana-de-açúcar, e trabalhos envolvendo a estimativa da altura da cana-de-açúcar baseada na modelagem tridimensional (MARTELLO et al., 2016; DE SOUZA et al., 2017).

2.5. Modelos digitais da superfície e do terreno

Na literatura existem várias terminologias referindo-se aos modelos digitais que representam a superfície terrestre, sua topografia ou ainda, outras variáveis cuja representação no espaço necessite de uma forma de expressão contínua. Giasson et al. (2013), por exemplo, utilizaram a terminologia de modelo digital de elevação (MDE) para mapeamento digital de solos, já Oliveira e Tommaselli (2014) utilizaram a terminologia MDS para modelo digital da superfície, e Silva et al. (2016) utilizaram a terminologia MDT para se referir ao modelo digital do terreno.

Neste caso, é importante fazer a diferenciação entre os termos a serem adotados. Para o presente trabalho o termo MDT (Modelo Digital de Terreno) refere-se a uma representação tridimensional digital da superfície topográfica. Já o termo MDS (Modelo Digital de Superfície), faz referência à representação que compreende pontos da superfície acima do MDT, tais como feições antrópicas (edificações, rodovias, etc) e vegetação, por exemplo (MENDONÇA JÚNIOR; MITISHITA, 2011; OLIVEIRA; TOMMASELLI, 2014).

Os MDSs e MDTs são essenciais para várias aplicações, avaliação de impactos ambientais, planejamento urbano e rural, análise de aptidão agrícola, políticas públicas para projetos de infraestrutura, geração de ortoimagens e como fonte de dados para Sistemas de Informações Geográficas (SIG) (CHAGAS et al., 2010; PACHECO et al., 2011).

Para geração dos modelos é necessário um conjunto de pontos que representem a variabilidade espacial do fenômeno de interesse. Quando o objetivo é a representação das feições topográficas do terreno as fontes mais comuns de amostras são cartas topográficas (CHAGAS et al., 2010) com a extração de isolinhas (curvas de nível) (WISE, 2000) e pontos notáveis geralmente obtidos com receptores GNSS (Sistema de Navegação Global por Satélites) (GERSTENECKER et al., 2005) e a utilização de imagens aéreas que permitem através de técnicas da fotogrametria a obtenção de modelos tridimensionais (OLIVEIRA; TOMMASELLI, 2014). Dados obtidos por sensores ativos, como radares, também são utilizados para a representação do terreno (GIASSON et al., 2013; SOUZA JUNIOR et al., 2014). Quando a busca é por modelos com alta precisão e resolução espacial a utilização de sensores LiDAR (da sigla inglesa Light Detection And Ranging) é uma das soluções (PACHECO et al., 2011).

Recentemente, a geração de modelos tridimensionais do terreno através do processamento de imagens bidimensionais capturadas por câmeras embarcadas nos RPAs e processadas em softwares específicos também tem sido utilizadas. Neste caso, o processamento é realizado através da técnica SFM (da sigla inglesa Structure From Motion), que identifica nas imagens pontos característicos, ou seja, semelhanças geométricas como bordas de objetos ou outros detalhes específicos e permite reconstituir a cena em três dimensões, fornecendo um fluxo de trabalho simples em comparação as técnicas da fotogrametria convencional (TURNER; LUCIEER; WATSON, 2012; VERHOEVEN, 2012).

Devido à alta resolução espacial e às altas taxas de recobrimento das imagens obtidas pelos RPAs, vários trabalhos vêm utilizando a técnica para obtenção de modelos tridimensionais para os mais variados usos, desde o monitoramento dos movimentos das geleiras (IMMERZEEL et al., 2014; RYAN et al., 2015) até no uso agrícola como ferramenta para modelagem da altura e dinâmica do crescimento das culturas (BENDIG et al., 2013).

2.6. Modelagem da altura da cultura

Na modelagem da cultura, a altura da planta é definida como a distância vertical desde a origem do modelo (MDT) até o ponto mais alto (MDS) (LATI; FILIN; EIZENBERG, 2013), ou seja para um talhão de plantas a altura será igual à diferença entre a superfície do terreno e o topo do dossel (BENDIG; BOLTEN; BARETH, 2013).

A mensuração da altura pode ser obtida por métodos não-destrutivos que incluem a medição de altura de forma indireta através de trenas a laser (EHLERT; HORN; ADAMEK, 2008; EHLERT; ADAMEK; HORN, 2009), sensores ultra-sônicos (SCOTFORD; MILLER, 2004) e cortinas de luz (MONTES et al., 2011). Todos os sensores e dispositivos acima mencionados são usualmente

montados em tratores, assim as medições abrangem as áreas próximas aos corredores onde o trator irá passar, resultando numa cobertura espacial limitada. A cobertura espacial aumenta quando a altura é derivada de nuvens de pontos 3D coletadas pelos sensores LiDAR (*Light Detection and Ranging*). Tais sensores são equipamentos que emitem pulsos laser com alta frequência em direção ao alvo. O tempo decorrido entre emissão e detecção ao ser refletido é utilizado para calcular a distância do sensor até o alvo (GORGENS; SILVA; RODRIGUEZ, 2014). Essa tecnologia se disseminou para aplicações industriais e recentemente tem sido avaliada para agricultura (SHI et al., 2013, 2014; GARRIDO et al., 2015).

Na aplicação da tecnologia LiDAR, quando os dados são obtidos a partir de uma perspectiva distante e acima do solo, é comumente chamado de *Airbone Laser Scanning* – Escaneamento Laser Aeroembarcado (ALS), já para os dados coletados a uma pequena distância do solo, acoplado a uma máquina por exemplo, é comum referenciar a esse nível como *Terrestrial Laser Scanning* – Escaneamento Laser Terrestre (TLS) (GORGENS; SILVA; RODRIGUEZ, 2014).

A grande maioria das publicações científicas que utilizam o LiDAR na agricultura são de nível terrestre (TLS). Nestes trabalhos se destacam aplicações para estimativa da produtividade (EHLERT; HORN; ADAMEK, 2008), e estudo da variabilidade e espaçamento entre plantas (DWORAK; SELBECK; EHLERT, 2011; BUSEMEYER et al., 2013; SHI et al., 2013, 2014; GARRIDO et al., 2015; HOFFMEISTER et al., 2015) e estimativa da altura da cultura (CANATA et al., 2016).

Outra maneira de obter tais nuvens de pontos 3D é usando imagens com sensibilidade na região do espectro visível (RGB) e imagens com sensibilidade na região do espectro do infravermelho próximo (IVP) obtidas através dos RPAs (ROSNELL; HONKAVAARA, 2012; BENDIG et al., 2013).

As nuvens de pontos são utilizadas para fornecer modelos da altura da cultura (MAC), que no inglês é conhecido pela sigla CSM (Crop Surface Model), introduzido pela primeira vez por Hoffmeister et al. (2010). Por definição, o MAC representa o topo do dossel da planta em determinado momento (BENDIG et al., 2013). Os MACs são georreferenciados com precisão e a sua resolução normalmente varia de 1 m a 0,01 m. Em um MAC, a altura é o resultado da superfície do dossel (MDS) em um determinado ponto, menos a superfície do solo (MDT). Os produtos do MAC incluem mapas de altura que permitem a detecção da variabilidade espacial (TILLY et al., 2014).

3. MATERIAL E MÉTODOS

3.1. Área de estudo

A área experimental foi definida pela equipe do Instituto Agrônomo de Campinas (IAC), como parte do projeto temático BIOEN/FAPESP nº2008/56147-1 e localizada próximo as coordenadas geográficas 22°41'02" de latitude sul e 47°38'44" de longitude oeste, no Polo Regional Centro Sul da Agência Paulista de Tecnologia dos Agronegócios (APTA) em Piracicaba. Este estudo também foi conduzido em conjunto com o Projeto FAPESP nº 2013/22435-9.

O experimento foi avaliado ao longo da safra 2014/2015 com cana-de-açúcar de segundo corte (primeira soca) variedade IACSP95-5000. A área com aproximadamente 0,5 ha foi implantada em 2013 e instalada com delineamento experimental de blocos aleatorizados (Figura 1a).

A área possuía 28 parcelas experimentais com diferentes tratamentos. Os tratamentos consistiram em quatro diferentes níveis de adubação (0, 60, 120 e 180 kg ha⁻¹), sendo que os tratamentos com 60, 120 e 180 kg ha⁻¹ apresentavam oito repetições, com exceção do tratamento controle (0 kg ha⁻¹) que apresentou quatro repetições. (Figura 1a).

Figura 1. (a) Delineamento da área de estudo. (b) Marcação das linhas e subamostras em cada parcela.

3.2. Delimitação do experimento

Cada parcela experimental foi composta por cinco linhas de cana, com 15 metros de comprimento. Para realizar a medição da biometria (altura) em campo foram definidas cinco touceiras de cana dentro de cada parcela. Esta etapa foi adotada para que a medição fosse realizada sempre no mesmo local no decorrer de toda a coleta de dados. Assim, cada touceira consistiu em uma subamostra da parcela (Figura 1b) totalizando 140 subamostras.

Para a marcação das subamostras foi realizado um levantamento topográfico utilizando uma estação total com precisão angular de 3" e linear de 1,5mm+2ppm. A orientação da estação foi realizada através de cinco pontos conhecidos utilizando cinco receptores GNSS (Global Navigation Satellite System – Sistema Global de Navegação por Satélite), com precisão de posicionamento de

0,5 cm + 1 ppm para distâncias de até 20 km no método estático de posicionamento. Esses pontos também serviram como referência para o georreferenciamento das imagens (Figura 2).

Figura 2. (a) Estação total estacionada sobre o vértice utilizado para as irradiações das subamostras. (b) Receptor GNSS estacionado sobre um dos vértices utilizados como ponto de referência das imagens no presente trabalho.

Para solucionar as ambiguidades como fixa, foi realizado rastreo em cada um dos cinco pontos por uma hora. Os pontos foram pós-processados com o auxílio do software GTR Processor versão 2.94. Utilizou-se como ponto base os dados obtidos através da Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS (RBMC), que possui a estação SPPI, na estação meteorológica da USP/ESALQ, Piracicaba, distante aproximadamente 3.000 metros da área de estudo.

Com os pontos pós processados, realizou-se a irradiação com a estação total para todos os 140 pontos (subamostras) que foram implantados na área de estudo. Com as subamostras definidas, procedeu-se a marcação com fita zebra em um dos colmos de cada touceira escolhida. Quando necessário, as mesmas foram remarcadas (Figura 3).

Figura 3. (a) Detalhe para a marcação das touceiras que serviram de subamostras. (b) Marcação inicial das subamostras com fita zebra, as marcações eram refeitas de acordo com a necessidade e durante todo o ciclo produtivo.

3.3. Equipamentos utilizados para coleta de dados

A coleta de dados deu-se com a realização da biometria e coleta das imagens aéreas. Para a coleta de dados da altura em solo foi utilizada uma régua topográfica telescópica, feita de alumínio e escala máxima para medição de quatro metros. Juntamente com a régua foram utilizadas planilhas específicas para anotação das alturas observadas.

Para obtenção das imagens aéreas, foi utilizado um conjunto de equipamentos composto por uma aeronave remotamente pilotada (RPA) e estação de controle.

3.3.1. Descrição do RPA utilizado

Neste trabalho, foi utilizado uma plataforma denominada multirotor, composta por seis rotores distanciados entre si. O multirotor tem capacidade de realizar decolagem e pouso de forma vertical, não necessitando de pista para tais funções.

O sistema propulsor foi composto por seis motores elétricos com capacidade máxima de carga 0,8 kg e um tempo de voo de aproximadamente 10 minutos. A aeronave contava com um sistema eletrônico para o controle do voo, composto pelos mais diversos sensores, giroscópio, acelerômetro, barômetro e receptor GNSS (Figura 4a), que graças ao sistema de piloto automático embarcado possibilitava efetuar rotas pré-definidas.

3.3.2. Estação de controle

A estação de controle no solo, além de executar o planejamento do voo, também permitia acompanhar o voo em tempo real (Figura 4b).

Figura 4. (a) Plataforma em voo; (b) Estação de controle.

A estação de controle possuía um sistema de telemetria que possibilitava operação em duas frequências de 433 MHz e de 2,4 GHz para que, em caso de falhas, fosse possível realizar

alternância entre elas. O acompanhamento do voo em solo foi sempre efetuado mantendo-se contato visual com a aeronave.

O software utilizado na estação de controle foi Mission Planner, software de código livre e com vários recursos disponíveis, tanto para o controle da aeronave como para o planejamento da missão.

Foram utilizados cinco pontos de referência posicional para as coletas aéreas (Figura 5). Nesses pontos foram colocados alvos antes de cada voo (Figura 5). Os alvos tinham como função primordial auxiliar no posicionamento dos modelos que foram gerados em seguida, bem como facilitar o alinhamento dos conjuntos de imagens coloridas (RGB) e infravermelho próximo (IVP). Esses alvos possuíam uma área de 0,25 m² com multicores e foram confeccionados com material emborrachado para evitar reflexo da luz solar.

Figura 5. Posicionamento dos pontos de referência e detalhe do alvo utilizado durante as coletas.

3.4. Obtenção das imagens aéreas

Para atender ao objetivo de utilizar sensores de baixo custo, a obtenção das imagens foi realizada por duas câmeras digitais não-métricas distintas. Uma das câmeras possuía resolução espectral na faixa do visível (350~700nm – RGB) com um sensor CMOS (Complementary Metal Oxide Semiconductor) e tamanho de 1/2,3" (6,17 x 4,55 mm) gerando imagens de até 12 megapixels, equipada com um temporizador interno que possibilitou a sua programação para realizar coletas de imagens em um intervalo de tempo pré-programado pelo usuário e dimensões de até 4000 pixels de largura por 3000 pixels de altura.

A outra câmera utilizada foi modificada com a substituição do filtro RGB Bayer pela inserção de um filtro capaz de bloquear a entrada de REM na faixa de 530 a 700 nm, permitindo a captura de imagens da faixa de 700 a 1100nm (IVP) (Figura 6a). O filtro foi analisado com o auxílio de um espectroradiômetro FieldSpec Pro 3 acoplado a esfera integradora para validar sua eficiência. Este filtro bloqueou a REM da faixa de 500 a 700 nm em mais de 90% (Figura 6b).

A câmera modificada (IVP) possuía um sensor CMOS (Complementary Metal Oxide Semiconductor) com tamanho de 1/3" (4,88 x 3,60 mm) possibilitando obter imagens com até 5 megapixels com dimensões de até 2304 pixels de largura por 1536 pixels de altura.

Figura 6. (a) Exemplificação da modificação da câmera; (b) Comportamento espectral do filtro utilizado.

As duas câmeras foram fixadas no RPA com o auxílio de um suporte desenvolvido especialmente para o trabalho (Figura 4a), com a finalidade de que as duas câmeras ficassem o mais próximo possível uma da outra, facilitando o alinhamento do conjunto de imagens. O suporte também possuía uma regulação para atenuar o efeito da inclinação que o RPA apresentava durante o voo, permitindo obter imagens o mais verticais possíveis.

3.4.1. Plano de voo

Antes de iniciar a aquisição dos dados, foi definido um plano de voo para ser utilizado em todas as coletas no decorrer do andamento da pesquisa. O plano de voo foi planejado para que houvesse um recobrimento lateral e longitudinal com alta densidade de imagens e permitisse realizar a modelagem da altura da cultura (MAC). Como cada câmera possuía um temporizador interno para efetuar os disparos. Foi programado um disparo a cada dois segundos, possibilitando um recobrimento tanto lateral como longitudinal de mais de 90% entre as imagens. Cada linha de voo possuía aproximadamente 153 metros de comprimento com uma distância entre linhas de 14,5 metros (Figura 7).

Os voos foram executados à altura de 40 metros do nível do solo, esta altura foi escolhida em função da resolução espacial e consequente detalhamento necessário para a modelagem da cultura. Como a área de estudo foi de 0,5 ha, os voos foram executados mantendo-se sempre a linha de visada entre o piloto e aeronave. A distância máxima entre a aeronave e a estação de solo não ultrapassou 200 metros.

Figura 7. Plano de voo utilizado para coleta das imagens aéreas.

3.5. Aquisição de dados

A coleta das imagens (IVP e RGB) iniciou no mês de dezembro de 2014, aos 67 dias após o corte (DAC), e se estendeu até o mês de outubro de 2015, totalizando nove coletas de campo (Tabela 1). Em cada coleta foram obtidas em torno de 94 imagens que em seguida foram processadas para a geração do Modelo da Altura da Cultura (MAC) da área de estudo.

Tabela 1. Obtenção das imagens áreas (coletas) com respectivos horários, dias, meses e dias após o corte da cultura (DAC)

Coletas	Horário	Dia	Mês	DAC
C1	13:40	16	Dezembro	67
C2	12:40	17	Janeiro	99
C3	14:40	03	Março	144
C4	10:50	23	Março	164
C5	11:30	28	Abril	200
C6	14:30	26	Maio	228
C7	12:00	6	Julho	269
C8	12:00	1	Setembro	326
C9	13:15	19	Outubro	*

Nota: * coleta após o corte da cultura.

Paralelamente às coletas das imagens aéreas foram realizadas as coletadas de dados no campo. Essas coletas consistiram em medições manuais da altura das cinco plantas marcadas, com o auxílio de régua topográfica, considerando o colmo de maior altura e tomando a medida do solo até o ápice da folha-bandeira, totalizando assim 140 amostras de altura (Figura 8).

Figura 8. (a) Medição da altura em estágio inicial. (b) Medição da altura em estágio final.

A produtividade final de cada parcela foi obtida após a colheita manual, sem queima, pesando-se os feixes de cada parcela com o auxílio de uma célula de carga instalada em uma carregadora de cana (Figura 9).

Figura 9. Pesagem para produtividade das parcelas, utilizando célula de carga na carregadora.

3.6. Processamento dos dados

Todos os dados de altura de campo foram organizados em Tabelas no software Microsoft Excel para realização das análises. Ambas as imagens, RGB e IVP passaram por um fluxo de processamento idêntico que será descrito a seguir.

3.6.1. Georreferenciamento das imagens

Após a coleta, as imagens foram georreferenciadas no software Mission Planner (Ardupilot Dev Team), pois as câmeras utilizadas no presente trabalho não possuíam integração direta com a controladora do RPA. Para efetuar o georreferenciamento o registro do voo foi sincronizado com o horário exato da captura da imagem.

3.6.2. Geração dos modelos digitais

Para geração dos modelos digitais, as imagens coletadas foram processadas no software Agisoft Photoscan (Agisoft LLC, São Peterburgo, Russia) que utiliza a técnica “structure from motion” (SFM) para reconstrução 3D da cena. O processamento das imagens para obtenção do modelo digital da superfície (MDS) e as ferramentas utilizadas em cada etapa são apresentados no fluxograma da Figura 10. Conforme é possível observar no fluxograma os passos do processamento

contemplaram o alinhamento das imagens. Neste passo as imagens foram processadas para a geração de uma nuvem de pontos homólogos presentes em cada imagem. O alinhamento definiu a posição exata de cada imagem em relação ao alvo. Em seguida realizou-se a triangulação (geração da malha) para determinação dos pontos de controle utilizados no georreferenciamento das imagens e na calibração da câmera, após a localização dos pontos de controle foi efetuada a calibração das imagens e em seguida realizou-se o processamento das imagens para obtenção da nuvem densa de pontos. Após a geração da nuvem densa de pontos, novamente foi gerada uma malha triangular sobre a área. No último passo, a malha triangular foi processada gerando o MDS e em seguida exportado em formato matricial (extensão de imagem “.TIF”).

Figura 10. Fluxograma do processamento para geração do MDS.

3.6.3. Geração do MDT Mensal

As imagens coletadas a partir da coleta C2 até a C8 foram processadas mensalmente para obtenção de um MDT para cada coleta realizada. O fluxo de processamento pode ser observado na Figura 11. A diferença entre o fluxograma apresentado na Figura 10 é a etapa de classificação da nuvem densa de pontos. Esta classificação da nuvem densa de pontos identificou os pontos que possuíam os valores mais baixos de altitude do MDS (GEIPEL; LINK; CLAUPEIN, 2014; DÍAZ-VARELA et al., 2015), e em seguida esses pontos foram triangulados obtendo o MDT mensal. Essa técnica possibilitou a extração da altura durante as diferentes fases de desenvolvimento, não sendo necessário um voo prévio ou posterior ao plantio e nem mesmo um levantamento topográfico. Esse método para obtenção do MDT foi frequentemente utilizado em outros trabalhos encontrados durante a revisão bibliográfica.

Figura 11. Fluxograma do processamento para geração do MDT.

3.6.4. MDT inicial e final

Utilizaram-se as imagens da cultura no início do seu ciclo para obtenção dos MDT inicial (RGB e IVP) conforme utilizado por Bendig; Bolten; Bareth (2013). Para geração do MDT final foram utilizadas as imagens obtidas após a colheita da cultura seguindo a metodologia apresentada por Holman et al. (2016).

3.6.5. MDT de referência obtido por levantamento planialtimétrico

O MDT de referência foi obtido a partir dos dados planialtimétricos, oriundos dos equipamentos topográficos conforme metodologia apresentada por Tonkin et al. (2014). Para que isso fosse possível as informações de cada ponto coletado e georreferenciado com a estação total foram exportadas para o software Qgis. Os pontos foram então interpolados, gerando assim o MDT de referência.

3.7. Análise dos dados

3.7.1. Avaliação dos MDTs

Para avaliar a influência do MDT sobre o resultado final do MAC, foram gerados seis MDTs distintos utilizando as imagens RGB e IVP, para tanto os MDTs foram organizados de acordo com a data de coleta sendo: dois MDTs iniciais (obtidos aos 67 DAC no início do ciclo produtivo), dois MDTs finais (obtidos após a colheita da cultura) e dois conjuntos de MDTs mensais (obtido mensalmente através da classificação da nuvem de pontos).

Os MDTs mensais foram obtidos para cada conjunto de dados RGB e IVP utilizando somente os pontos referentes ao nível do terreno em cada coleta (C2 a C8). O MDT utilizado como referência foi gerado a partir dos dados topográficos obtidos com a estação total e GPS L1 pós-processado e interpolados.

Para analisar os seis conjuntos de MDTs gerados, os mesmos foram comparados com o MDT de referência observando a diferença entre eles. Os valores extraídos para serem utilizados na análise foram obtidos nas mesmas posições dos 140 pontos amostrais que também foram utilizados para a coleta de dados da biometria. Na verificação utilizou-se a metodologia proposta por Clapuyt; Vanacker; Van Oost, (2016) que recomenda a regressão linear ao nível de 5% de significância ($p \leq 0,05$) entre os valores de cada MDT gerado e aqueles obtidos com os dados topográficos - MDT referência.

Também foi efetuada a análise da diferença entre cada $MDT_{(n)}$ com o MDT de referência, os resultados foram apresentados em gráficos de distribuição de frequência (histograma) e *bloxplot*. As análises estatísticas foram processadas com o software Microsoft Excel e o complemento ActionStat (EstatCamp, São Carlos, SP, Brasil).

O desempenho dos MDTs foram avaliados de acordo com o coeficiente de determinação (R^2) entre o valor MDT referência (predito) e $MDT_{(n)}$ (estimado) e a raiz quadrada do erro médio (RMSE) como ilustrado na Equação 1.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (1)$$

Sendo: $\hat{y}_i$ os valores estimados pelos MDTs propostos e y_i são os valores preditos pelo MDT referência. O RMSE mostra o erro do MDT e sua unidade de medida é a mesma das unidades das medidas originais.

3.7.2. Avaliação dos MDS

Afim de avaliar possíveis diferenças entre os modelos de superfície obtidos pelos dois sensores (RGB e IVP), os MDS foram separados de acordo com suas coletas e organizados no software QGIS (QGIS Development Team). Para extração dos valores de altitude de cada amostra, foram extraídos os valores de altitude de cada MDS utilizando-se as posições dos 140 pontos amostrais que também foram utilizados para a coleta de dados da biometria. Todos os valores de altitude foram exportados para o software Excel. Para a análise dos MDS foi utilizado o valor médio de altitude de cada parcela e correlacionados entre si.

Primeiramente foram apresentadas as diferenças entre os dois MDS, os resultados foram expressados por gráfico de *bloxplot* e Tabela com a estatística descritiva.

Após essa primeira análise os MDS foram submetidos a regressão linear para obtenção do coeficiente de determinação (R^2) e correlação linear de Pearson (r) visando identificar o grau de correlação entre os dois modelos, os resultados foram expressos em gráficos de dispersão. A análise foi realizada separadamente para cada coleta ($n=140$) e com todos os dados coletados ($n=980$).

3.7.3. Análise da relação entre modelo de altura da cultura e dados biométricos

Com o conjunto dos seis MDTs (2 iniciais 1 mensal e 2 finais) e os dois MDSs (RGB e IVP) de cada mês, foram calculados os Modelos de Altura da Cultura (MACs), o qual representa a altura da cultura no momento da coleta das imagens conforme proposto por Hoffmeister et al., (2015). Para o cálculo da altura da cultura foi utilizado a álgebra de mapas, representada pela Equação (2):

$$MAC_n = MDS_n - MDT_n \quad (2)$$

Sendo:

MAC_n – Modelo da Altura da Cultura no mês “n”;

MDS_n – Modelo Digital da Superfície no mês “n”;

MDT_n – Modelo Digital do Terreno gerado pelas diferentes técnicas “n”.

A avaliação da influência do MDT e dos MDS (RGB e IVP) sobre o MAC foi realizada através de 12 combinações geradas a partir de diferentes arranjos de MDT e MDS (Tabela 2).

Tabela 2. Combinações entre MDTs e MDSs.

Combinações	MDT	MDS
1	MDT Inicial RGB	RGB
2	MDT Inicial RGB	IVP
3	MDT Inicial IVP	RGB
4	MDT Inicial IVP	IVP
5	MDT Final RGB	RGB
6	MDT Final RGB	IVP
7	MDT Final IVP	RGB
8	MDT Final IVP	IVP
9	MDT Mensal	RGB
10	MDT Mensal	IVP
11	MDT Referência	RGB
12	MDT Referência	IVP

Após a determinação das combinações apresentadas na Tabela 2, realizou-se o processamento (equação 2) no software QGIS.

Para a extração dos resultados de altura dentro de cada parcela, foram definidas cinco subamostras com 0,65 m de diâmetro e área de 0,33 m² cada uma. As subamostras possuíam a mesma localização espacial das cinco plantas marcadas em cada parcela onde foram obtidas as coletas dos dados biométricos. Todos os valores de altitude foram exportados para o software Excel e organizados de acordo com a coleta e parcela.

Para a avaliação do MAC foram realizadas regressões lineares utilizando os valores médios das cinco subamostras, totalizando 28 amostras comparando-os com os valores das alturas reais obtidas em campo. Os dados foram separados por coleta (n=28) tendo sido realizada a correlação de Pearson ($p \leq 0,05$) entre os valores de altura estimados pelo MAC com os valores de altura medidos na biometria. A mesma análise foi executada para todo período com os dados das sete coletas (n=196).

O desempenho das 12 combinações foi avaliado para todo o período de coleta, de acordo com o coeficiente de correlação (r), o coeficiente de determinação (R²), o RMSE (Equação 1) e o erro relativo (RE) como ilustrado na Equação 3.

$$RE = \frac{100}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

Sendo: $\hat{y}_i$ os valores estimados pelos MACs propostos e y_i são os valores preditos pela biometria. RE mostra o erro do modelo em porcentagem em relação à média padrão.

3.7.4. Estimativa da produtividade utilizando dados de altura

Para verificar a relação entre a produtividade final com os dados obtidos de altura, os mesmos foram submetidos a análise de regressão linear, sendo avaliados pelo coeficiente de correlação de Pearson e coeficiente de determinação (R^2). Primeiramente analisaram-se os dados de campo (altura média das subamostras de cada parcela) com a produtividade final da parcela. Em seguida, a análise diferiu em relação a média das alturas de cada parcela que, neste caso, foram obtidas a partir das subamostras do MAC. E a terceira análise foi efetuada com os dados obtidos com o MAC, porém a altura média de cada parcela foi obtida a partir da amostragem em um polígono padrão com 10 metros de comprimento por 4,24 metros de largura, totalizando 42,48m² que estava locado no centro das amostras. Essa abordagem objetivou obter um valor médio de altura que compreendesse e considerasse a variabilidade de cada parcela, não limitando-as em subamostras.

3.7.5. Análise da variabilidade espacial

3.7.5.1. Mapeamento da variabilidade da altura

Para avaliar a variabilidade da altura que a cultura apresentou durante todo o seu ciclo os modelos (MACs) foram apresentados juntamente com os mosaicos RGB para cada coleta, com o intuito de observar a variabilidade presente nos dois conjuntos de dados.

Os MACs também foram apresentados de acordo com as doses de nitrogênio aplicadas no início do ciclo, essa abordagem permitiu observar visualmente o comportamento da altura em relação aos tratamentos.

Posteriormente com o mosaico RGB da coleta C2 (início do ciclo) foi calculado um índice de vegetação proposto por Bendig et al., (2015) onde utilizou-se as três bandas visíveis (RGB), esse índice facilita a identificação dos locais sem a presença de plantas (Equação 4) o que permite avaliar a relação entre áreas que apresentaram solo exposto ou palhada.

$$RGBVI = \frac{(G^2) - (R*B)}{(G^2) + (R*B)} \quad (4)$$

Sendo: R é a banda vermelha, G é a banda verde e B a banda azul.

Após o cálculo do índice RGBVI o mesmo foi reclassificado para separar a vegetação do solo exposto e palhada. Para este trabalho, valores superiores a 0,05 foram classificados como vegetação, já valores inferiores a 0,05 foram classificadas como áreas sem presença de vegetação (solo/palha). Após a classificação, as duas classes foram convertidas em camada vetorial a fim de delimitar as áreas que apresentam a ausência de fechamento de dossel dentro de cada parcela. Após a delimitação das áreas, os vetores foram sobrepostos sobre cada MAC facilitando a observação da variabilidade da altura em função das áreas com ausência do fechamento do dossel no início do ciclo produtivo. Todo o processamento foi desenvolvido com auxílio do software QGis e exemplificado na Figura 12.

Figura 12. Processamento de classificação das áreas com ausência do fechamento do dossel no mosaico RGB da coleta C2.

3.7.5.2. Mapeamento da variabilidade da produtividade

Para representar a variabilidade da predição da produtividade da área de estudo, foi utilizado o software Qgis para a geração do mapa de predição da produtividade. Para geração do mapa foi utilizado o modelo de regressão linear que apresentou o maior valor de RSME e menor valor de RE entre a altura e produtividade final. Esse modelo foi utilizado juntamente com o MAC do respectivo mês, assim foi gerado o mapa de predição da produtividade final da área de estudo.

Seguindo o mesmo princípio utilizado na avaliação da variabilidade da altura, os limites das áreas sem fechamento de dossel foram sobrepostos no mapa da predição da produtividade final, para verificar visualmente a ocorrência de relação entre a produtividade e as áreas que apresentaram falhas no fechamento do dossel no início do ciclo.

4. RESULTADOS E DISCUSSÃO

4.1. Análise dos MDTs

Os resultados e a discussão dos MDTs foram analisados separadamente de acordo com a forma de coleta de cada um, ou seja MDT inicial/final e MDT mensal. Primeiramente foi analisado a diferença entre o MDT de referência com os MDTs iniciais (RGB e IVP) que foram obtidos no início do ciclo (67 DAC) e os MDTs finais (RGB e IVP) obtidos após a colheita. Em seguida são apresentados os resultados do MDT mensal (RGB e IVP) que foram obtidos a cada mês.

4.1.1. MDT inicial e final

Com o objetivo de observar a diferença entre os MDTs obtidos no início do ciclo produtivo (MDT inicial) com os MDTs obtidos após a colheita da cultura (MDT final), os dados foram analisados separadamente em comparação ao MDT de referência. A Tabela 3 apresenta a estatística descritiva da diferença entre o MDT referência com os MDTs inicial e final em metros.

Ao observar os resultados apresentados na Tabela 3, é possível constatar que a maior diferença média entre o MDT de referência e os avaliados ocorreu no MDT final (RGB) devido a superestimação de 0,124 m. Este MDT apresentou o segundo maior valor de desvio padrão 0,118 em relação a média.

Ao analisar os MDTs em relação ao tipo de imagem RGB ou IVP, observa-se que os menores valores de desvio padrão ocorreram nos MDTs obtidos através das imagens RGB, já ao analisar todos os MDTs sem considerar a diferença em relação ao tempo da coleta (inicial e final) os menores desvios padrões foram nos MDTs inicial RGB e IVP. Embora o menor valor da diferença média foi observado no MDT final IVP, este MDT apresentou o maior valor de desvio padrão acarretando no maior intervalo de diferença entre todos os MDTs.

Tabela 3. Estatística descritiva da diferença entre o MDT de referência entre os MDTs iniciais e finais (RGB e IVP) em metros.

	Mínimo	Mediana	Média	Máximo	Desvio Padrão
MDT Inicial (RGB)	-0,134	0,035	0,033	0,162	0,053
MDT Inicial (IVP)	-0,307	-0,077	-0,088	0,090	0,095
MDT Final (RGB)	-0,089	0,098	0,124	0,512	0,118
MDT Final (IVP)	-0,449	-0,026	-0,003	0,513	0,205

Nos histogramas apresentados na Figura 13 pode-se observar a distribuição das diferenças entre os valores dos MDTs analisados com o MDT de referência. Comparando o MDT inicial RGB (Figura 13a) e o MDT final RGB (Figura 13b) podemos observar que o MDT inicial RGB apresentou uma menor distribuição das diferenças com o MDT de referência. Já o MDT final RGB apresentou

dispersão maior das diferenças, também é possível observar que a maioria das diferenças foram negativas indicando subestimação do MDT em questão.

A distribuição dos MDTs inicial e final IVP (Figura 13c e 13d) apresentaram um comportamento similar aos MDTs RGB porem com maiores dispersões das diferenças em relação ao MDT de referência, indicando o MDT inicial RGB como o melhor MDT entre os quatro analisados.

Figura 13. Histograma de frequência da diferença entre o MDT referência em relação aos MDTs iniciais e finais (RGB e IVP).

Para obter o RSME e o coeficiente de determinação (R^2) os valores numéricos obtidos nos MDTs (inicial, final) foram analisados através de regressões lineares. Todos MDTs apresentaram altos valores de R^2 , com baixo valor de RSME (Figura 14) semelhantes aos valores encontrados por Clapuyt, Vanacker e Van Oost, (2016). Porém é possível observar entre eles, que os MDTs iniciais foram os que apresentaram os maiores valores de R^2 (0,995 e 0,985) e os menores valores de RMSE (0,05m e 0,09m) quando comparados aos MDTs finais, o que pode indicar que a diferença de tempo (inicial e final) entre as coletas pode influenciar a obtenção do MDT.

Conforme a Figura 14 e confirmando os resultados da estatística descritiva, o MDT inicial (RGB) foi o que apresentou o melhor resultado em relação aos demais quando foi comparado a verdade de campo (MDT referência), obtendo o maior valor de coeficiente de determinação, 0,99 e o menor valor de RSME, 0,05m. O MDT inicial (IVP) foi o segundo melhor com um RSME de 0,09m, coincidentemente o mesmo valor de diferença observado por Clapuyt; Vanacker; Van Oost, (2016) ao testar duas lentes com comprimento focal diferente.

Figura 14. Regressão linear entre o MDT referência com os MDTs iniciais e finais (RGB e IVP).

Conforme foi observado na Tabela 3 e Figura 14, os MDTs apresentaram resultados diferentes em relação às imagens RGB e IVP. Considerando o tempo de coleta os MDTs obtidos com o conjunto RGB apresentaram qualidade superior ao conjunto IVP.

Essas diferenças observadas podem estar relacionadas ao filtro utilizado nas câmeras para obtenção das imagens como também aos comprimentos focais das lentes utilizadas em cada câmera.

Conforme observado por Clapuyt, Vanacker e Van Oost (2016) avaliando duas distâncias focais de lente (28mm e 50mm) para obtenção das imagens e geração de modelos de superfície de terreno existem diferenças nos resultados em relação ao comprimento focal das lentes. Uma diferença de precisão de 0.04 m no MDT foi observada por esses autores entre o conjunto de dados de cada lente.

Em relação ao tempo de coleta dos dados para geração do MDT final e inicial, os resultados evidenciam que embora exista a influência das câmeras, o tempo de coleta também apresenta influência. Outros autores também observaram a influência temporal sobre a geração do MDT. Holman et al. (2016) avaliando um método para determinar a taxa de crescimento do trigo a partir de imagens de alta resolução obtidas por RPA, destacaram que ao utilizar imagens obtidas após a colheita para obtenção do MDT a diferença de precisão do modelo pode ser inferior em função do impacto potencial da operação da colheita que acarreta mudanças no cenário. Os dados obtidos para geração do MDT de referência foram coletados no mesmo momento em que foi realizado a coleta das imagens para geração dos MDT's iniciais, já o intervalo de tempo entre os dados referência e a obtenção dos dados para MDT final foi de 10 meses. Além dos possíveis impactos da operação de colheita sobre a topografia do terreno, o intervalo de tempo decorrido também pode ter ocasionado pequenas alterações no terreno, como por exemplo, o crescimento da vegetação circundante.

Turner; Lucieer; Watson, (2012); Harwin; Lucieer; Osborn, (2015); Clapuyt; Vanacker; Van Oost, (2016) e Holman et al., (2016) destacaram a importância da qualidade dos componentes da imagem, como estabilização e autofocus, além é claro da localização e da quantidade de pontos de controle. Turner; Lucieer e Watson, (2012) verificaram que utilizando-se pontos de controle a precisão posicional do modelo aumenta. Ao comparar a geração de MDT de forma direta sem utilizar pontos de controle, estes autores observaram precisão espacial absoluta de 65-120 cm enquanto que utilizando pontos de controle obtiveram uma precisão de aproximadamente 10-15 cm. Os pontos de controle utilizados nesse trabalho estão de acordo com as recomendações de Clapuyt; Vanacker; Van Oost, (2016).

Em relação aos resultados de RSME para o MDT inicial e final (Figura 14), o menor valor foi encontrado no MDT inicial RGB, 0,0503 seguido do MDT inicial IVP, 0,0916. O pior resultado foi do MDT final IVP, 0.1794. Estes valores foram inferiores aos encontrados por Clapuyt; Vanacker; Van Oost, (2016), que observou RSME entre 0,27 a 0,45 metros, quando avaliou a eficiência da modelagem através das imagens obtidas por RPA, comparando-as com dados LIDAR (Laser Scanner). Já Tonkin et al., (2014) avaliando a potencialidade da modelagem digital do terreno com imagens obtidas por RPA obtiveram valores de RMSE 0,52 metros validados por dados obtidos com estação total.

4.1.2. MDT Mensal RGB e IVP

O MDT mensal foi obtido para cada coleta e para cada conjunto de imagens RGB e IVP. Avaliação do MDT mensal possibilitou verificar o nível de detalhes que foi possível obter do MDT utilizando a classificação da nuvem densa de pontos, visto que ao utilizar este método não há dependência de coletar dados no início ou final do ciclo. Para avaliar os MDTs mensais, os dados também foram comparados ao MDT de referência e são apresentados a seguir.

A Tabela 4 apresenta a estatística descritiva da diferença entre o MDT referência com todos MDTs Mensais RGB, sendo que na Tabela 5 temos as diferenças do MDT referência com os MDTs mensais IVP.

Observando os resultados apresentados na Tabela 4, percebe-se que as coletas C2, C3 e C6 foram as que apresentaram o menor desvio padrão e C3 e C6 apresentaram também os menores valores de diferença média.

Tabela 4. Estatística descritiva da diferença entre o MDT de referência com o MDT mensal (RGB) em metros.

MDT 5 (RGB)	Mínimo	Mediana	Média	Máximo	Desvio Padrão
C2	-0,055	0,251	0,227	0,469	0,115
C3	-0,219	-0,047	-0,042	0,129	0,071
C4	-0,347	-0,053	-0,065	0,253	0,135
C5	-0,463	-0,187	-0,183	0,050	0,131
C6	-0,223	-0,053	-0,059	0,118	0,079
C7	-0,523	-0,198	-0,215	0,050	0,160
C8	-0,702	-0,238	-0,274	0,168	0,195

Os resultados obtidos para o MDT Mensal IVP apresentaram semelhança com os resultados obtidos utilizando as imagens RGB. As coletas C3, C4 e C6 apresentaram menor desvio padrão em relação as demais (Tabela 5). A diferença média também foi menor nas coletas C4 e C6.

O maior desvio padrão observado foi para a coleta C8 que apresentou a segunda maior diferença média observada. Essa foi a última coleta antes da colheita da cultura, aproximadamente 300 dias após a coleta do MDT de referência. Um fator que pode ter influenciado este resultado, é a diferença entre o tempo de coleta do MDT em questão com o MDT de referência, conforme foi discutido anteriormente para o MDT inicial e final.

Tabela 5. Estatística descritiva da diferença entre o MDT de referência com o MDT mensal (IVP) em metros.

MDT 5 (IVP)	Mínimo	Mediana	Média	Máximo	Desvio Padrão
C2	-0,171	0,050	0,051	0,405	0,118
C3	-0,130	0,036	0,047	0,276	0,076
C4	-0,220	-0,015	-0,006	0,363	0,097
C5	-0,448	-0,218	-0,228	0,065	0,102
C6	-0,163	-0,015	-0,016	0,177	0,067
C7	-0,213	0,040	0,049	0,379	0,132
C8	-0,318	0,081	0,067	0,483	0,163

Na Figura 15, são apresentados os dados dos MDT Mensal RGB em gráfico *boxplot*. Neste gráfico é possível observar de forma mais clara a dispersão dos dados na coleta C8 assim como, o maior desvio padrão. Percebe-se também que os resultados obtidos na coleta C2 apresentaram valores de superestimação.

Figura 15. Gráfico bloxplot da diferença entre o MDT de referência em relação ao MDT mensal - RGB

Já para o MDT Mensal IVP, os resultados apresentados no gráfico de *bloxplot* (Figura 16) ressaltam a homogeneidade das diferenças médias, diferenciando apenas a coleta C5 que apresentou subestimação.

Figura 16. Gráfico bloxplot da diferença entre o MDT de referência em relação ao MDT mensal - IVP

Analisando o resultado da classificação dos pontos para geração do MDT mensal - C2 que é apresentado na Figura 17, é possível observar que alguns pontos foram classificados como terreno dentro das parcelas de estudo. Essa classificação pode ter superestimado o MDT em questão. Como a classificação dos pontos do terreno é feita de forma automática, possivelmente os pontos selecionados erroneamente foram classificados devido a utilização de valores padrões para todas as classificações, prejudicando assim a interpolação do MDT mensal da coleta C2.

Figura 17. Classificação da nuvem densa de pontos para a coleta C2 RGB, detalhe nos pontos marrons utilizados para a geração do MDT-Mensal-C2-RGB.

Diferentemente do MDT mensal C2 RGB em que se observou superestimação, o MDT mensal C5 IVP apresentou subestimação. Esse comportamento pode ser observado na Figura 18, onde percebe-se que a baixa quantidade de pontos classificados próximo aos talhões prejudicou a interpolação para obtenção do MDT mensal C5 IVP.

Figura 18. Classificação da nuvem densa de pontos para a coleta C5 IVP, detalhe nos pontos marrons utilizados para a geração do MDT mensal-C5-IVP.

Para melhor visualização da distribuição das diferenças médias e desvio padrão, na Figura 19 e 20 são apresentados os histogramas dos MDTs RGB e IVP.

Figura 19. Histograma de frequência da diferença entre o MDT de referência em relação ao MDT mensal RGB.

Através dos histogramas percebe-se que a coleta C8 apresentou o maior valor de desvio padrão em relação as demais coletas em ambos os MDTs IVP e RGB. Pelo gráfico de histograma é possível observar a subestimação na coleta C5 (Figura 19d). Já as coletas C2, C3, C7 e C8 apresentam um comportamento de superestimação, visto que as maiores frequências das diferenças encontram-se acima de 0,0 metros (Figura 19 a,b,f,g).

Figura 20. Histograma de frequência da diferença entre o MDT referência em relação ao MDT Mensal IVP.

Também é possível observar na Figura 20b a subestimação na coleta C5 tanto para o RGB como para o IVP. Embora a coleta C2 tenha apresentado superestimação em ambos os MDT (RGB e IVP) a distribuição de frequência dos valores foi diferente.

As regressões lineares, assim como os valores de RSME, aplicados para o conjunto do MDT Mensal RGB são apresentadas na Figura 21. Os resultados foram significativos para todos os MDTs mensais. A coleta C3 (Figura 21b) apresentou o maior coeficiente de regressão $R^2 = 0,9916$, seguida pela coleta C6 (Figura 21e) com $R^2 = 0,9909$, e os menores valores de RSME 0,0689 e 0,0695 respectivamente. Os valores mais baixos R^2 0,9592, 0,9516 e maior RSME 0,1591, 0,1857 foram encontrados respectivamente nas duas últimas coletas C7 e C8 (Figura 21f,g) confirmando os resultados observados na estatística descritiva.

Figura 21. Regressão linear entre o MDT referência com o MDT Mensal – RGB em metros

Os resultados das regressões lineares para o MDT Mensal IVP são apresentados na Figura 22. Comparando-se as correlações obtidas para os MDTs RGB e IVP, observa-se que os resultados são muito próximos tanto em relação ao melhor modelo C6 e C4 quanto aos seus valores de RMSE. Para o MDT Mensal IVP, a coleta C6 (Figura 22e) apresentou o maior coeficiente de regressão $R^2 = 0,9930$ e o menor valor de RSME 0,0654. As coletas C3 e C4 (Figura 22bc) apresentaram valores similares de R^2 0,9907, 0,9903 e RSME 0,0750, 0,0810 respectivamente. Já os valores mais baixos de R^2 0,980, 0,9756 e maiores valores de RSME 0,1241, 0,1265 foram encontrados respectivamente nas duas últimas coletas C7 e C8 (Figura 22fg).

Figura 22. Regressão linear entre o MDT de referência com o MDT mensal – IVP em metros

Os resultados apresentados demonstram que para ambos conjuntos de dados (RGB e IVP) os melhores resultados foram observados para as coletas C3 e C6 coincidindo também as coletas que apresentaram os piores resultados de MDT, C2 e C8.

O comportamento desses dados indica que existe uma forte influência da classificação da nuvem densa de pontos na geração destes MDTs. Os valores utilizados para classificação da nuvem densa de pontos foram iguais para todos os MDTs. Como cada mês de coleta possui suas particularidades em relação a cobertura do terreno acredita-se que utilizando valores específicos para cada mês de coleta, os resultados poderiam ter sido mais satisfatórios em alguns meses. Conforme foi observado nas Figuras 17 e 18 a coleta C2 apresentou forte superestimação, provavelmente devido a cultura apresentar estágio de crescimento inicial, dificultando a classificação da nuvem densa de pontos. Neste caso, a classificação da nuvem pode ter escolhido pontos para a geração do MDT que na realidade seriam plantas. Já para os dados da coleta C5 IVP onde se observou forte subestimação, a classificação da nuvem densa de pontos atuou de maneira contrária ao descrito na coleta C2, foram classificados poucos pontos.

O comportamento do MDT da coleta C8 RGB e IVP apresentou alta dispersão dos valores provavelmente em função do desenvolvimento da cultura que impossibilitou a obtenção de pontos adequados do terreno para realização da modelagem. Como foi observado por Geipel; Link; Claupein, (2014) os MDTs que baseiam-se na interpolação de pontos de solo previamente classificados, geralmente estão propensos a erros de classificação em povoamentos de culturas densas e com fechamento de dossel. Nestas situações, apenas uma pequena quantidade de pontos do terreno será visível, enfraquecendo a confiabilidade dos resultados de interpolação.

Nesse sentido, o grande fator que influenciou a obtenção dos MDTs através da classificação da nuvem de pontos foram os limiares utilizados para a classificação. Este é um aspecto interessante que deve ser destacado, aja vista que na literatura são escassos os trabalhos que apresentam limiares de classificação. Assim, ao utilizar os mesmos valores para todas as coletas buscou-se visualizar a influência de se utilizar um valor fixo para a classificação, conforme também foi realizado por Geipel; Link; Claupein, (2014) que utilizou um RPA para capturar conjuntos de dados de imagens RGB para predição de rendimento da cultura de milho, em três fases de crescimento.

Embora o principal fator apontado seja a classificação, não podem ser ignorados outros dois fatores que também são discutidos pela literatura internacional (Al et al., 2015; BENDIG et al., 2015; CLAPUYT; VANACKER; VAN OOST, 2016; HOLMAN et al., 2016), o primeiro deles diz respeito a reprodutibilidade da execução do plano de voo, que embora foi o mesmo em todas as coletas, pode ter ocorrido pequenas variações devido a precisão posicional do sistema GNSS (sistema de navegação global por satélites) instalado no RPA e utilizado para posicionar as imagens, o outro aspecto diz respeito as condições meteorológicas no momento dos voos.

4.2. Modelos digitais de superfície (MDS), para dados RGB e IVP

Para avaliar a relação do MAC e o dados biométricos foi realizada uma comparação entre os dois conjuntos de MDS (RGB e IVP). A estatística descritiva da diferença entre os modelos RGB e IVP foi separada de acordo com as coletas e pode ser observada na Tabela 6.

Através dos resultados apresentados na Tabela 6, observa-se que a coleta C2 apresentou o maior valor de diferença média (0,425) e o segundo maior valor de desvio padrão (0,272), seguida da coleta C8 que apresentou o segundo maior valor de diferença média (0,331) e o maior valor de desvio padrão (0,284), o que indica que a maior diferença entre os MDSs foi na primeira e última coleta (C2 e C8) com a amplitude de variação chegando a 1,172 e 1,519 metros respectivamente. Já o menor valor de média (-0,066) e desvio padrão (0,083) foi encontrado para a coleta C3.

Estes resultados seguem as tendências observadas nos MDTs apresentados anteriormente. O MDT C8 foi o que apresentou os piores resultados tanto para RGB quanto utilizando as imagens IVP. Já os MDTs obtido através das imagens da coleta C3 foram os modelos que apresentaram as menores diferenças médias e menor RSME para os dois tipos de imagens.

Tabela 6. Estatística descritiva da diferença entre o MDS RGB e o MDS IVP em metros.

MDS (RGB/IVP)	Mínimo	Mediana	Média	Máximo	Desvio Padrão
C2	-0,146	0,442	0,425	1,026	0,272
C3	-0,310	-0,061	-0,066	0,096	0,083
C4	-0,265	0,037	0,052	0,730	0,145
C5	-0,130	0,214	0,211	0,629	0,151
C6	-0,101	0,186	0,180	0,453	0,113
C7	-0,198	0,184	0,187	0,535	0,150
C8	-0,447	0,329	0,331	1,072	0,284

Os maiores valores de diferença entre os MDSs também podem ser observados na Figura 23, que apresenta a distribuição da diferença média através do gráfico de *boxplot*. As coletas C3, C4 e C6 foram as que apresentaram menor desvio padrão em relação as demais.

Figura 23. Gráfico boxplot da diferença entre o MDS RGB em relação ao MDS IVP

Os dois MDSs foram submetidos à regressão linear e correlação de Pearson para avaliar a relação entre eles. Na Figura 24, é possível observar os resultados das regressões de todas as coletas. Observa-se que as coletas C2 e C8 (Figura 24ag) que apresentaram os maiores valores de desvio padrão e os maiores valores de diferença média são as que apresentaram o menor valor de coeficiente de regressão R^2 0,8767, 0,8770 respectivamente. As coletas C3 e C6 (Figura 24be) foram as que apresentaram os maiores valores de R^2 , acima de 0,98. Já para as coletas C4, C5 e C7 (Figura 24cdf) os valores de R^2 ficaram entre 0,95 a 0,97. Todos os valores de correlação de Pearson (r) foram superiores a 0,87 o que indica a forte correlação entre os dois MDSs.

Figura 24. Regressão linear (R^2) e correlação de Pearson (r) entre o MDS RGB com o MDS IVP para cada coleta em metros.

Na Figura 25 é apresentado o gráfico com todos os dados obtidos através dos MDSs para cada conjunto de imagens RGB e IVP bem como para cada coleta (C2 a C8), e constata-se a diferença das altitudes em relação a coleta C2 até a coleta C8, também é possível observar as diferenças presentes em cada coleta com relação ao conjunto de imagens utilizadas para o MDS. Avaliando as diferenças podemos observar que as coletas C2, pontos cinza, e C8, pontos vermelhos, apresentaram as maiores dispersões em relação as demais coletas (Figura 25). Essas diferenças observadas nas coletas C2 e C8 possuem relação direta com o estágio de crescimento que a cultura apresentava, sendo que cada sensor (RGB e IVP) possui uma sensibilidade diferente aos alvos.

No estágio inicial, as parcelas apresentavam áreas expostas com solo e palhada, que através do sensor IVP, foram facilmente identificadas. Isso se deve ao alto contraste que a vegetação apresenta em relação ao solo e palhada na região espectral do infravermelho próximo (HOLMAN et al., 2016). Comportamento semelhante foi também observado ao final do ciclo (C8), onde a estrutura do dossel apresentava falhas devido ao acamamento das folhas.

Figura 25. Regressão linear (R^2) e correlação de Pearson (r) entre o MDS RGB com o MDS IVP em metros

A análise da comparação entre o MDS RGB e IVP permitiu observar a alta correlação entre os modelos gerados, além de identificar que os MDS gerados nas coletas C2 e C8 apresentam menor correlação e por consequência maior amplitude de dispersão dos pontos, essa diferença observada reflete diretamente na estimativa da altura da cultura. Não foram encontrados na literatura trabalhos que realizaram comparações entre diferentes sensores conforme foi realizado neste trabalho, dificultando a discussão mais aprofundada.

4.3. Modelos de altura da cultura - MAC

Para gerar os modelos de altura da cultura (MAC) foi necessário identificar o melhor MDS e MDT. Para atingir este objetivo foram efetuadas 12 combinações (as combinações foram apresentadas na Tabela 2 no item 3.7.3 da metodologia), realizando associações diferentes entre os MDTs (referência, inicial, final e mensal) com os dois MDSs (RGB-IVP) e avaliando-se as correlações de Pearson geradas. Todas as correlações foram submetidas ao teste-t para que fosse possível avaliar a sua significância aos níveis de 5 e 10% de probabilidade. Os resultados das correlações são apresentados na Tabela 7.

Através da Tabela 7 é possível observar que cada simulação apresenta um valor distinto de correlação, o que evidencia que utilizando diferentes MDTs e MDS o resultado final é afetado.

A coleta C2 apresentou os menores valores de correlação e o menor número de combinações significativa, seguida da coleta C4. A coleta C4 apresentou correlação não significativa nas simulações 7 e 8 o que pode indicar a influência do MDT no resultado da coleta em questão. Nas duas simulações (7 e 8) foi utilizado como referência o MDT final obtido após a colheita com as

imagens IVP. Este MDT final em comparação com o MDT Referência foi o que apresentou os piores resultados em comparação com MDTs inicial (RGB e IVP) e final (RGB) (Tabela 7) influenciando negativamente na obtenção da altura da cultura.

No geral é possível observar que a maior parte das correlações ficaram com valores entre 0,60 a 0,90 o que indica a potencialidade da técnica na estimativa da altura.

Tabela 7. Coeficientes de correlação linear de Pearson entre a altura medida em campo e a altura obtida a partir das combinações para cada uma das sete coletas.

Combinações	DAC 99	DAC 144	DAC 164	DAC 200	DAC 228	DAC 269	DAC 326
	C2	C3	C4	C5	C6	C7	C8
1	0,37**	0,62**	0,44**	0,68**	0,87**	0,84**	0,60**
2	0,29 ^{ns}	0,60**	0,34*	0,73**	0,73**	0,68**	0,59**
3	0,38**	0,60**	0,46**	0,64**	0,85**	0,86**	0,64**
4	0,33*	0,56**	0,38**	0,66**	0,74**	0,73**	0,58**
5	0,35*	0,48**	0,62**	0,67**	0,88**	0,79**	0,58**
6	0,26 ^{ns}	0,49**	0,57**	0,69**	0,83**	0,69**	0,52**
7	0,39**	0,64**	0,29 ^{ns}	0,55**	0,59**	0,72**	0,57**
8	0,33*	0,59**	0,17 ^{ns}	0,59**	0,50**	0,64**	0,52**
9	0,35*	0,67**	0,46**	0,63**	0,83**	0,84**	0,73**
10	0,27 ^{ns}	0,60**	0,65**	0,64**	0,75**	0,82**	0,71**
11	0,41**	0,60**	0,52**	0,65**	0,90**	0,90**	0,65**
12	0,39**	0,58**	0,44**	0,70**	0,79**	0,74**	0,62**

Nota: ^{ns} representa correlação não significativa a 5% e 10% de probabilidade pelo teste t, * representa correlação significativa a 10% pelo teste t, ** representa correlação significativa a 5% pelo teste t.

Quando todos os dados obtidos em cada coleta foram submetidos a análise de regressão e correlação linear é possível avaliar a eficiência do método em estimar a altura da cultura no decorrer de uma safra (Tabela 8). As combinações que foram obtidas com o MDS utilizando as imagens IVP (2,4,6,8,10,12) foram as que apresentaram os maiores valores de correlação, bem como os menores valores de RSME quando comparadas as simulações que utilizaram o mesmo MDT, mas com o MDS obtido com as imagens RGB.

O erro relativo máximo da estimativa da altura através da MAC foi 13%, sendo que as melhores combinações foram a 2 e 12 que obtiveram um RE de 6,34 % e 5,97 % respectivamente (Tabela 8). Os MDTs utilizados nessas duas combinações foram o MDT inicial RGB na combinação 2 e MDT referência na combinação 12. Ambas combinações foram realizadas com o MDS (IVP) o que indica que para este trabalho as imagens obtidas pela câmera IVP apresentaram melhores resultados na estimativa da altura da cana-de-açúcar.

Tabela 8. Coeficientes de correlação linear de Pearson (r), Coeficiente de determinação (R^2), Raiz quadrada do erro médio (RSME) e Erro relativo % (RE) entre a altura medida em campo e a altura obtida a partir das combinações das sete coletas.

Combinações	R	R^2	RSME	RE (%)
1	0,95	0,90	0,26	10,36
2	0,98	0,95	0,17	6,34
3	0,94	0,89	0,28	10,70
4	0,97	0,94	0,20	7,16
5	0,94	0,89	0,28	11,62
6	0,97	0,94	0,19	7,44
7	0,92	0,85	0,32	12,83
8	0,95	0,90	0,26	9,57
9	0,95	0,90	0,30	11,41
10	0,97	0,94	0,20	7,47
11	0,95	0,90	0,25	10,05
12	0,98	0,96	0,16	5,97

Essa diferença entre as simulações obtidas com as imagens RGB e IVP pode ser explicada pela Figura 26, onde são apresentados os resultados das simulações 11 e 12 que foram obtidas com o MDS RGB e IVP respectivamente. Na simulação 11 (Figura 26b) é possível identificar visualmente a maior dispersão dos dados nas coletas C2 (cinza) e C8 (vermelho) em comparação com a simulação 12 (Figura 26a). Essa diferença já havia sido identificada na análise da diferença entres os MDS (RGB e IVP) observados na Figura 25.

Figura 26. Gráfico de dispersão entre a altura da planta medida em campo com a altura obtida pela combinação 12 (a) e pela combinação 11 (b).

A análise efetuada com as diferentes combinações permitiu visualizar a interferência do MDT e MDS para a obtenção do MAC. Pelos resultados apresentados percebe-se que as combinações que utilizaram o MDS obtido a partir do conjunto de imagens IVP, foram os que apresentaram os maiores valores de correlação e os menores valores de erro relativo (RE) e RSME.

Conforme já destacado pela literatura, a utilização de imagens com sensibilidade na região espectral do infravermelho próximo (IVP) em vez de RGB permite o aumento do contraste entre a planta e o solo e podem melhorar significativamente o processamento do modelo (HOLMAN et al., 2016).

Esse fator pode explicar a dispersão dos dados encontrados nas coletas C2 e C8 na análise do MDS, essa diferença entre a modelagem IVP e RGB pode ser também visualizada na Figura 26, a qual apresenta uma dispersão maior dos dados nas coletas C2 e C8 para a combinação 11 que utilizou dados RGB.

Ao observar os resultados e a influência de cada combinação no resultado final do MAC foi evidente que os diferentes métodos de geração do MDT, embora tenham diferido entre eles, não afetaram o MAC nas mesmas proporções que a utilização de diferentes MDSs.

Ao avaliar a precisão dos dados de altura obtidos através da combinação 12, é possível identificar uma subestimação das alturas em comparação com a biometria de campo. Verificou-se que a modelagem da altura da cultura (MAC) utilizando imagens obtidas por RPA, frequentemente subestima as alturas, como foi discutido em outros estudos avaliando culturas de milho (GEIPEL; LINK; CLAUPEIN, 2014) cevada (AASEN et al., 2015) e trigo (HOLMAN et al., 2016).

Em termos de precisão, os dados produzidos proporcionaram bons resultados com $R^2 = \geq 0,95$ e $RMSE = \leq 0,16$ m para combinação 12. Ao comparar os resultados obtidos neste trabalho e outros trabalhos que também estimaram a altura da cultura utilizando SFM para a modelagem 3D, os resultados obtidos para RSME foram extremamente satisfatórios. Li et al., (2016) avaliaram a estimativa da altura do dossel para a cultura de milho e obteve o valor de RMSE de 0,21 metros com coeficiente de determinação de R^2 0,74. Outros trabalhos também avaliaram a cultura do milho, Geipel, Link e Claupein, (2014) obtiveram o mesmo valor de coeficiente de determinação 0,74, porém neste estudo, não foram apresentados valores de RSME. Já Holman et al., (2016) avaliando a potencialidade da técnica para a cultura do trigo obteve RMSE de 0,07 m e R^2 0,93. Díaz-Varela et al., (2015) utilizaram esta técnica para estimar a altura de cultura perene, árvores de oliveira, obtendo valores de RSME variando entre 0,45 a 0,20 com R^2 0,07 a 0,53.

Recentemente Souza et al., (2017) utilizaram um RPA de asa fixa para obtenção de imagens e geração de nuvem densa de pontos para estimar a altura da cana-de-açúcar, os resultados obtidos apresentaram RSME variando entre 0,57 a 0,40 metros dependendo da direção do voo para obtenção das imagens. O coeficiente de correlação de Pearson encontrado, variou entre 0,23 e 0,54. Os dados obtidos por esses autores são inferiores aos obtidos por esse estudo. Os autores apontam como fatores que possam ter influenciado na qualidade dos dados, a presença de sombra nas imagens, a diferença na intensidade de luz, a heterogeneidade na altura da cana-de-açúcar.

Outros trabalhos utilizaram técnicas diferentes para estimar a altura da cana-de-açúcar visando obter a variabilidade espacial, Canata et al., (2016) utilizaram sensor LiDAR acoplado a uma plataforma terrestre a fim de obter a espacialização da altura de um canavial. Esses autores observaram um coeficiente de determinação R^2 0,44 e apontaram alguns fatores que podem afetar a qualidade dos dados e a potencialidade da técnica, como por exemplo a presença de ruídos devido a inclinação do terreno e a luz solar incidente sobre o sensor, bem como a adaptação para condições

reais de campo, onde até o momento não se tem a possibilidade de adentrar na lavoura com veículo agrícola durante o ciclo vegetativo da cultura.

4.4. Relação entre a altura e a produtividade final

Assim como outros trabalhos que já utilizaram a altura para estimar a produtividade, a Tabela 9 apresenta os resultados do presente trabalho em relação à altura e a produtividade final. Os resultados apontaram relação entre a altura e produtividade final mais expressiva entre as coletas C5 a C7. Ao avaliar diferentes métodos para obtenção da altura média de cada parcela, foi possível observar que a medida em que foram obtidos dados utilizando uma área amostral maior (polígono) obteve-se maior correlação com a produtividade final.

Tabela 9. Coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2) entre a altura em relação a produtividade final, para cada coleta e para cada método de obtenção da altura.

Análise	DAC 99 C2	DAC 144 C3	DAC 164 C4	DAC 200 C5	DAC 228 C6	DAC 269 C7	DAC 326 C8
Alturas Biometria							
Correlação P.	0,42	0,36	0,63	0,79	0,83	0,83	0,72
R^2	0,17	0,13	0,39	0,63	0,69	0,69	0,52
Alturas MAC – Subamostras							
Correlação P.	0,76	0,78	0,45	0,82	0,81	0,74	0,63
R^2	0,57	0,60	0,21	0,68	0,65	0,55	0,39
Alturas MAC – Amostra Polígono							
Correlação P.	0,79	0,80	0,57	0,85	0,83	0,82	0,69
R^2	0,62	0,65	0,33	0,72	0,70	0,67	0,47

Ao observar as correlações obtidas entre os dados de biometria e altura do MAC foi possível constatar que a biometria apresentou correlações (r) maiores que 0,60 a partir da coleta C4, enquanto que o MAC apresentou correlações maiores que 0,60 a partir da coleta C2. No entanto a coleta C4 apresentou resultados inferiores as demais coletas para os dados obtidos com o MAC, o que indicou que o modelo foi afetado por algum motivo específico e consequentemente apresentou comportamento anormal em relação as demais coletas.

Como os dados do MAC - polígono foram os que apresentaram maior relação com a produtividade, optou-se por submetê-los a regressão linear para encontrar os valores de RSME e RE (%) (Figura 27). Holman et al (2016), também utilizou polígonos para extração das alturas médias da parcela isolando a faixa de bordadura para evitar efeitos negativos na determinação da altura da parcela.

Figura 27. Regressões lineares entre as alturas obtidas pelo MAC (polígono) e a produtividade fina em metros.

Os dados de altura obtidos pela biometria de campo apresentaram alta correlação com a produtividade final a partir da coleta C5 (200 DAC) até a coleta C7 (269 DAC), com valores de correlação de Pearson de 0,79, 0,79 e 0,83 respectivamente, tendência observada também com os dados obtidos pelo MAC (Tabela 9). Portz, Amaral e Molin, (2012a) obtiveram manualmente com uma régua a altura da cana para a predição da biomassa. Os autores observaram altas correlações entre a altura da cana com a produtividade de biomassa em diferentes períodos de coleta, obtendo valores de coeficiente de determinação máximo de R^2 0,91 para a coleta realizada no fim da estação seca com amplitude da altura da cana de 1,3 metros.

No mesmo trabalho, esses autores obtiveram valores mais baixos de coeficiente de determinação, R^2 0,69, quando estavam avaliando a altura obtida durante o início da estação seca com a altura da cana variando de 0,2 a 0,8 metros. O valor de R^2 observado foi o mesmo encontrado no presente trabalho nas coletas C6 e C7.

No entanto, outros trabalhos obtiveram melhores resultados de coeficiente de determinação para a estimativa de biomassa. Portz et al., (2013) utilizando um sensor ultrassônico para mensurar a

altura da cana-de-açúcar obtiveram altos valores de coeficiente de determinação na estimativa da produtividade de biomassa. O trabalho foi desenvolvido em duas áreas que possuíam solos com diferentes texturas, sendo um arenoso (12 ha) e o outro argiloso (16 ha), a altura foi obtida em dois períodos diferentes, após a validação da estimativa da produtividade em 10 pontos na área de estudo. Os resultados foram R^2 0,81 para área arenosa no primeiro período de coleta (0,3 a 0,5 metros de altura) e R^2 0,82 para a segunda coleta quando a cultura apresentava um porte de 0,5 a 0,7 metros. Já para área argilosa foram obtidos valores de R^2 0,69 e 0,88 na primeira e segunda coleta respectivamente.

Esses resultados salientam a sensibilidade da utilização da altura para prever a produtividade quando as plantas apresentam maiores alturas. Esse comportamento foi observado neste trabalho, onde os maiores valores de R^2 foram obtidos entre a coleta C5 a C7. Outro aspecto a destacar é que no trabalho de Portz et al., (2013) devido ao experimento utilizar o sensor ultrassônico acoplado a uma máquina agrícola houve dificuldade de obter dados quando a cultura apresenta altura superior a 2 metros, por exemplo, diferentemente da utilização de imagens aéreas, onde a modelagem não é limitada em relação à altura da cultura.

O maior valor de R^2 (0,72) encontrado neste trabalho, foi para a coleta C5 (200 DAC) utilizando a média da altura do MAC obtida por área amostral (Figura 27d). Esse valor encontra-se abaixo dos valores observados em trabalhos que utilizaram outras técnicas para obtenção da altura na cana-de-açúcar, porém a área de estudo do presente trabalho é menor em comparação aos trabalhos apresentados.

A produtividade final apresentou baixa variabilidade entre as parcelas (coeficiente de variação de 10 %) o que pode dificultar a estimativa da mesma, diferentemente dos trabalhos apresentados em que foi avaliado a altura em áreas comerciais e a amplitude encontrada chegou ao patamar de 1,3 metros dentro da mesma coleta.

Uma alternativa para melhorar a estimativa da produtividade pode ser a utilização simultânea da modelagem da altura da cultura juntamente com índices de vegetação, como já foi realizado para a cultura de milho (GEIPEL; LINK; CLAUPEIN, 2014; LI et al., 2016), cevada (AASEN et al., 2015; BENDIG et al., 2015) e até mesmo para a pastagem (POSSOCH et al., 2015).

4.5. Avaliação da variabilidade espacial da cana-de-açúcar por meio do MAC

4.5.1. Comparação entre o MAC e Mosaico RGB

Analisar a variabilidade da cultura em relação a altura pode ser um fator importante na análise da dinâmica do crescimento (SHI et al., 2016). Os mapas do MAC gerados para cada coleta juntamente com o mosaico obtido a partir das imagens RGB são apresentados nas Figuras 28 e 29.

Figura 28. A esquerda a representação do MAC e a direita os mosaicos RGB para cada coleta C2 a C5.

Figura 29. A esquerda a representação do MAC e a direita os mosaicos RGB para cada coleta C6 a C8.

Quando as duas informações foram comparadas (MAC e Mosaico) foi possível observar a variabilidade espacial que cada informação apresenta. Observando o mosaico RGB da coleta C2 (Figura 28), é possível identificar que naquele momento o dossel da cultura ainda não havia fechado completamente, sendo possível observar áreas com palhada (cores mais claras em relação ao verde do dossel). Para a imagem do MAC a mesma tendência foi notada onde os valores de altitude são menores com maior variabilidade no modelo. No mosaico da coleta C3 já não foi mais possível observar visualmente a variabilidade causada pelas linhas de plantio e palhada devido ao fechamento do dossel. Já o MAC da coleta C3 possibilitou observar a dinâmica do crescimento da cultura mesmo após o fechamento do dossel. Através do MAC foi possível observar a variabilidade que a cultura apresenta em relação a sua altura durante todas as coletas.

Conhecer a variabilidade da área de estudo permite observar zonas que apresentam padrões semelhantes que podem ser associados a variáveis diretamente ligadas ao desenvolvimento da cultura. Imagens aéreas já foram utilizadas na avaliação da variabilidade espacial da cana-de-açúcar, imagens orbitais (GALVÃO; FORMAGGIO; TISOT, 2005; FORTES; DEMATTÊ, 2006),

imagens obtidas por aeronaves convencionais (LABBÉ et al., 2007; LEBOURGEOIS et al., 2008), e imagens obtidas por RPA (MAGALHÃES et al., 2013) no entanto, esses trabalhos não avaliaram a utilização da modelagem tridimensional para estimativa da altura da cana-de-açúcar.

O MAC já foi utilizado em trabalhos que avaliaram a variabilidade que a cultura apresenta em relação à altura, cevada (BENDIG; BOLTEN; BARETH, 2013), milho (GEIPEL; LINK; CLAUPEIN, 2014; LI et al., 2016), arroz (BENDIG et al., 2013), oliveiras (DÍAZ-VARELA et al., 2015), trigo (HOLMAN et al., 2016).

Mais recentemente De Souza et al. (2017) utilizou modelagem tridimensional para estimativa da altura da cana-de-açúcar, no entanto este autor não fez uso de mosaicos para identificar a variabilidade espacial.

Embora Magalhães et al. (2013) tenha utilizado índices de vegetação para avaliação da variabilidade, estes autores também observaram que quando a cana-de-açúcar encontra-se em seu estágio inicial de desenvolvimento (60 DAC) a mesma apresenta maior variabilidade com relação a áreas que não apresentam fechamento de dossel, o mesmo foi observada no mosaico RGB da coleta C2 (99 DAC) deste trabalho. Estes mesmos autores também avaliaram a cultura aos 180 DAC e observaram o mesmo comportamento encontrado neste trabalho em relação ao fechamento do dossel.

Foi também possível observar a diferença entre o MAC e o mosaico RGB para a mesma coleta, uma das vantagens em se utilizar o MAC é a facilidade em observar a dinâmica que a cultura apresenta, essa variabilidade é facilmente identificada em comparação com o mosaico RGB (Figura 29) que após a coleta C2 não apresenta visualmente grandes mudanças na cobertura da cultura. Na cultura da cana-de-açúcar não se tem estudos que utilizam o MAC temporalmente para avaliação da variabilidade espacial, mas na cultura da cevada e arroz, trabalhos apontam a grande potencialidade da técnica (BENDIG et al., 2013; BENDIG; BOLTEN; BARETH, 2013).

4.5.2. Avaliação da variabilidade espacial do MAC com relação a dose de N

Uma vez comprovado através das análises anteriores que o MAC é capaz de estimar a altura do dossel da cana-de-açúcar, este foi utilizado para observar a variabilidade espacial do talhão de estudo, o qual apresentava variabilidade devido a aplicação de diferentes doses de N em cada parcela. As Figuras 30 e 31 apresentam o modelo da altura da cultura para as coletas C2 a C8, sendo que as parcelas foram numeradas e os tratamentos são representados por círculos de cores diferentes.

Figura 30. Modelos da altura da cultura (MAC) das coletas C2 a C5, com as respectivas parcelas e tratamentos.

Figura 31. Modelos da altura da cultura (MAC) das coletas C6 a C8, com as respectivas parcelas e tratamentos.

Observando o comportamento da altura para cada coleta foi possível constatar que algumas parcelas que não receberam nenhuma dose de nitrogênio (0 kg ha⁻¹) foram as que apresentaram as menores alturas, é o caso das parcelas 21 e 28, juntamente com essas parcelas percebe-se que as parcelas 22 e 27 que receberam uma dose de 60 kg ha⁻¹ também apresentam alturas inferiores à média das demais parcelas. Isoladamente observa-se a variabilidade da altura dentro da parcela 18, a qual apresentou menores alturas no centro da parcela, esse comportamento é contraditório, a vista que é uma das parcelas que recebeu a maior dose de N (180 kg ha⁻¹).

Outro comportamento observado diz respeito as parcelas 25 e 26 que respectivamente receberam doses de N de 120 e 180 kg ha⁻¹ e apresentaram alturas inferiores as observadas nas parcelas 4 e 8 que receberam doses de 60 kg ha⁻¹. Esse comportamento também pode ser observado

nas parcelas 2 e 3 que receberam doses de 120 kg ha⁻¹ e as alturas observadas assemelham-se as alturas da parcela 6 que não recebeu nitrogênio.

Por outro lado, as parcelas 1, 10, 17 e 19 que receberam doses de N 60 kg ha⁻¹ e a parcela 11 que não recebeu N apresentaram alturas mais baixas em comparação as parcelas 5, 9, 12, 13, 14, 15, 16, 20, 23 e 24 que receberam as maiores doses de N (120 e 180 kg ha⁻¹) e apresentaram as maiores alturas observadas. Essa semelhança entre as doses aplicadas de N e a altura da cana também foram observadas no trabalho de Amaral et al., (2014) e Molin et al., (2010) que utilizaram sensores ativos para quantificar a respostas dos teores de nitrogênio presente na cultura da cana-de-açúcar.

Destaca-se a utilidade da modelagem da altura da cultura para avaliar a variabilidade espacial, possibilitando observar o desenvolvimento e o comportamento que a cultura apresenta entre as parcelas, bem como o comportamento dentro de uma única parcela com alto nível de detalhamento como observado por Bendig et al., (2015) que avaliou a modelagem da altura na cultura da cevada. A altura pode ser uma informação importante para avaliar o comportamento da cultura em relação a doses de nitrogênio desde que seja integrada a outros sistemas de coleta de dados como proposto por Portz et al., (2013b).

4.5.3. Avaliação da variabilidade espacial do MAC com relação ao fechamento de dossel

Avaliando os mosaicos RGB gerados para análise da variabilidade espacial, foi possível observar que na coleta C2 algumas parcelas não apresentaram o fechamento total do dossel. Sendo assim, essas áreas que não apresentavam cobertura com vegetação no dia da coleta foram vetorizadas para a comparação com o modelo da altura da cultura. Para facilitar a vetorização das áreas foi utilizado o índice de vegetação RGBVI que posteriormente foi reclassificado e vetorizado, resultando nas áreas que não apresentaram o fechamento total do dossel.

As Figuras 32 e 33 apresentam o MAC para cada coleta, as parcelas, assim como a sobreposição da camada da vetorização das áreas com ausência de fechamento de dossel obtidas através da coleta C2. A sobreposição permitiu avaliar de forma visual o comportamento entre a altura das plantas e o fechamento do dossel em cada parcela.

Observando a Figura 32, constata-se que as baixas alturas da coleta C2 estão nas mesmas parcelas onde observou-se áreas com ausência de fechamento de dossel (vetorização). Este comportamento já era esperado, visto que o MAC da coleta C2 e o mosaico RGB, utilizado para vetorização das áreas de ausência de fechamento de dossel, foram obtidos com as mesmas imagens na coleta C2.

Nas outras coletas houve também a presença de baixas alturas nos mesmos locais vetorizados a partir do mosaico RGB da coleta C2. No entanto, este comportamento se evidenciou apenas nas parcelas que apresentaram as maiores áreas com ausência de fechamento de dossel, parcelas 17, 18, 21 e 28.

A parcela 18 foi uma das parcelas que apresentou baixo desenvolvimento de altura e área sem fechamento do dossel. Ao avaliar o MAC em relação a dose de nitrogênio, foi observado que essa parcela apresentou comportamento atípico em relação a dose de nitrogênio (180 kg ha^{-1}). Este comportamento é indício de que, nesta parcela, pode ter ocorrido interferência de algum fator externo que não foi avaliado neste trabalho e que se manifestou desde o início do ciclo produtivo.

Também foi possível observar que a parcela 21 que não recebeu dose de nitrogênio, apresentou áreas com ausência de fechamento de dossel e baixa altura. O alto nível de detalhamento do MAC permitiu observar a variabilidade espacial de cada parcela. Assim, diferentemente da parcela 18, a parcela 21 apresentou áreas de ausência de fechamento do dossel distribuídas por toda a parcela, assim como o comportamento da altura observado no MAC.

Figura 32. MAC das coletas C2 a C5 com a sobreposição das áreas que não apresentaram cobertura de vegetação na coleta C2 e o limite de cada parcela com suas respectivas doses de nitrogênio ($\text{kg}^{-1} \text{ha}$).

Figura 33. MAC das coletas C6 a C8 com a sobreposição das áreas que não apresentaram cobertura de vegetação na coleta C2 e o limite de cada parcela com suas respectivas doses de nitrogênio ($\text{kg}^{-1} \text{ha}$).

Outros trabalhos buscaram espacializar e identificar as áreas de falhas na brotação da cana-de-açúcar, como exemplo Molin e Veiga, (2016) que através de um sensor acoplado em uma máquina agrícola obtiveram um mapa das áreas que apresentavam falhas de brotação na linha de plantio. A espacialização das falhas é extremamente importante pois áreas com falhas representam perdas na produtividade da cana-de-açúcar (STOLF, 1986).

Pode-se citar como possível utilização do MAC a visualização da dinâmica do crescimento em relação a áreas que apresentaram desenvolvimento anormal ou falhas. As Figuras 32 e 33 apresentam a sobreposição entre o MAC e a vetorização de área que não apresentava fechamento do dossel no momento da coleta C2. Nestas Figuras é possível observar como a cultura apresentou

baixo desenvolvimento nas áreas que apresentaram falhas de brotação ou deficiência no desenvolvimento.

4.5.4. Estimativa da produtividade por meio do MAC

Como a altura tem alta correlação com a produtividade final da cana-de-açúcar (SILVA et al., 2009; SILVA; DE MORAES; MOLIN, 2011; PORTZ; AMARAL; MOLIN, 2012a; PORTZ et al., 2013b; CANATA et al., 2016) é possível através do MAC espacializar a produtividade e definir áreas que apresentaram maiores e menores produtividades (Figura 34). Através do MAC foi possível identificar áreas que apresentaram comportamento anormal fornecendo informação para o tomador de decisões quanto a medida a ser tomada.

Devido a facilidade na obtenção dos dados o monitoramento da cultura pode ser avaliado durante várias safras, fornecendo informações importantes desde a delimitação de áreas que possuam um maior potencial de produtividade até áreas que apresentam problemas e consequentemente proporcionam baixas produtividades.

Para observar a variabilidade da produtividade foi gerado um mapa utilizando o modelo obtido a partir da regressão linear entre os dados de altura e a produtividade final juntamente com o MAC da coleta C5. Essa coleta foi a que apresentou o menor valor de RSME e erro relativo (RE) na regressão. O mapa em questão encontra-se na Figura 34, nele foram rotuladas as doses aplicadas de nitrogênio ($\text{kg}^{-1} \text{ha}$) com o intuito de verificar visualmente a influência das doses em relação a modelagem da produtividade final.

Figura 34. Mapa da estimativa da produtividade final obtida através do modelo de regressão linear entre a altura da cultura e a produtividade obtida em campo.

Através da Figura 34 , constata-se visualmente que as parcelas que receberam as maiores doses de nitrogênio foram as que apresentaram os maiores valores de produtividade.

Embora o MAC tenha apenas correlação moderada com a produtividade, o mesmo possui alta capacidade para identificar tendências de rendimento e locais para investigação mais profunda sobre as causas da variância espacial da cultura, conincidindo com os resultados observados em outros trabalhos (BENDIG; BOLTEN; BARETH, 2013; GEIPEL; LINK; CLAUPEIN, 2014; LI et al., 2016; BENDIG et al., 2013).

5. CONCLUSÕES

Os resultados obtidos pelo presente trabalho permitiram avaliar os dados coletados para a modelagem tridimensional da cultura da cana-de-açúcar. Foi possível observar a alta correlação dos modelos gerados para prever o modelo digital do terreno (MDT) em comparação ao método tradicional utilizado como MDT de referência. Os três métodos de coleta (Inicial, Mensal e Final) apresentaram resultados satisfatórios e comprovaram a eficiência da técnica para obtenção do MDT, destacando-se os MDTs obtidos no início do ciclo produtivo (MDT Inicial - RGB).

Os modelos de altura (MAC) obtidos através das imagens aéreas foram adequados para modelar a altura da cana-de-açúcar, apresentando altos valores de correlação entre o valor observado em campo e o estimado pela modelagem. Através da comparação entre sensores (RGB e IVP) foi possível observar que os modelos gerados a partir do sensor IVP apresentaram maiores correlações com os dados de campo.

A altura derivada do MAC permitiu estimar a produtividade de biomassa da cultura, apresentando valores de correlação próximos aos encontrados na literatura. Estes resultados indicam a potencialidade da técnica para utilização em campo. Também foi possível observar os melhores períodos para a coleta de dados a fim de prever a produtividade do canavial.

Os mapas de altura e produtividade gerados apresentaram-se como uma informação que possibilita a verificação da variabilidade espacial, fornecendo dados úteis para gestão e manejo adequado da cultura.

6. CONSIDERAÇÕES FINAIS

Embora o método desenvolvido neste estudo tenha demonstrado produzir resultados de qualidade ao longo da escala temporal do ciclo da cana-de-açúcar, ainda há margem para melhoria na compreensão das dependências do processamento e coleta das imagens a serem utilizadas com a técnica SFM (Structure From Motion).

Outro ponto a destacar é a necessidade de avaliar a potencialidade da técnica em áreas maiores. Nesse sentido, deve-se realizar mais estudos para que as informações obtidas possam ser utilizadas em escalas mais amplas considerando a quantidade de variáveis que podem influenciar a coleta dos dados, desde a escolha adequada da plataforma, sensor e principalmente o processamento e geração dos produtos finais.

REFERÊNCIAS

- AASEN, H.; BURKART, A.; BOLTEN, A.; BARETH, G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, n. 2016, p. 245–259, 2015.
- AI, M.; HU, Q.; LI, J.; WANG, M.; YUAN, H.; WANG, S. A robust photogrammetric processing method of low-altitude UAV images. **Remote Sensing**, v. 7, n. 3, p. 2302–2333, 2015.
- AMARAL, L. R.; MOLIN, J. P. J. P.; PORTZ, G.; FINAZZI, F. B.; CORTINOVE, L. Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. **Precision Agriculture**, v. 16, n. 1, p. 15–28, 2014.
- AMARAL, L. R.; MOLIN, J. P.; SCHEPERS, J. S. Algorithm for variable-rate nitrogen application in sugarcane based on active crop canopy sensor. **Agronomy Journal**, v. 107, n. 4, p. 1513–1523, 2015.
- ANDRADE, R. G.; SEDIYAMA, G.; SOARES, V. P.; GLERIANI, J. M.; MENEZES, S. J. M. da C. Estimativa da produtividade da cana-de-açúcar utilizando o Sebal e imagens Landsat. **Revista Brasileira de Meteorologia**, v. 29, n. 3, p. 433–442, set. 2014.
- ANDRADE, S. F. de. SENSORIAMENTO REMOTO E ALGUMAS APLICAÇÕES. **CADEGEO**, v. 2, n. 1, p. 13–26, 2011.
- BARBOSA, A. P.; MARTELLO, M.; FIORIO, P. R.; TAVARES, T. R. Utilização de veículo aéreo não tripulado na detecção de falhas de plantio em um canavial. **XLIV Congresso Brasileiro de Engenharia Agrícola**, 2015.
- BARETH, G.; AASEN, H.; BENDIG, J.; GNYP, M. L.; BOLTEN, A.; JUNG, A.; MICHELS, R.; SOUKKAMÄKI, J. Low-weight and UAV-based Hyperspectral Full-frame Cameras for Monitoring Crops: Spectral Comparison with Portable Spectroradiometer Measurements. **Photogrammetrie - Fernerkundung - Geoinformation**, v. 2015, n. 1, p. 69–79, 2015a.
- BARETH, G.; BOLTEN, A.; HOLLENBERG, J.; AASEN, H.; BURKART, A.; SCHELLBERG, J. Feasibility study of using non-calibrated UAV-based RGB imagery for grassland monitoring: Case study at the Rengen Long-term Grassland Experiment (RGE), Germany. **DGPF Tagungsband 24**, p. 55–62, 2015b.
- BENDIG, J.; BOLTEN, A.; BARETH, G. UAV-based Imaging for Multi-Temporal, very high Resolution Crop Surface Models to monitor Crop Growth Variability. **Photogrammetrie - Fernerkundung - Geoinformation**, v. 2013, n. 6, p. 551–562, 2013.
- BENDIG, J.; WILLKOMM, M.; TILLY, N.; GNYP, M. L.; BENNERTZ, S.; QIANG, C.; MIAO, Y.; BARETH, G. Very high resolution crop surface models (CSMs) from UAV-based stereo images for rice growth monitoring In Northeast China. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XL, n. p. 4–6, 2013.

- BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79–87, 2015.
- BUSEMEYER, L.; MENTRUP, D.; MÖLLER, K.; WUNDER, E.; ALHEIT, K.; HAHN, V.; MAURER, H. P.; REIF, J. C.; WÜRSCHUM, T.; MÜLLER, J.; RAHE, F.; RUCKELSHAUSEN, A. Breedvision - A multi-sensor platform for non-destructive field-based phenotyping in plant breeding. **Sensors (Switzerland)**, v. 13, n. 3, p. 2830–2847, 2013.
- CÂMARA, G. M. . Ecofisiologia da cultura da cana-de-açúcar. In: **Produção de cana-de-açúcar**. Piracicaba: ESALQ, 1993. p. 31–64.
- CANATA, T. .; MOLIN, J. P.; COLAÇO, A. .; TREVISAN, R. .; MARTELLO, M.; FIORIO, P. R. Measuring height of sugarcane plants through LiDAR technology. In: **13th Internacional conference on Precision Agriculture**. 2016.
- CANDIAGO, S.; REMONDINO, F.; GIGLIO, M. De; DUBBINI, M.; GATTELLI, M. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. **Remote Sensing**, v. 7, n. Vi, p. 4026–4047, 2015.
- CHAGAS, C. S.; FERNANDES FILHO, E. I.; ROCHA, M. F.; DE CARVALHO JÚNIOR, W.; SOUZA NETO, N. C. Avaliação de modelos digitais de elevação para aplicação em um mapeamento digital de solos Evaluation of digital elevation models for application in a digital soil mapping. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 2, p. 218–226, 2010.
- CLAPUYT, F.; VANACKER, V.; VAN OOST, K. Reproducibility of UAV-based earth topography reconstructions based on Structure-from-Motion algorithms. **Geomorphology**, v. 260, n. May, p. 4–15, 2016.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.
- COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira de cana-de-açúcar, Segundo Levantamento – Safra 2015/2016** Brasília, 2015. .
- COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira de cana-de-açúcar, Terceiro Levantamento - Safra 2016/2017**, 2016.
- CREPANI, E. **Princípios básicos de sensoriamento remoto**. São José dos Campos: INPE, 1993.
- CRIMMINS, M. a.; CRIMMINS, T. M. Monitoring plant phenology using digital repeat photography. **Environmental Management**, v. 41, n. 6, p. 949–958, 2008.
- DE SOUZA, C. H. W.; LAMPARELLI, R. A. C.; ROCHA, J. V.; MAGALHÃES, P. S. G. Height estimation of sugarcane using an unmanned aerial system (UAS) based on structure from motion (SfM) point clouds. **International Journal of Remote Sensing**, v. 0, n. 0, p. 1–13, 2017.
- DÍAZ-VARELA, R.; DE LA ROSA, R.; LEÓN, L.; ZARCO-TEJADA, P. High-Resolution Airborne UAV Imagery to Assess Olive Tree Crown Parameters Using 3D Photo Reconstruction: Application in Breeding Trials. **Remote Sensing**, v. 7, n. 4, p. 4213–4232, 2015.
- DINARDO MIRANDA, L. .; VASCONCELOS, A. C. M. de; LANDELL, M. G. de A. **Cana-de-açúcar**. Campinas: Instituto Agrônômico, 2008.

- DIOLA, V.; SANTOS, F. Fisiologia. In: SANTOS, F.; BORÉM, A.; CALDAS, C. (Ed.). **Cana-de-açúcar: bioenergia, açúcar e álcool: tecnologias e perspectivas**. 1. ed. Viçosa: Editora UFV, 2010. p. 25–49.
- DWORAK, V.; SELBECK, J.; EHLERT, D. Ranging sensors for vehicle-based measurement of crop stand and orchard parameters: a review. **Trans. ASABE**, v. 54, n. 4, p. 1497–1510, 2011.
- EHLERT, D.; ADAMEK, R.; HORN, H.-J. Laser rangefinder-based measuring of crop biomass under field conditions. **Precision Agriculture**, v. 10, n. 5, p. 395–408, 26 out. 2009.
- EHLERT, D.; HORN, H. J.; ADAMEK, R. Measuring crop biomass density by laser triangulation. **Computers and Electronics in Agriculture**, v. 61, n. 2, p. 117–125, 2008.
- FERREIRA, F. M.; BARROS, W. S.; SILVA, F. L. da; BARBOSA, M. H. P.; CRUZ, C. D.; BASTOS, I. T. Relações fenotípicas e genotípicas entre componentes de produção em cana-de-açúcar. **Bragantia**, v. 66, n. 4, p. 605–610, 2007.
- FIORIO, P. R.; MARTINS, J.A.; MOLIN, J.P.; AMARAL, L.R. Dados espectrais de dossel de cana-de-açúcar para predição do teor relativo de clorofila. **XVII Simpósio Brasileiro de Sensoriamento Remoto**, João Pessoa - PB, 2015.
- FLORENZANO, T. G. **Imagens de satélites para estudos ambientais**. São Paulo: Oficina de Textos, 2002.
- FORTES, C.; DEMATTÊ, J. a. M. Discrimination of sugarcane varieties using Landsat 7 ETM+ spectral data. **International Journal of Remote Sensing**, v. 27, n. September 2014, p. 1395–1412, 2006.
- FRASSON, F. R.; MOLIN, J. P.; POVH, F. P.; SALVI, J. V. Temporal Behavior of Ndvi Measured With an Active Optical Sensor for Different Varieties of Sugarcane. **BioEng**, v. 1, n. 3, p. 237–244, 2007.
- GALVÃO, L. S.; FORMAGGIO, A. R.; TISOT, D. A. Discrimination of sugarcane varieties in Southeastern Brazil with EO-1 Hyperion data. **Remote Sensing of Environment**, v. 94, n. 4, p. 523–534, 2005.
- GARRIDO, M.; PARAFOROS, D.; REISER, D.; VÁZQUEZ ARELLANO, M.; GRIEPENTROG, H.; VALERO, C. 3D Maize Plant Reconstruction Based on Georeferenced Overlapping LiDAR Point Clouds. **Remote Sensing**, v. 7, n. 12, p. 17077–17096, 2015.
- GEIPEL, J.; LINK, J.; CLAUPEIN, W. Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System. **Remote Sensing**, v. 6, n. 11, p. 10335–10355, 27 out. 2014.
- GERSTENECKER, C.; LÄUFER, G.; STEINECK, D.; TIEDE, C.; WROBEL, B. Validation of Digital Elevation Models around Merapi Volcano, Java, Indonesia. **Natural Hazards and Earth System Science**, v. 5, n. 6, p. 863–876, 8 nov. 2005.
- GIASSON, E.; HARTEMINK, A. E.; TORNQUIST, C. G.; TESKE, R.; BAGATINI, T. Avaliação de cinco algoritmos de árvores de decisão e três tipos de modelos digitais de elevação para mapeamento digital de solos a nível semidetalhado na Bacia do Lageado Grande, RS, Brasil. **Ciência Rural**, v. 43, n. 11, p. 1967–1973, nov. 2013.

- GOLDEMBERG, J.; MELLO, F. F. C.; CERRI, C. E. P.; DAVIES, C. A.; CERRI, C. C. Meeting the global demand for biofuels in 2021 through sustainable land use change policy. **Energy Policy**, v. 69, p. 14–18, jun. 2014.
- GÓMEZ-CANDÓN, D.; DE CASTRO, A. I.; LÓPEZ-GRANADOS, F. Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. **Precision Agriculture**, v. 15, n. 1, p. 44–56, 2014.
- GORGENS, E. B.; SILVA, A. G. P.; RODRIGUEZ, L. C. E. **Lidar: aplicações florestais**. CRV ed.1. 132p. 2014
- HARWIN, S.; LUCIEER, A.; OSBORN, J. The Impact of the Calibration Method on the Accuracy of Point Clouds Derived Using Unmanned Aerial Vehicle Multi-View Stereopsis. **Remote Sensing**, v. 7, n. 9, p. 11933–11953, 17 set. 2015.
- HERWITZ, S. .; JOHNSON, L. .; DUNAGAN, S. .; HIGGINS, R. .; SULLIVAN, D. .; ZHENG, J.; LOBITZ, B. .; LEUNG, J. .; GALLMEYER, B. .; AOYAGI, M.; SLYE, R. .; BRASS, J. . Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. **Computers and Electronics in Agriculture**, v. 44, n. 1, p. 49–61, 2004.
- HOFFMEISTER, D.; BOLTEN, A.; CURDT, C.; WALDHOFF, G.; BARETH, G. High resolution Crop Surface Models (CSM) and Crop Volume Models (CVM) on field level by terrestrial laser scanning. **SPIE Proceedings**, v. 7840, n. Cvm, p. 78400E–78400E–6, 2010.
- HOFFMEISTER, D.; WALDHOFF, G.; KORRES, W.; CURDT, C.; BARETH, G. Crop height variability detection in a single field by multi-temporal terrestrial laser scanning. **Precision Agriculture**, 2015.
- HOLMAN, F. H.; RICHE, A. B.; MICHALSKI, A.; CASTLE, M.; WOOSTER, M. J.; HAWKESFORD, M. J. High Throughput Field Phenotyping of Wheat Plant Height and Growth Rate in Field Plot Trials Using UAV Based Remote Sensing. 2016.
- HONKAVAARA, E.; SAARI, H.; KAIVOSOJA, J.; PÖLÖNEN, I.; HAKALA, T.; LITKEY, P.; MÄKYNEN, J.; PESONEN, L. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, v. 5, n. 10, p. 5006–5039, 2013.
- HUANG, Y. B.; THOMSON, S. J.; HOFFMANN, W. C.; LAN, Y. B.; FRITZ, B. K. Development and prospect of unmanned aerial vehicle technologies for agricultural production management. **International Journal of Agricultural and Biological Engineering**, v. 6, n. 3, p. 1–10, 2013.
- HUNT, E. R.; DEAN HIVELEY, W.; FUJIKAWA, S. J.; LINDEN, D. S.; DAUGHTRY, C. S. T.; MCCARTY, G. W. Acquisition of NIR-green-blue digital photographs from unmanned aircraft for crop monitoring. **Remote Sensing**, v. 2, n. 1, p. 290–305, 2010.
- IMMERZEEL, W. W.; KRAAIJENBRINK, P. D. A.; SHEA, J. M.; SHRESTHA, A. B.; PELLICCIOTTI, F.; BIERKENS, M. F. P.; DE JONG, S. M. High-resolution monitoring of Himalayan glacier dynamics using unmanned aerial vehicles. **Remote Sensing of Environment**, v. 150, p. 93–103, 2014.
- JENSEN, J. R. **Sensoriamento remoto do ambiente uma perspectiva em recursos terrestre**. 2. ed. Iguaba Grande: Parêntese Editora, 2009.

- JOHNSON, L.; HERWITZ, S. Collection of ultra high spatial and spectral resolution image data over California vineyards with a small UAV. **Proc. 30th International Symposium on Remote Sensing of Environment (ISRSE)**, n. Ccd, p. 3–5, 2003.
- JORGE, L. A. C.; BRANDÃO, Z. N.; INAMASU, R. Y. Insights and recommendations of use of UAV platforms in precision agriculture in Brazil. **Remote Sensing for Agriculture, Ecosystems, and Hydrology XVI**, v. 9239, n. 2004, p. 923911, 2014.
- JÚNIOR, A. L.; RODRIGUES, G. C.; NETO, J. C.; SILVA, F. C.; JORGE, L. A. de C. Estimativa da fração coberta do solo em canavial usando imagens aéreas obtidas por Vants . **Congresso Brasileiro de Agroinformática (SBIAGRO)**, 2015.
- LABBÉ, S.; ROUX, B.; BÉGUÉ, a; LEBOURGEOIS, V.; B MALLAVAN. An operational solution to acquire multispectral images with standard light cameras: Characterization and acquisition guidelines. **ISPRS Workshop Airborne Digital Photogrammetric Sensor Systems**, p. 1–6, 2007.
- LATI, R. N.; FILIN, S.; EIZENBERG, H. Estimating plant growth parameters using an energy minimization-based stereovision model. **Computers and Electronics in Agriculture**, v. 98, p. 260–271. 2013.
- LEBOURGEOIS, V.; BÉGUÉ, A.; LABBÉ, S.; MALLAVAN, B.; PRÉVOT, L.; ROUX, B. Can commercial digital cameras be used as multispectral sensors? A crop monitoring test. **Sensors**, v. 8, n. 11, p. 7300–7322, 2008.
- LEE-LOVICK, G.; KIRCHNER, L. Limitations of Landsat TM data in monitoring growth and predicting yields in sugarcane. **Proceedings of the Australian Society of Sugar Cane Technology**, v. 13, p. 124–129, 1991.
- LELONG, C. C. D.; BURGER, P.; JUBELIN, G.; ROUX, B.; LABBÉ, S.; BARET, F. Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots. **Sensors**, v. 8, n. 5, p. 3557–3585, 2008.
- LI, W.; NIU, Z.; CHEN, H.; LI, D.; WU, M.; ZHAO, W. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system. **Ecological Indicators**, v. 67, p. 637–648, 2016.
- LIN, Y.; HYYPPÄ, J.; JAAKKOLA, A. Mini-UAV-borne LIDAR for fine-scale mapping. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 3, p. 426–430, 2011.
- MADRID, R. C.; ANTONIO, J.; CORTÉS, N.; BORREGO, M. M.; BEATRIZ, B.; LEÓN, C. L.; JESÚS, P.; TEJADA, Z. Detection of Verticillium wilt of olive trees and downy mildew of opium poppy using hyperspectral and thermal UAV imagery. v. 16, p. 2014, 2014.
- MAGALHÃES, A. c. . Análise quantitativa do crescimento. In: FERRI, M. . (Ed.). **Fisiologia Vegetal**. 2. ed. São Paulo: EDUSP, 1985. p. 331–350.
- MAGALHÃES, P. S. G.; SANCHES, G. M.; MOLIN, J. P.; AMARAL, L. R.; KOLLN, O. T.; DUFT, D. G. Potential Solution to Contribute for Sugar Cane Spatial Variability Management. **EFITA-WCCA-CIGR Conference “Sustainable Agriculture through ICT Innovation”**, Turin, Italy, 2013, p. 24–27, 2013.

- MARAFON, A. C. **Análise quantitativa de crescimento em cana-de-açúcar : uma introdução ao procedimento prático**. Aracaju : Embrapa Tabuleiros Costeiros, 2012. 29 p. (Documentos / Embrapa Tabuleiros Costeiros, ISSN 1678-1953; 168).
- MARIN, F. R.; JONES, J. W. Process-based simple model for simulating sugarcane growth and production. **Scientia Agricola**, v. 71, n. 1, p. 1–16, 2014.
- MAROTTA, G. S.; CICERELLI, R. E.; FERREIRA, A. M. R.; ROIG, H. L.; ABREU, M. A. De. AVALIAÇÃO POSICIONAL DE MODELO DIGITAL DE SUPERFÍCIE DERIVADO DE CÂMARA DE PEQUENO FORMATO Positional Evaluation of Digital Super ficial Model Generated by Small Format Camera. **Revista Brasileira de Cartografia**, v. 67/7, p. 1467–1477, 2015.
- MARTELLO, M.; FIORIO, P. R.; TAVARES, T. R.; STRABELI, T. F. MONITORAMENTO DO CRESCIMENTO DE CANA-DE-AÇÚCAR POR MEIO DA MODELAGEM DIGITAL DO DOSSEL COM IMAGENS OBTIDAS COM RPA (DRONE). **Congresso Brasileiro de Agricultura de Precisão - ConBAP 2016**, 2016.
- MARTELLO, M.; FIORIO, P.R; VETTORAZZI, C.A; BARROS, P. P. da S.; TAVARES, T.R; SEIXAS, H.T Utilização de imagens aéreas obtidas por RPA no monitoramento inicial de Eucalyptus sp. **Simpósio Brasileiro de Sensoriamento Remoto**, 2015.
- MARTINS, J. A.; FIORIO, P. R.; BARROS, P. P. da S.; MUNIZ, R. de A.; TAMEIRÃO SEIXAS, H. Alterações na resposta espectral da cana-de-açúcar cultivada em diferentes condições edáficas. **XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa, 2015.
- MARTINS, L. M.; LANDELL, M. G. de A. **Conceitos e critérios para avaliação experimental em cana-de-açúcar utilizados no programa cana iac**. Campinas: Pindorama: Instituto Agrônômico - IAC, 1995.
- MEDEIROS, F. A.; AIRTON, I.; SANTOS, D.; II, A.; REGINA, M.; BALESTRA, G.; VILNEI DE OLIVEIRA, I.; II, D.; LUIZ, M.; JÚNIOR, L. Utilização de um veículo aéreo não-tripulado em atividades de imageamento georeferenciado. **Ciência Rural**, v. 38, n. 8, p. 2375–2378, 2008.
- MENDONÇA JÚNIOR, M. G.; MITISHITA, E. A. Emprego do método Z-Buffer modificado na detecção de oclusões de edificações para geração de ortoimagens verdadeiras. **Boletim de Ciências Geodésicas**, v. 17, n. 1, p. 93–114, mar. 2011.
- MILTON, E. J. Low-cost ground-based digital infra-red photography. n. February 2015, p. 37–41, 2002.
- MIPHOKASAP, P.; HONDA, K.; VAIPHASA, C.; SOURIS, M.; NAGAI, M. Estimating canopy nitrogen concentration in sugarcane using field imaging spectroscopy. **Remote Sensing**, v. 4, n. 6, p. 1651–1670, 2012.
- MOLIN, J. P.; FRASSON, F. R.; AMARAL, L. R. Do; POVH, F. P.; SALVI, J. V. Capacidade de um sensor ótico em quantificar a resposta da cana-de-açúcar a doses de nitrogênio Capability of an optical sensor in verifying the sugarcane response to nitrogen rates. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 12, p. 1345–1349, 2010.
- MOLIN, P.; VEIGA, P. S. Spatial variability of sugarcane row gaps : measurement and mapping. v. 40, n. 3, p. 347–356, 2016.

- MONTES, J. M.; TECHNOW, F.; DHILLON, B. S.; MAUCH, F.; MELCHINGER, A. E. High-throughput non-destructive biomass determination during early plant development in maize under field conditions. **Field Crops Research**, v. 121, n. 2, p. 268–273, 2011.
- MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, 2013.
- NEX, F.; REMONDINO, F. UAV for 3D mapping applications: A review. **Applied Geomatics**, v. 6, n. 1, p. 1–15, 2014.
- NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Blucher, 2010.
- OLIVEIRA, R. A. de; TOMMASELLI, A. M. G. Avaliação de uma técnica para geração de modelos digitais de superfície utilizando múltiplas imagens. **Boletim de Ciências Geodésicas**, v. 20, n. 2, p. 257–278, jun. 2014.
- PACHECO, A. da P.; CENTENO, J. A. S.; ASSUNÇÃO, M. G. T. de; BOTELHO, M. F. Classificação de pontos LIDAR para a geração do MDT. **Boletim de Ciências Geodésicas**, v. 17, n. 3, p. 471–438, set. 2011.
- PERIN, G.; GERKE, T.; LACERDA, V. S.; ZUBEK DA ROSA, J.; CAIRES, E. F.; GUIMARÃES, A. M. Análise de Acurácia de Georreferenciamento de Mosaicos de Imagens Obtidas por RPA. **Anais do EATI - Encontro Anual de Tecnologia da Informação e STIN – Simpósio de Tecnologia da Informação da Região Noroeste do RS 193**, p. 193–199, 2016.
- PETACH, A. R.; TOOMEY, M.; AUBRECHT, D. M.; RICHARDSON, A. D. Monitoring vegetation phenology using an infrared-enabled security camera. **Agricultural and Forest Meteorology**, v. 195–196, p. 143–151, 2014.
- PORTZ, G.; AMARAL, L. R.; MOLIN, J. P. Measuring Sugarcane Height in Complement To Biomass Sensor for Nitrogen Management. n. March 2016, p. 9, 2012a.
- PORTZ, G.; AMARAL, L. R.; MOLIN, J. P. Optimum Sugarcane Growth Stage for Canopy Reflectance Sensor To Predict Biomass and Nitrogen Uptake. **11th International Conference on Precision Agriculture**, n. March 2016, p. 11, 2012b.
- PORTZ, G.; DO AMARAL, L. R.; MOLIN, J. P.; ADAMCHUK, V. Field comparison of ultrasonic and canopy reflectance sensors used to estimate biomass and N-uptake in sugarcane. 2013a.
- PORTZ, G.; MOLIN, J. P.; JASPER, J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields. **Precision Agriculture**, v. 13, n. 1, p. 33–44, 2012.
- POSSOCH, M.; BIEKER, S.; HOFFMEISTER, D.; BOLTEN, A.; SCHELLBERG, J.; BARETH, G.; CONSERVATION, R.; GROUP, C. S.; CONSERVATION, R.; ECOLOGY, P.; MODEL, C. S. Multi-Temporal Crop Surface Models Combined With the Rgb Vegetation Index From Uav-Based Images for Forage Monitoring in Grassland. n. July, 2015.
- QUEMADA, M.; GABRIEL, J.; ZARCO-TEJADA, P. Airborne Hyperspectral Images and Ground-Level Optical Sensors As Assessment Tools for Maize Nitrogen Fertilization. **Remote Sensing**, v. 6, n. 4, p. 2940–2962, 31 mar. 2014.

- RISTORTO, G.; MAZZETTO, F.; GUGLIERI, G.; QUAGLIOTTI, F. Monitoring performances and cost estimation of multicopter Unmanned Aerial Systems in precision farming. In: 2015 International Conference on Unmanned Aircraft Systems (ICUAS), **Anais...IEEE**, jun. 2015.
- ROIG, H. L.; FERREIRA, A. M. R.; MENEZES, P. H. B. .; MAROTTA, G. S. Uso de câmeras de baixo custo acopladas a veículos aéreos leves no estudo do aporte de sedimentos no Lago Paranoá. In: Simpósio Brasileiro de Sensoriamento Remoto, Foz do Iguaçu. **Simpósio Brasileiro de Sensoriamento Remoto** Foz do Iguaçu: INPE, 2013.
- ROKHMANA, C. A. The Potential of UAV-based Remote Sensing for Supporting Precision Agriculture in Indonesia. **Procedia Environmental Sciences**, v. 24, p. 245–253, 2015.
- ROSA, H. J. A.; DO AMARAL, L. R.; MOLIN, J. P.; CANTARELLA, H. Sugarcane response to nitrogen rates, measured by a canopy reflectance sensor. **Pesquisa Agropecuaria Brasileira**, v. 50, n. 9, p. 840–848, 2015.
- ROSA, R. **Introdução ao sensoriamento remoto**. 7. ed. Uberlândia: EDUFU, 2009.
- ROSNELL, T.; HONKAVAARA, E. Point Cloud Generation from Aerial Image Data Acquired by a Quadcopter Type Micro Unmanned Aerial Vehicle and a Digital Still Camera. **Sensors (Basel, Switzerland)**, v. 12, n. 1, p. 453–80, 4 jan. 2012.
- RYAN, J. C.; HUBBARD, a. L.; BOX, J. E.; TODD, J.; CHRISTOFFERSEN, P.; CARR, J. R.; HOLT, T. O.; SNOOKE, N. UAV photogrammetry and structure from motion to assess calving dynamics at Store Glacier, a large outlet draining the Greenland ice sheet. **The Cryosphere**, v. 9, n. 1, p. 1–11, 2015.
- SANKARAN, S.; KHOT, L. R.; ESPINOZA, C. Z.; JAROLMASJED, S.; SATHUVALLI, V. R.; VANDEMARK, G. J.; MIKLAS, P. N.; CARTER, A. H.; PUMPHREY, M. O.; KNOWLES, R. R. N.; PAVEK, M. J. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. **European Journal of Agronomy**, v. 70, n. March, p. 112–123, 2015.
- SANTANA, M. S. De; OLIVEIRA, F. J. De; MELO, L. J. O. T. De. Correlações genéticas em alguns clones RB e em variedades de cana-de-açúcar. **Revista Brasileira de Ciências Agrárias**, v. 5, n. 4, p. 460–467, 2010.
- SANTESTEBAN, L. G.; DI GENNARO, S. F.; HERRERO-LANGREO, A.; MIRANDA, C.; ROYO, J. B.; MATESE, A. High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. **Agricultural Water Management**, v. 183, p. 49–59, 2017.
- SCOTFORD, I. M.; MILLER, P. C. H. Combination of Spectral Reflectance and Ultrasonic Sensing to monitor the Growth of Winter Wheat. **Biosystems Engineering**, v. 87, n. 1, p. 27–38, 2004.
- SHI, Y.; THOMASSON, J. A.; MURRAY, S. C.; PUGH, N. A.; ROONEY, W. L.; SHAFIAN, S.; RAJAN, N.; ROUZE, G.; MORGAN, C. L. S.; NEELY, H. L.; RANA, A.; BAGAVATHIANNAN, M. V.; HENRICKSON, J.; BOWDEN, E.; VALASEK, J.; OLSENHOLLER, J.; BISHOP, M. P.; SHERIDAN, R.; PUTMAN, E. B.; POPESCU, S.; BURKS, T.; COPE, D.; IBRAHIM, A.; MCCUTCHEN, B. F.; BALTENSBERGER, D. D.; AVANT, R. V.; VIDRINE, M.; YANG, C.; YANG, C. Unmanned Aerial Vehicles for High-Throughput Phenotyping and Agronomic Research. **PloS one**, v. 11, n. 7, p. e0159781, 2016.

- SHI, Y.; WANG, N.; TAYLOR, R. K.; RAUN, W. R. Improvement of a ground-LiDAR-based corn plant population and spacing measurement system. **Computers and Electronics in Agriculture**, n. February 2016, 2014.
- SHI, Y.; WANG, N.; TAYLOR, R. K.; RAUN, W. R.; HARDIN, J. A. Automatic corn plant location and spacing measurement using laser line-scan technique. **Precision Agriculture**, v. 14, n. 5, p. 478–494, 2013.
- SILVA, C. B.; DE MORAES, M. A. F. D.; MOLIN, J. P. Adoption and use of precision agriculture technologies in the sugarcane industry of São Paulo state, Brazil. **Precision Agriculture**, v. 12, n. 1, p. 67–81, 2011.
- SILVA, M. de A.; JERONIMO, E. M.; LÚCIO, A. D. Perfilhamento e produtividade de cana-de-açúcar com diferentes alturas de corte e épocas de colheita. **Pesquisa Agropecuária Brasileira**, v. 43, n. 8, p. 979–986, ago. 2008.
- SILVA, C. A. da; DUARTE, C. R.; SOUTO, M. V. S.; SANTOS, A. L. S. Dos; AMARO, V. E.; BICHO, C. P.; SABADIA, J. A. B.; SILVA, C. A. da; DUARTE, C. R.; SOUTO, M. V. S.; SANTOS, A. L. S. Dos; AMARO, V. E.; BICHO, C. P.; SABADIA, J. A. B. AVALIAÇÃO DA ACURÁCIA DO CÁLCULO DE VOLUME DE PILHAS DE REJEITO UTILIZANDO VANT, GNSS E LiDAR. **Boletim de Ciências Geodésicas**, v. 22, n. 1, p. 73–94, mar. 2016.
- SILVA, F. L. Da; PEDROZO, C. Â.; BARBOSA, M. H. P.; RESENDE, M. D. V. De; PETERNELLI, L. A.; COSTA, P. M. D. A.; VIEIRA, M. S. Análise de trilha para os componentes de produção de cana-de-açúcar via blup. **Ceres**, v. 56, n. 3, p. 308–314, 2009.
- SOUZA JUNIOR, M. D.; DOS SANTOS, M. L.; SALAMUNI, E.; STEVAUX, J. C.; MORALES, N. ANÁLISE MORFOTECTÔNICA DA BACIA HIDROGRÁFICA DO RIO IVAÍ-PR, CURSO INFERIOR. **Revista Brasileira de Geomorfologia**, v. 14, n. 2, 21 mar. 2014.
- STOLF, R. Metodologia de avaliação de falhas nas linhas de cana-de-açúcar. **STAB**, v. 4, n. 6, p. 22–36, 1986.
- SU, T.-C.; CHOU, H.-T. Application of Multispectral Sensors Carried on Unmanned Aerial Vehicle (UAV) to Trophic State Mapping of Small Reservoirs: A Case Study of Tain-Pu Reservoir in Kinmen, Taiwan. **Remote Sensing**, v. 7, n. 8, p. 10078–10097, 7 ago. 2015.
- TAVARES, T. R.; FIORIO, P. R.; MARTELLO, M.; STRABELI, T. F.; GUARDIA, J.; BRUSCAGIN, M. Sensor hiperespectral passivo para diferenciação de doses de nitrogênio em cana-de-açúcar. In: **Simpósio Brasileiro de Sensoriamento Remoto** 2015.
- TERUEL, D. A.; BARBIERI, V.; FERRARO JR., L. A. Sugarcane leaf area index modeling under different soil water conditions. **Scientia Agricola**, v. 54, n. SPE, p. 39–44, 1997.
- TILLY, N.; HOFFMEISTER, D.; CAO, Q.; HUANG, S.; LENZ-WIEDEMANN, V.; MIAO, Y.; BARETH, G. Multitemporal crop surface models: accurate plant height measurement and biomass estimation with terrestrial laser scanning in paddy rice. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 83671, 6 mar. 2014.
- TONKIN, T. N.; MIDGLEY, N. G.; GRAHAM, D. J.; LABADZ, J. C. The potential of small unmanned aircraft systems and structure-from-motion for topographic surveys: A test of emerging integrated approaches at Cwm Idwal, North Wales. **Geomorphology**, v. 226, p. 35–43, 2014.

- TORRES-SÁNCHEZ, J.; LÓPEZ-GRANADOS, F.; PEÑA, J. M. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. **Computers and Electronics in Agriculture**, v. 114, p. 43–52, 2015.
- TULLDAHL, H. M.; BISSMARCK, F.; LARSSON, H.; GRÖNWALL, C.; TOLT, G. Accuracy evaluation of 3D lidar data from small UAV. **Proc. SPIE**, v. 9649, p. 964903, 2015.
- TURNER, D.; LUCIEER, A.; WATSON, C. An Automated Technique for Generating Georectified Mosaics from Ultra-High Resolution Unmanned Aerial Vehicle (UAV) Imagery, Based on Structure from Motion (SfM) Point Clouds. **Remote Sensing**, v. 4, n. 12, p. 1392–1410, 14 maio 2012.
- VERHOEVEN, G. Archaeological Three-dimensional Reconstructions from Aerial Photographs with PhotoScan. **Archaeological Prospection**, v. 19, n. 2, p. 103–121, 2012.
- WALLACE, L.; LUCIEER, A.; MALENOVSKÝ, Z.; TURNER, D.; VOPĚNKA, P. Assessment of Forest Structure Using Two UAV Techniques: A Comparison of Airborne Laser Scanning and Structure from Motion (SfM) Point Clouds. **Forests**, v. 7, n. 3, p. 62, 2016.
- WALTER, A.; GALDOS, M. V.; SCARPARE, F. V.; LEAL, M. R. L. V.; SEABRA, J. E. A.; DA CUNHA, M. P.; PICOLI, M. C. A.; DE OLIVEIRA, C. O. F. Brazilian Sugarcane Ethanol: Developments so Far and Challenges for the Future. **Wiley Interdisciplinary Reviews: Energy and Environment**, v. 3, n. 1, p. 70–92, 22 jan. 2014.
- WISE, S. Assessing the quality for hydrological applications of digital elevation models derived from contours. **Hydrological Processes**, v. 14, n. 11–12, p. 1909–1929, 15 ago. 2000.
- YANG, X.; ZHOU, Q.; MELVILLE, M. Estimating local sugarcane evapotranspiration using Landsat TM image and a VITT concept. **International Journal of Remote Sensing**, v. 18, n. 2, p. 453–459, 1997.
- ZARCO-TEJADA, P. J.; GONZÁLEZ-DUGO, V.; BERNI, J. a J. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. **Remote Sensing of Environment**, v. 117, p. 322–337, 2012.