

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

CURSO DE AGRONOMIA

MATHEUS GABRIEL ACORSI

**MODELAGEM DA PRODUÇÃO DE BIOMASSA DA AVEIA PRETA
(*Avena strigosa* Schreb.) ATRAVÉS DE IMAGENS OBTIDAS POR
AERONAVE REMOTAMENTE PILOTADA**

TRABALHO DE CONCLUSÃO DE CURSO

DOIS VIZINHOS

2017

MATHEUS GABRIEL ACORSI

**MODELAGEM DA PRODUÇÃO DE BIOMASSA DA AVEIA PRETA
(*Avena strigosa* Schreb.) ATRAVÉS DE IMAGENS OBTIDAS POR
AERONAVE REMOTAMENTE PILOTADA**

Trabalho de Conclusão de Curso, apresentado à disciplina de Trabalho de conclusão de curso II, do Curso Superior de Agronomia, da Universidade Tecnológica Federal do Paraná - UTFPR, como requisito parcial para obtenção do Título de Engenheiro Agrônomo.

Orientador: Prof. Dra. Fabiani D. A. Miranda
Co-orientador: Prof. Msc. Maurício Martello

DOIS VIZINHOS

2017



TERMO DE APROVAÇÃO

MODELAGEM DA PRODUÇÃO DE BIOMASSA DA AVEIA PRETA (*Avena strigosa* Schreb.) ATRAVÉS DE IMAGENS OBTIDAS POR AERONAVE REMOTAMENTE PILOTADA

por

MATHEUS GABRIEL ACORSI

Este Trabalho de Conclusão de Curso (TCC) foi apresentado em 1 (um) de dezembro de 2017 como requisito parcial para a obtenção do título de Engenheiro Agrônomo. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Fabiani das Dores Abati Miranda
Prof. Orientadora
UTFPR – Dois Vizinhos

Raoni Wainer Duarte Bosquilia
Membro titular
UTFPR – Dois Vizinhos

Laercio Ricardo Sartor
Membro titular
UTFPR – Dois Vizinhos

Angélica Signor Mendes
Responsável pelos Trabalhos
de Conclusão de Curso

Lucas da Silva Domingues
Coordenador do Curso
UTFPR – Dois Vizinhos

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso -

RESUMO

ACORSI, M. G. **Modelagem da produção de biomassa da aveia preta (*Avena strigosa* Schreb.) através de imagens obtidas por Aeronave Remotamente Pilotada.** 2017. 58 f. Trabalho de conclusão de curso de graduação. Universidade Tecnológica Federal do Paraná. Dois Vizinhos, 2017.

O monitoramento agrícola torna-se um fator determinante quando o objetivo é o aumento da produtividade e rentabilidade de uma cultura. Atualmente uma das técnicas mais empregadas para o monitoramento é o Sensoriamento Remoto. A partir da utilização de imagens, é possível obter estimativa da produtividade, realizar o controle de doenças e pragas, além de avaliar a necessidade hídrica de plantas, fornecendo, portanto, importantes subsídios à tomada de decisões. É nesse contexto que a utilização das Aeronaves Remotamente Pilotadas (RPAS) surge como uma importante opção, dada a notável capacidade destas plataformas em fornecer dados com a mais alta resolução espacial e temporal, permitindo um Sensoriamento Remoto mais efetivo em aplicações de escala reduzida, como é caso da agricultura. Nesse sentido, o objetivo deste trabalho foi avaliar a potencialidade da utilização de imagens adquiridas através uma plataforma RPAS para obtenção de modelos tridimensionais representando o dossel da cultura da aveia preta. A partir destes modelos, foram estimadas a altura de plantas, acúmulo de matéria verde e acúmulo de matéria seca, evidenciando a variabilidade espacial destes atributos. Para coleta de dados, foi avaliado um experimento situado na Universidade Tecnológica Federal do Paraná (UTFPR), câmpus Dois Vizinhos. As coletas ocorreram entre os meses de julho e agosto de 2017, onde foi utilizada uma plataforma RPAS com sensor RGB a bordo. O planejamento do voo foi realizado em um aplicativo para *smartphone*, em que foi definida uma taxa de recobrimento lateral e longitudinal entre as imagens de 90 % e altura de voo em 25 m. A partir destas informações, juntamente com o sistema de navegação global (GNSS) existente no equipamento, os voos foram realizados de forma autônoma. Após o processamento das imagens, foram obtidos modelos digitais de superfície (MDS) com resolução espacial de 1,8 cm.pixel⁻¹, devidamente associados a pontos de controle materializados nos vértices do experimento, o que garantiu a precisão posicional dos dados. Em paralelo, foram coletados dados à campo, onde foram mensuradas a altura de plantas, produção de matéria verde e de matéria seca, para cada uma das parcelas avaliadas. Juntamente com o banco de dados proveniente do RPAS, uma série de análises regressões foram realizadas, em que foram obtidos modelos matemáticos para estimar as variáveis de interesse. Como resultado, obteve-se um R² entre 0,77 e 0,91 entre a altura de plantas derivada do RPAS e altura de plantas mensurada a campo. Já a análise referente a produção de biomassa, resultou em um R² entre 0,64 e 0,94 para as diferentes coletas, com um erro relativo inferior a 17%. Os modelos aqui obtidos demonstraram a alta potencialidade do uso de RPAS como forma de estimar a altura de plantas e produção de biomassa para a cultura da aveia preta, permitindo que a ferramenta seja utilizada no monitoramento destas áreas, fornecendo um importante subsídio a tomada de decisões.

Palavras chave: Agricultura de Precisão; Biomassa vegetal; Sensoriamento Remoto.

ABSTRACT

ACORSI, M. G. **Estimating biomass of black oats (*Avena strigosa* Schreb.) using Remotely Piloted Aircraft imagery.** 2017. 58 f. Trabalho de conclusão de curso de graduação. Universidade Tecnológica Federal do Paraná. Dois Vizinhos, 2017.

Agricultural monitoring becomes a determining factor when the goal is to increase the productivity and profitability of a crop. Currently one of the most used techniques for monitoring agricultural areas is Remote Sensing. From the use of images, it is possible to obtain estimates of productivity, control diseases and pests, and evaluate the water requirement of plants, thus providing important subsidies to decision making. It is in this context that the use of Remotely Piloted Aircraft System (RPAS) emerges as an important option, given the remarkable capacity of these platforms to provide data with the highest spatial and temporal resolution, allowing a more effective Remote Sensing in small scale applications, such as agriculture. In this sense, the objective of this work was to evaluate the potential of using images acquired through a RPAS platform to obtain three dimensional models representing the canopy of the black oat crop. From these models, plant height, fresh biomass and dry biomass were estimated, evidencing the spatial variability of these attributes. For data collection, a test site was evaluated at the Universidade Tecnológica Federal do Paraná (UTFPR), Dois Vizinhos campus. The collections occurred between July and August of 2017, where a RPAS platform with RGB sensor was used on board. Flight planning was carried out in a smartphone application, where a lateral and longitudinal overlap between images of 90 % was defined, flight height at 25 meters, and the delimitation of the area to be covered. From this information, along with the global navigation system (GNSS) receiver in the equipment, the flights were realized in an autonomously . After the image processing, digital surface models (MDS) with spatial resolution of $1.8 \text{ cm} \cdot \text{pixel}^{-1}$ were obtained, duly associated to control points in the field, which ensured the positional accuracy of the data. In parallel, data were collected in the field, where the height of plants, fresh matter and dry matter production were measured for each of the plots evaluated. Along with the database from the RPAS, a series of regression analyzes were performed, in which mathematical models were obtained to estimate the variables studied. As a result, R^2 was obtained between 0.77 and 0.91 for plant height derived from RPAS and height of plants measured in the field. On the other hand, the analysis of biomass production resulted in a R^2 between 0.64 and 0.94 for the different missions, with a relative error of less than 17%. The models obtained here demonstrated the high potential of the use of RPAS as a way of estimating plant height and biomass production for black oats, allowing the tool to be used in the monitoring of these areas, providing an important contribution to decision making.

Keywords: Precision Agriculture; Vegetal biomass; Remote Sensing.

SUMÁRIO

| | |
|---|-----------|
| 1 INTRODUÇÃO | 5 |
| 2. OBJETIVOS | 7 |
| 2.1 OBJETIVO GERAL | 7 |
| 2.2 OBJETIVOS ESPECÍFICOS | 7 |
| 3 REVISÃO DE LITERATURA | 8 |
| 3.1 SENSORIAMENTO REMOTO | 8 |
| 3.2 PLATAFORMAS DE SENSORIAMENTO REMOTO | 9 |
| 3.3 SISTEMAS DE AERONAVES REMOTAMENTE PILOTADAS E SUAS APLICAÇÕES NA AGRICULTURA..... | 10 |
| 3.4 MODELAGEM DA ALTURA E BIOMASSA DOS CULTIVOS | 14 |
| 4 MATERIAL E MÉTODOS | 18 |
| 4.1 ÁREA DE ESTUDO | 18 |
| 4.2 PLATAFORMA RPAS E SENSOR UTILIZADO | 19 |
| 4.3 COLETA DE DADOS..... | 21 |
| 4.3.1 Coleta de dados através do RPAS | 22 |
| 4.3.1.1 Plano de voo | 23 |
| 4.3.1.2 Pontos de controle | 25 |
| 4.3.2 Coleta de dados à campo | 27 |
| 4.4 PROCESSAMENTO DOS DADOS | 29 |
| 4.4.1 Processamento das imagens | 29 |
| 4.4.2 Procedimentos em ambiente SIG..... | 33 |
| 4.5 ANÁLISE ESTATÍSTICA..... | 34 |
| 5 RESULTADOS E DISCUSSÃO | 36 |
| 5.1 PRODUTOS FOTOGRAMÉTRICOS OBTIDOS..... | 36 |
| 5.2 ANÁLISE DE REGRESSÃO..... | 38 |
| 5.2.1 Altura de plantas | 38 |
| 5.2.3 Produtividade de matéria verde..... | 41 |
| 5.2.4 Produtividade de matéria seca | 46 |
| 5.3 MAPAS DE PRODUTIVIDADE | 51 |
| 6 CONCLUSÕES | 53 |
| 7 CONSIDERAÇÕES FINAIS | 54 |
| 8 REFERÊNCIAS | 55 |

1 INTRODUÇÃO

A agricultura desempenha um papel primordial na economia do Brasil, colocando o país entre os maiores produtores mundiais. Dentro deste setor, a escalada na produção de cereais ganha destaque, fato atrelado as grandes transformações ocorridas nos sistemas de produção nos últimos anos, em que se observa um crescente emprego de novas tecnologias, visando um incremento na produtividade e a redução nos custos de produção.

Uma das principais tecnologias que impulsionam o setor é a Agricultura de Precisão, a qual utiliza abordagens científicas modernas, combinadas com os conhecimentos tradicionais e tecnologias de informação, proporcionando uma produção agrícola inteligente, com maior rentabilidade, produtividade e sustentabilidade (SHIRATSUCHI et al., 2014). Nesse contexto, as técnicas de Sensoriamento Remoto tornam-se fundamentais, permitindo um monitoramento agrícola mais eficiente e menos subjetivo, além de facilitar uma série de diagnósticos, como a avaliação nutricional, detecção de pragas e doenças, estimativa da produtividade e avaliação da necessidade hídrica de cultivos.

Contudo, algumas limitações inerentes ao Sensoriamento Remoto por meio de imagens de satélites podem limitar a sua utilização no âmbito agrícola, onde altas resoluções espaciais e altas periodicidades são exigidas para que a variabilidade espacial dos fatores que influenciam no desenvolvimento dos cultivos seja monitorada (CAMPBELL AND WYNNE, 2011).

É neste cenário que as plataformas RPAS (Sistemas Aeronaves Remotamente Pilotadas), popularmente conhecidas como *drones*, surgem como uma alternativa promissora em estudos de menor escala, oferecendo uma série de vantagens perante a plataforma orbital. O principal ganho se dá pela maior flexibilidade dos RPAS, que por um menor custo, permitem a aquisição de imagens diárias com alto nível de detalhamento (EISENBEISS 2009; SILVA 2013).

A inserção dos RPAS no mercado ampliou os horizontes de aplicação, não somente na Agricultura, mas no âmbito da engenharia como um todo. A possibilidade

de se obter modelos tridimensionais altamente detalhados, que quando calibrados, permitem a tomada de medidas acuradas, tornaram a ferramenta ainda mais completa. Através deste conceito, diversas pesquisas veem sendo realizadas avaliando a possibilidade de se utilizar os Modelos Digitais de Elevação obtidos por meio de imagens coletadas por RPAS como forma de estimar a altura de plantas em diversas culturas. Tal interesse é explicado pela possibilidade de prever a produção de biomassa dos cultivos através da altura de plantas, dada a alta correlação existente entre estas variáveis (BUSEMEYER et al., 2013).

A estimativa da produção de biomassa através de dados provenientes de RPAS já apresentou resultados satisfatórios para as culturas do trigo, cevada, arroz e pastagens (SHIRRMANN et al., 2016; BENDIG et al., 2014; BENDIG et al., 2013; POSSOCH et al., 2016), permitindo que a biomassa fosse estimada de forma não destrutiva, além de evidenciar a variabilidade espacial da produtividade nas áreas avaliadas.

Uma cultura que, por apresentar características similares às espécies já avaliadas, pode se beneficiar desta técnica é a aveia preta (*Avena strigosa* Schreb.), espécie amplamente difundida no sul do Brasil. Sua dupla aptidão, utilizada tanto como forrageira na pecuária, ou planta de cobertura no Sistema Plantio Direto (SPD), faz com que o cultivo da aveia preta seja mais expressivo, tendo como principal objetivo o acúmulo de biomassa, o que torna o dimensionamento deste atributo primordial.

2. OBJETIVOS

2.1 OBJETIVO GERAL

Avaliar a potencialidade da utilização de imagens obtidas por RPAS na estimativa da biomassa produzida pela cultura da aveia preta.

2.2 OBJETIVOS ESPECÍFICOS

Comparar os resultados obtidos através da plataforma RPAS com os dados mensurados a campo;

Apontar o momento mais adequado para estimar a produção de biomassa da cultura através de imagens obtidas por RPAS;

Elaborar mapas de produtividade com o banco de dados obtido no presente estudo.

3 REVISÃO DE LITERATURA

3.1 SENSORIAMENTO REMOTO

O Sensoriamento Remoto é definido como tecnologia capaz de obter imagens e outros tipos de dados da superfície terrestre, através da captação e do registro da energia refletida ou emitida pela superfície. O termo Sensoriamento remete à obtenção de dados por meio de sensores instalados em plataformas terrestres, aéreas e orbitais (satélites artificiais). O termo Remoto, significa distante, é utilizado visto que a obtenção de dados é feita à distância, ou seja, sem contato físico entre o sensor e objetos da superfície terrestre (FLORENZANO, 2011).

Ainda com relação aos sensores utilizados pelo Sensoriamento Remoto, estes são caracterizados de acordo com suas resoluções em diferentes parâmetros. A resolução espacial remete a proporção de área representada por um pixel da imagem no terreno, ou seja, o seu nível de detalhamento. Já a resolução temporal, remete ao período necessário para que a mesma área seja imageada novamente, ou seja, a periodicidade dos dados. A resolução radiométrica refere-se à sensibilidade do sensor, isto é, a sua habilidade em detectar pequenas variações de energia, sendo este parâmetro determinado pelo número de *bits* do sensor. Por fim, a resolução espectral, que é relativa aos intervalos do espectro eletromagnético captados pelo sensor, por exemplo, o infravermelho próximo, que contempla os comprimentos de onda entre 0,7 e 1,2 μm . (MENESES, 2012)

Os produtos do Sensoriamento Remoto apresentam um grande potencial para serem utilizados na agricultura. Através desta técnica, é possível obter informações sobre: estimativa de área plantada, produção agrícola, vigor vegetativo das culturas, além de fornecer subsídios para o manejo agrícola em diferentes escalas, abrangendo desde pequenas propriedades até o país como um todo (MOREIRA e RUDORFF, 2002).

3.2 PLATAFORMAS DE SENSORIAMENTO REMOTO

As plataformas de Sensoriamento Remoto são definidas de acordo com a distância do sensor em relação à superfície da Terra, pressupondo 3 classes: orbital (sensores a bordo de satélites artificiais), aéreo (sensores a bordo de aeronaves) e terrestre (campo ou laboratório) (FLORENZANO, 2011). Obviamente, cada plataforma apresenta uma série de vantagens e desvantagens, as quais devem ser levadas em consideração de acordo com o propósito do estudo, juntamente com as características inerentes aos sensores.

A plataforma orbital, composta por sensores embarcados em satélites artificiais, marcou um dos maiores avanços tecnológicos já presenciados pela humanidade, especialmente quando comparado ao método antecessor de aquisição de imagens, as fotos aéreas. Dentre outras vantagens, é notória a capacidade de imagear em curto espaço de tempo toda a superfície do planeta, de maneira sistemática, visto que um satélite fica continuamente orbitando à Terra, permitindo detectar e monitorar mudanças na superfície terrestre em qualquer área do planeta (MENESES, 2012).

Além disso, os sensores imageadores presentes nestas plataformas são extremamente avançados, podendo ser de caráter passivo, isto é, registram a energia eletromagnética refletida ou emitida pela superfície terrestre, ou ainda, de imageamento ativo, emitindo e recebendo a radiação a partir de seu próprio sensor, a exemplo do sistema radar. Tais sensores avançaram a medida que as plataformas orbitais foram se consolidando, havendo constantes aprimoramentos, principalmente em termos de resolução espectral e espacial, o que permite uma melhor caracterização e identificação de diferentes alvos, bem como, um maior grau de detalhamento das imagens produzidas (BLASCHKE e KUX, 2007).

Porém, o uso desta plataforma é limitado quando se trata de estudos envolvendo pequenas porções de área, a exemplo da Agricultura de Precisão, onde são demandadas altíssimas resoluções espaciais com alta periodicidade, algo que as plataformas orbitais atuais não são capazes de oferecer (MATESE et al., 2015).

Já as plataformas terrestres, são aquelas que se deslocam na superfície do terreno, utilizadas quando se objetiva fazer medições a curta distância do alvo, a fim de minimizar o efeito que a atmosfera possa ter sobre a qualidade dos dados. Essa

modalidade é muito empregada para fins científicos, utilizando-se principalmente de sistemas radiométricos de campo, capazes de mensurar com alta precisão as variações da reflectância ao longo do espectro. Esses dados são muito importantes quando se objetiva a caracterização espectral de um alvo em específico, ou ainda, para fins de calibração de dados coletados por sensores a bordo de aeronaves ou satélites (SILVA, 2013).

Nas plataformas aéreas, os sensores estão acoplados a aeronaves, helicópteros, ou mais recentemente, a RPAS (*Remotely Piloted Aircraft System*), tendo como grande vantagem o maior detalhamento dos dados em termos de resolução espacial em comparação a plataformas orbitais, além da maior flexibilidade na aquisição de imagens e redução da influência atmosférica sob a qualidade dos dados.

Entretanto, o elevado custo financeiro pode ser um entrave na escolha desta plataforma, principalmente quando se trata de aerolevantamentos executados por aviões. Nesse sentido, o uso de RPAS veem se tornando cada vez mais recorrente, dadas as inúmeras vantagens deste tipo de aeronave perante as demais. Além do menor custo na aquisição das imagens, os RPAS são mais adequados em estudos de menor escala, porém a sua capacidade limitada de carga e curto tempo de voo são fatores que devem ser considerados, capazes de inviabilizar o seu uso em determinadas situações (MATESE et al., 2015).

3.3 SISTEMAS DE AERONAVES REMOTAMENTE PILOTADAS E SUAS APLICAÇÕES NA AGRICULTURA

Oficialmente nomeado pela *International Civil Aviation Organization*, os RPAS foram introduzidos no mercado da Fotogrametria apresentando inúmeras vantagens a um custo reduzido, o que democratizou o uso desta ferramenta para os mais diversos fins. Dotados de câmeras compactas e diversos outros sensores, estes equipamentos são capazes de fornecer produtos com qualidade e precisão compatíveis com as demandas do setor, fato evidenciado pelos inúmeros estudos

desenvolvidos, que visam validar o uso desta ferramenta, bem como, encontrar novas aplicações para esta tecnologia (MOUTINHO, 2015).

No setor agrícola, a utilização de RPAS surge como uma importante opção, especialmente quando se trata de Agricultura de Precisão, dada a capacidade destes dispositivos em fornecer dados com a mais alta periodicidade, e resolução espacial compatível com o monitoramento detalhado dos cultivos (SHIRMMANN et al., 2016).

Os dois modelos de RPAS mais utilizados na aerofotogrametria são os multirotores e os de asas fixas (Figura 1). Ambos são utilizados em levantamentos aerofotogramétricos, cada um com suas peculiaridades de acordo com a arquitetura adotada.

Figura 1 – Modelos de RPAS



Fonte: Model air plane news (2015).

Os multirotores são os mais populares, especialmente os *quadcopters* (Figura 2), embora existam inúmeros modelos combinando diferentes números de rotores e braços. Estes modelos demonstram-se extremamente complexos quando se trata do sistema de controle embarcado, visto que os motores trabalham de maneira individual, necessitando de um processamento e sincronização em tempo real para que se alcance estabilidade e execução correta de manobras. Como principal vantagem, podemos elencar a versatilidade dos multirotores, especialmente pela pilotagem simplificada e pela capacidade de pousos e decolagens na vertical, facilitando a execução de levantamentos em ambientes com muitos obstáculos (JORGE e INAMASU, 2014).

Figura 2 – Multirotor do tipo *Quadcopter*



Fonte: Droneng (2015).

A maior dificuldade inerente a esta plataforma, é o tempo de voo reduzido, explicado pelo alto consumo de energia por parte dos motores e componentes elétricos envolvidos, apresentando uma autonomia que geralmente fica abaixo dos 30 minutos de operação. Outro ponto chave se tratando de autonomia, é o peso à ser carregado pelo equipamento, visto que maiores cargas requerem maior energia por parte dos motores, o que tende a reduzir o tempo de voo (MOUTINHO, 2015).

Na categoria de asas fixas (Figura 3), embora existam diferentes portes, algumas características se aplicam a todos. Geralmente estes modelos apresentam especificações mais sofisticadas, elevando o seu custo perante os multirotores. A maior virtude dos RPAS de asa fixa é a autonomia, que pode passar de uma hora, garantindo que grandes porções de área sejam recobertas em um único voo, característica fundamental a grandes levantamentos. Entretanto, a necessidade de uma plataforma de lançamento, representada por sistemas de elásticos ou catapultas, requer um local aberto para que as decolagens e pousos sejam executados com segurança, tornando a operação destes equipamentos mais complexa (DE SOUSA, 2017).

Figura 3 – RPAS do tipo asa fixa



Fonte: Droneng (2015).


Dentre os sensores mais utilizados nas plataformas RPAS, Munaretto (2015) destaca os seguintes: sensores na faixa do visível (RGB), muito recorrente no monitoramento de obras, agricultura e mineração; sensores infravermelhos (IV), com importantes aplicações na agricultura, como na identificação de estresse hídrico, e estimativa da biomassa; sensores multiespectrais e hiperespectrais, capazes de fornecer a reflectância dos alvos em diferentes faixas do espectro, permitindo que estes sejam caracterizados e diferenciados de maneira precisa; *L.I.D.A.R.* (*Light Detection And Ranging*), capaz de emitir pulsos de laser que posteriormente são refletidos pelos alvos, gerando uma nuvem densa de pontos com alto nível de detalhamento.

Ainda, cabe ressaltar a diversidade de preços no segmento de sensores, sendo que muitos destes apresentam um elevado custo, podendo inviabilizar o investimento. Nesse sentido, os sensores que operam na faixa do visível (RGB) se tornam muito mais acessíveis, onde são utilizadas câmeras convencionais, que podem ser facilmente encontradas no mercado, o que diminui consideravelmente o custo final do equipamento. Na agricultura, as câmeras RGB podem ser utilizadas na detecção de falhas de plantio, para monitorar o desenvolvimento dos cultivos e aspectos fitopatológicos, assim como na obtenção de modelos digitais de superfície e de terreno (JORGE e INAMASU, 2014).

3.4 MODELAGEM DA ALTURA E BIOMASSA DOS CULTIVOS

A possibilidade de obtenção de modelos digitais, através do uso de sensores RGB, viabiliza uma importante aplicação da ferramenta na agricultura, a quantificação da altura de plantas, passível de ser obtida por meio de uma combinação entre Modelo Digital de Terreno (MDT) e *Crop Surface Model* (CSM) (Figura 4).

Figura 4 – Representação gráfica do MDT e CSM em relação as plantas




Fonte: Adaptado de Hoffmeister (2014).

Os modelos digitais citados podem ser obtidos através da exploração dos conceitos da estereoscopia e paralaxe, temas amplamente abordados no âmbito da Fotogrametria, que quando associada a utilização de mídias digitais e softwares de visão computacional, passa a se chamar Fotogrametria Digital (MOUTINHO, 2015).

De forma simplificada, a estereoscopia estuda os métodos e técnicas que permitem a visão em perspectiva, ou seja, a percepção de profundidade. Tal propriedade está presente na visão humana, em que ao observar uma imagem sob dois pontos de vista ligeiramente distantes um do outro, em que cada olho recebe uma imagem distinta, promovendo uma diferença de enquadramento, ou perspectiva binocular, permite que o observador sintetize em seu cérebro as duas imagens, reconfigurando o espaço observado, permitindo que aspectos como relevo, distância e volume sejam observados (MASCHIO, 2008).

Já o estudo da paralaxe (Figura 5), é mais recorrente no âmbito da Fotogrametria, em que o deslocamento relativo de um ponto-imagem em fotografias aéreas consecutivas, resultado da tomada de imagens sob pontos distintos, pode ser medido de forma a obter a diferença de altura entre dois ou mais objetos (TEMBA, 2000). Nesse sentido, o recobrimento entre as fotos se torna muito importante, visto que somente a partir de recobrimentos longitudinais iguais ou superiores a 50% é possível ter a percepção estereoscópica, e assim, explorar os fundamentos da paralaxe.

Figura 5 – Estudo da paralaxe



Fonte: Wolf e Dewitt (2000).

Dada a importância do recobrimento entre imagens na modelagem tridimensional do terreno, o plano de voo (Figura 6) ganha um papel primordial, especialmente quando se objetiva a obtenção de resultados compatíveis com o a finalidade do aerolevamento. Nele, são definidos alguns parâmetros básicos, como a delimitação da área a ser levantada, recobrimento lateral e longitudinal, altura de voo, direção das linhas de voo e etc, sempre levando em consideração o propósito do levantamento e aspectos inerentes a plataforma, como autonomia e especificações técnicas da câmera (VALAVANIS e VACHTSEVANOS, 2015).

Figura 6 – Plataforma para elaboração de plano de voos em *smartphones*



Fonte: Drones Made Easy (2017).

No entanto, é somente a partir do processamento das imagens coletadas que são obtidos os produtos de interesse, que neste caso, é representado pelos modelos digitais de elevação (MDT e MDS). Para tanto, são utilizados softwares de visão computacional, em que, através de algoritmos específicos, é formada uma nuvem densa composta por milhares de pontos, que quando conectados, formam um modelo que representa a superfície levantada (MOUTINHO, 2015).

É nesse contexto que diversas aplicações envolvendo a manipulação de modelos digitais de elevação se tornam possíveis, uma vez que o conhecimento detalhado do comportamento do relevo é um dado essencial para o desenvolvimento de diversos estudos. No âmbito científico, Sulebak (2000) cita alguns dos estudos desenvolvidos com base na utilização dos modelos digitais de elevação: avaliação de impactos climáticos; monitoramento e modelagem geológica e hidrológica; tecnologias de informação geográfica e análises geomorfológicas.

Também, como já citado, uma das mais recentes aplicações envolvendo o uso de modelos digitais de elevação voltada ao setor agrícola, é a mensuração da altura das plantas. Tal potencialidade foi verificada em diversos estudos envolvendo inúmeras espécies de importância agrícola, como o trigo e a cevada, em que os modelos digitais obtidos através de imagens capturadas por sensores RGB a bordo

de RPAS apresentaram altas correlações a altura de plantas aferida à campo, (BENDIG et al., 2015; SHIRRMANN et al., 2016).

De forma indireta, outros parâmetros podem derivar da altura de plantas, como é o caso da quantidade de biomassa produzida. Em estudo proposto por Tilly, Aasen e Bareth (2015), a modelagem de altura de plantas para o cultivo do arroz, obtida por meio de um laser scanner terrestre (TLS), resultou em altos níveis de correlação com a biomassa produzida.

Da mesma forma, porém utilizando-se de sensores RGB, Bendig et al. (2014) e Shirrmann et al. (2016) verificaram a alta correlação entre o modelo de altura gerado e a produtividade de biomassa na cultura do trigo e cevada.

Dada a potencialidade da ferramenta na modelagem da altura de plantas, outros cultivos podem se beneficiar de sua utilização, como é o caso da aveia preta (*Avena strigosa*). Devido a sua dupla aptidão, sendo utilizada tanto como forragem e para fins de cobertura do solo, o conhecimento da biomassa acumulada ao longo do tempo se torna muito importante na condução e manejo desta cultura.

Como forrageira, o conhecimento da altura da aveia, bem como, de sua biomassa acumulada são os principais parâmetros a serem considerados no dimensionamento da carga animal (número de animais/área). Quando desempenhado de forma correta, o dimensionamento é capaz de minimizar a degradação do pasto e do solo e maximizar o desempenho econômico da área, além de permitir um maior controle dos resíduos vegetais remanescentes em sistemas integrados (GRISE, 2002).

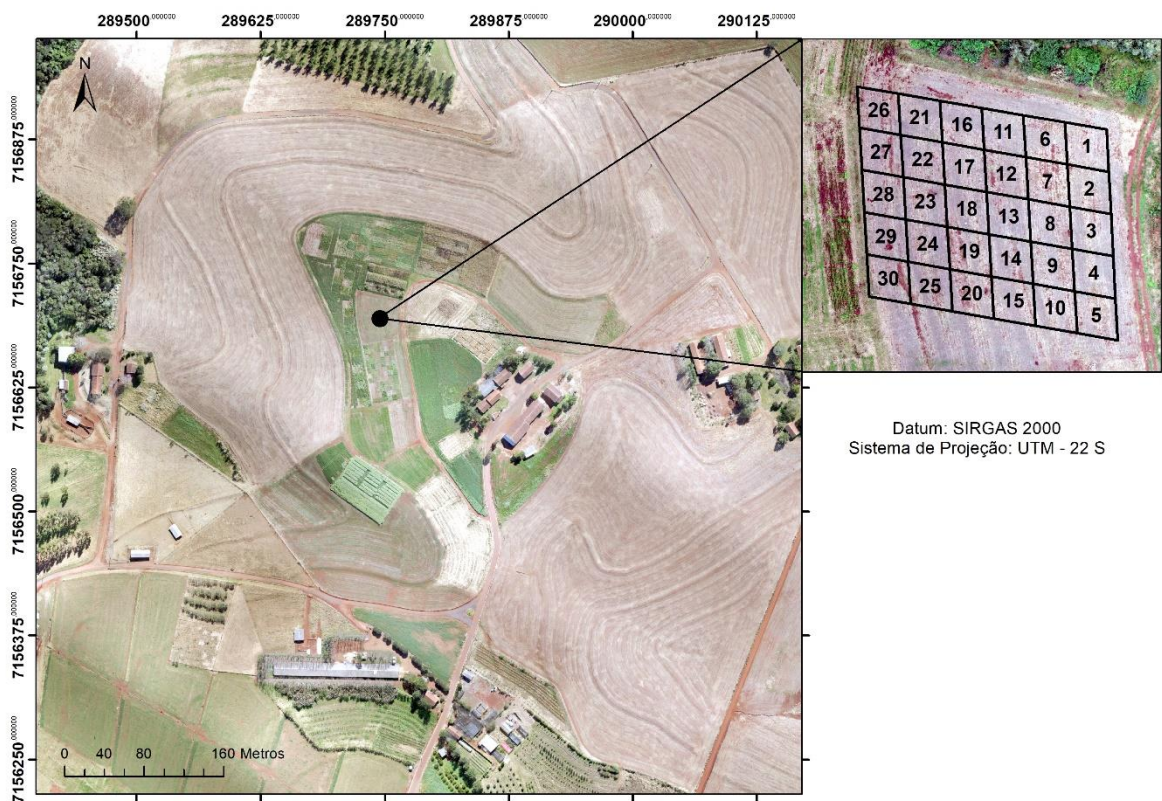
Quando utilizada como planta de cobertura, o conhecimento da biomassa da aveia se torna importante para que uma das premissas do Sistema Plantio Direto (SPD) seja alcançada. A quantidade de palha sobre o solo e a uniformidade de sua distribuição são considerados parâmetros de referência para uma avaliação preliminar sobre as condições nas quais o SPD está se desenvolvendo (ALVARENGA et al., 2001).

4 MATERIAL E MÉTODOS

4.1 ÁREA DE ESTUDO

Para a elaboração do presente trabalho, utilizou-se a área experimental da Universidade Tecnológica Federal do Paraná, câmpus Dois Vizinhos. O experimento foi locado nas seguintes coordenadas geográficas: 25°41'33" S, e 53°05'43" W, com altitude média de 530 m (Figura 7). De acordo com a classificação internacional de Köppen, o clima é do tipo Cfa, subtropical, úmido (ALVARES et al., 2013), com precipitação anual média de 2000 a 2500 mm. O solo predominante na região é classificado como Nitossolo vermelho distroférico (BHERING et al., 2008).

Figura 7 – Localização da área de estudo e distribuição das parcelas avaliadas



Fonte: Autoria própria (2017).

O experimento avaliado foi implantado utilizando-se do delineamento experimental blocos ao acaso, com 10 tratamentos e 3 repetições, perfazendo um total de 30 parcelas, as quais possuíam dimensões de 7 x 7 m (49 m²). A cultivar de aveia preta (*Avena strigosa* Schreb.) semeada foi a BRS 139, em uma densidade de semeadura de 70 kg.ha⁻¹ e espaçamento de 0,13 m entre linhas.

Como tratamentos, foram utilizadas diferentes doses de fertilizante, tanto de origem animal quanto mineral (Tabela 1), os quais foram aplicados a lanço após a semeadura.

Tabela 1 – Tratamentos utilizados no experimento

| Tratamento | Parcelas |
|--|------------|
| Sem fertilizantes (T1) | 1,13 e 30 |
| Cama de aviário – 6 t.ha ⁻¹ (T2) | 8, 16 e 28 |
| Cama de aviário – 12 t.ha ⁻¹ (T3) | 10,12 e 25 |
| Cama de aviário – 18 t.ha ⁻¹ (T4) | 2, 20 e 24 |
| Cama de aviário – 6 t.ha ⁻¹ (T5) | 5, 18 e 26 |
| Cama de aviário (6 t.ha ⁻¹) e fertilizante mineral (75 kg-N.ha ⁻¹) (T6) | 6, 15 e 22 |
| Cama de aviário (6 t.ha ⁻¹) e fertilizante mineral (150 kg-N.ha ⁻¹) (T7) | 7, 17 e 29 |
| Cama de aviário (6 t.ha ⁻¹) e fertilizante mineral (225 kg-N.ha ⁻¹) (T8) | 9, 14 e 23 |
| Fertilizante mineral N-P-K (T9) | 3, 19 e 21 |
| Fertilizante mineral N-P-K (T10) | 4, 11 e 27 |

Fonte: Autoria própria (2017).

4.2 PLATAFORMA RPAS E SENSOR UTILIZADO

Para a execução dos voos, foi utilizado o RPAS multirrotor Phantom 3 Advanced (Figura 8), modelo comercial desenvolvido pela empresa chinesa DJI. Dotado de 4 rotores, o modelo conta com uma bateria de 4480 mAh, capaz de oferecer autonomia de até 23 minutos. Ainda, é equipado com receptores GNSS (*Global Navigation Satellite System*) para os sistemas GPS e GLONASS, o que permite a

execução de planos de voos pré-definidos de forma autônoma. O equipamento é controlado remotamente através de um rádio que opera na faixa dos 2,4 GHz, com a tecnologia denominado *Lightbridge*, permitindo que o RPAS seja controlado a uma distância de até 5 km, além de realizar a transmissão das imagens capturadas pela câmera em tempo real. (DJI, 2015).

Figura 8 – RPAS utilizado para coleta de dados (Phantom 3 Advanced)



Fonte: Autoria própria (2017).

Dentre outros sensores embarcados na plataforma, a câmera utilizada ganha destaque. Acoplada a um gimbal composto de 3 eixos, que garante a estabilização das imagens, apresenta as seguintes especificações: sensor CMOS RGB Sony EXMOR 1/2.3" com resolução de 12 megapixels (4000 x 3000 pixels); lentes de foco fixo com ângulo de visão (*Field of view*) de 94°, distância focal 20 mm e abertura de f/2.8 (DJI, 2015).

4.3 COLETA DE DADOS

Como forma de abranger os estádios fenológicos mais importantes da aveia preta, e assim, gerar um modelo matemático capaz de representar o crescimento e desenvolvimento da cultura, foram realizadas 3 coletas ao longo do cultivo, além uma coleta adicional realizada antes da semeadura, que objetivou a geração do Modelo Digital de Terreno (MDT). A Tabela 2, apresenta maiores detalhes de cada coleta de dados realizada.

Tabela 2 – Data e informações sobre cada coleta de dados realizada

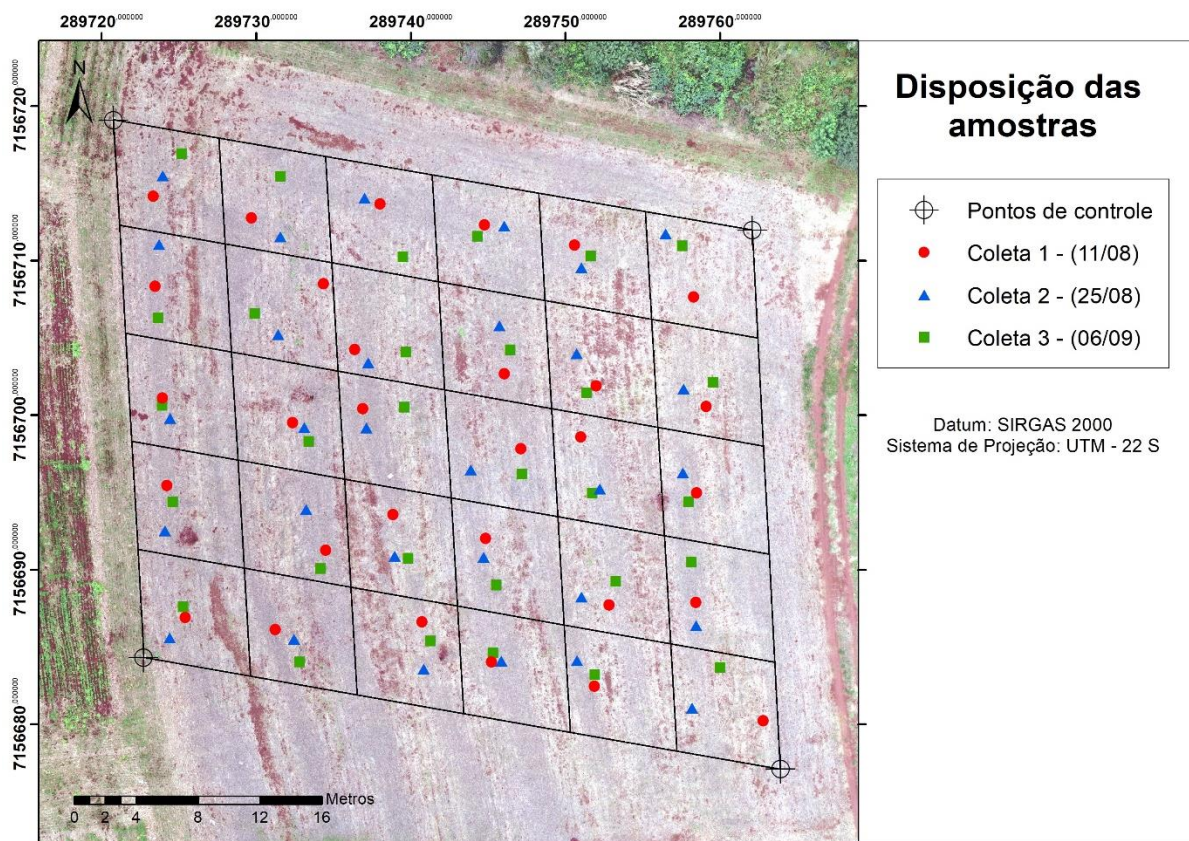
| Data | Horário de início | Objetivo da coleta | Estádio fenológico da cultura | Velocidade do vento (m/s) | Radiação (kJ/m ²) |
|------------|-------------------|--------------------|-------------------------------|---------------------------|-------------------------------|
| 04/06/2017 | 10:48 | MDT | - | 1,1 | 617 |
| 11/08/2017 | 13:34 | CSM | Emborrachamento | 4,1 | 2300 |
| 25/08/2017 | 13:03 | CSM | Início do Florescimento | 3,4 | 2555 |
| 06/09/2017 | 12:38 | CSM | Enchimento de grãos | 3,3 | 2432 |

Fonte: Autoria própria (2017).

Nas três avaliações realizadas, foram tomadas uma amostra para cada parcela, perfazendo 30 amostras em cada coleta e 90 ao final do trabalho, tanto para os dados coletados através do RPAS quanto os mensurados a campo.

Como forma de reduzir o viés experimental, os pontos de amostragem foram alocados aleatoriamente, como mostra a figura 9.

Figura 9 – Disposição das amostras em cada coleta realizada



Fonte: Autoria própria (2017).

4.3.1 Coleta de dados através do RPAS

Para garantir a qualidade e alto padrão dos dados a serem coletados, o planejamento do levantamento foi fundamental, sempre considerando todos os fatores que pudessem vir a influenciar os resultados do estudo. Dentre eles, a condição do tempo, que é determinante nos levantamentos aerofotogramétricos, sempre evitando condições de tempo nublado e de ventos excessivos. Também, buscou-se um padrão entre os horários de coleta, sempre efetuada próximo às 12 horas, momento em que há um pico de luminosidade, além de ser um horário capaz de reduzir a incidência de sombras nas imagens.

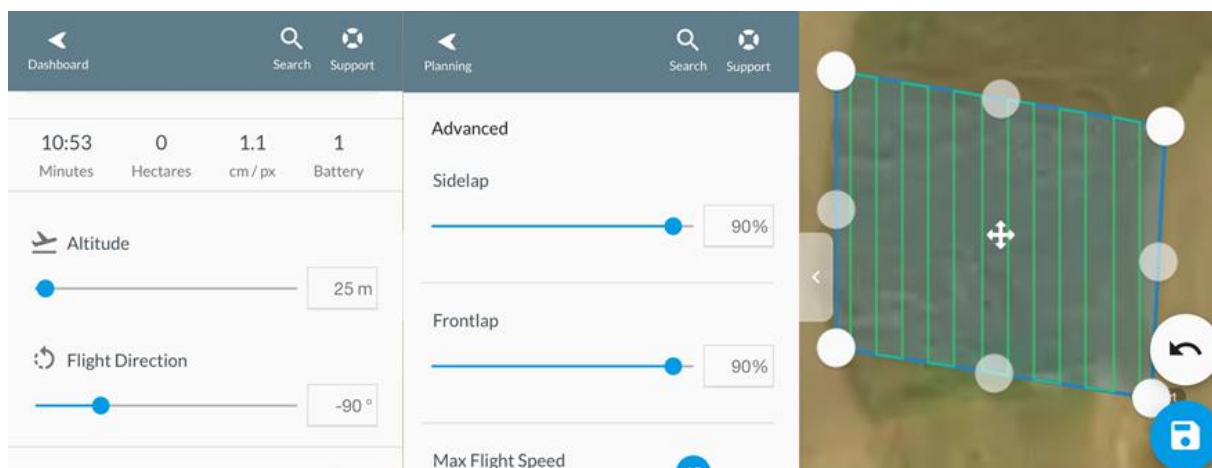
Além de todos os cuidados citados, outro elemento fundamental ao planejamento do levantamento é o estudo e elaboração do plano de voo, que deve ser adequado aos objetivos do aerolevanteamento.

4.3.1.1 Plano de voo

Todo levantamento aerofotogramétrico pressupõe a existência de um plano de voo, em que são definidos os parâmetros básicos do levantamento, como a delimitação da área a ser levantada, altura de voo e recobrimento. A definição destas informações irá implicar diretamente na qualidade do produto final, podendo ser exemplificada pela resolução espacial dos produtos a serem gerados, isto é, as dimensões que um pixel representa no terreno, característica influenciada diretamente pela altitude de voo.

Outra importante informação definida no plano de voo foi o recobrimento entre as imagens, característica que ganha papel fundamental devido a natureza do estudo. Nesse sentido, foram utilizadas altas taxas de recobrimento associadas a uma baixa altura de voo, a fim de proporcionar um maior nível de detalhamento dos modelos gerados, e assim, representar com maior fidelidade as informações presentes no campo.

Para que o plano de voo fosse elaborado, utilizou-se o software DroneDeploy, o qual é disponibilizado gratuitamente para smartphones. Nele, definiu-se os seguintes parâmetros, os quais foram utilizados em todas as coletas: altitude de 25 m; direção das linhas de voo de -90° ; recobrimento longitudinal e lateral de 90%; área recoberta e câmera com configurações automáticas (Figura 10). A partir dessas informações, o tempo de voo para cada levantamento foi estimado em cerca de 11 minutos. Assim, para realização do voo, foi feito o *upload* do plano do voo para o RPAS, em que o dispositivo realiza a missão de forma autônoma, de acordo com os parâmetros pré-definidos.

Figura 10 – Plano de voo elaborado no aplicativo DroneDeploy

Fonte: Autoria própria (2017).

Para facilitar a delimitação da área amostrada, em todas as coletas foi realizado um voo adicional, seguindo os mesmos parâmetros citados acima, exceto para o recobrimento, que foi reduzido para casa dos 80%, visto que o objetivo deste segundo voo foi apenas a análise do ortomosaico gerado, não visando a exploração de modelos digitais de elevação. O voo extra permitiu uma comparação exata entre os dados de campo e os coletados pelo RPAS, visto que foram extraídas apenas as informações da área ocupada por cada amostra.

Tal prática foi viabilizada através do processo de fotointerpretação, em que os pacotes contendo o material vegetal colhido foram deixados exatamente sob área amostrada (Figura 11), permitindo uma delimitação mais coerente da área colhida. Cabe ainda ressaltar, que o objetivo dos voos adicionais foram exclusivamente a delimitação das áreas amostradas, sendo que estes dados não foram contabilizados no processo de modelagem.

Figura 11 – Imagem do aerolevanteamento adicional realizado para delimitação de cada área amostrada



Fonte: Autoria própria (2017).

4.3.1.2 Pontos de controle

Outra importante etapa do trabalho foi a materialização dos pontos de apoio, os quais são necessários para garantir que os modelos gerados sejam sobrepostos de maneira precisa, além de ser utilizado para fins de calibração durante o processamento dos dados. Nesse sentido, foram estabelecidos 4 pontos, os quais coincidem com os vértices do experimento.

Para determinação das coordenadas dos pontos de controle, foram utilizados receptores GNSS (Figura 12) com as seguintes especificações: GNSS TechGeo modelo GTR-G² (dupla frequência - L1/L2), capaz de rastrear sinal das constelações GPS e GLONASS, com precisão nominal de 5 mm na vertical e 10 mm na horizontal; GNSS TechGeo modelo GTR - A^{BT} (única frequência - L1), capaz de rastrear sinal da constelação GPS, com precisão nominal de 5 mm (horizontal e vertical). Para o levantamento dos pontos, o receptor GTR-G² foi estacionado sob a referência de nível (RN) presente na universidade, e o receptor GTR - A^{BT} (*rover*) foi utilizado para a coleta dos pontos propriamente ditos.

Figura 12 – Receptores GNSS utilizados na coleta de dados dos pontos de controle



Fonte: TechGeo (2012).

O método de posicionamento empregado foi o relativo estático, com tempo de coleta de 1 h para cada ponto. Nesse método, a posição de um ponto é determinada em relação a um ou mais referenciais materializados com coordenadas conhecidas, sendo necessário que ambos os receptores estejam coletando dados simultaneamente (INCRA, 2013).

Para que os pontos de controle pudessem ser visualizados nas imagens tomadas pelo RPAS, foi necessário o uso de alvos (Figura 13), o que garantiu maior precisão no processo de georreferenciamento dos modelos gerados.

Figura 13 – Alvos utilizados para identificação dos pontos de controle



Fonte: Autoria própria (2017).

4.3.2 Coleta de dados à campo

Após a execução do aerolevanteamento, se deu início a coleta de dados a campo, em que foram avaliados os seguintes parâmetros: altura de plantas; produção de matéria verde e matéria seca. Os pontos de coleta foram, como já citado, foram escolhidos aleatoriamente, distribuídos na ordem de uma amostra por parcela, totalizando ao final do estudo 90 amostras.

Para facilitar o processo de amostragem, utilizou-se um quadro metálico de 0,5 x 0,5 m, subdividido em 4 quadrantes, como mostra a figura 14.

Figura 14 – Quadro metálico utilizado para o processo de amostragem à campo



Fonte: Autoria própria (2017).

O método biométrico escolhido para aferir a altura de plantas, pressupôs a distância existente entre a base da planta até o nível da folha bandeira (Figura 15), padrão mantido em todas as coletas. O número de sub-amostras foi de 8 plantas mensuradas por parcela, divididas em 2 para cada quadrante, as quais foram consideradas na composição da média final de cada parcela.


Figura 15 – Procedimento realizado para aferir a altura das plantas



Fonte: Autoria própria (2017).

Após tomar as informações relativas a altura de plantas, as amostras (0,5 x 0,5 m) foram cortadas rente ao solo e devidamente acondicionadas em pacotes identificados, que de imediato foram pesados para compor os dados relativos a matéria verde (MV) (Figura 16).

Figura 16 – Colheita e pesagem das amostras



Fonte: Autoria própria (2017).

Para a determinação da matéria seca, as amostras foram submetidas a secagem em estufa, sob temperaturas de aproximadamente 65°C, permanecendo

neste processo até atingirem peso constante. Satisfeita essa condição, foram novamente pesadas e seus dados registrados na planilha de campo.

4.4 PROCESSAMENTO DOS DADOS


Tomados os devidos cuidados durante o processo de aquisição das imagens, outro importante passo foi iniciado: o processamento de dados. Nessa etapa, foram utilizados diferentes softwares, especialmente os de visão computacional e SIGs (Sistema de Informações Geográficas), responsáveis pela construção dos modelos e utilizados para manipulação e extração das informações.

4.4.1 Processamento das imagens

Para o processamento das imagens obtidas pelo RPAS, utilizou-se o *software* fotogramétrico russo Agisoft Photoscan Professional, versão 1.2.6, em que se utilizou uma licença de avaliação concedida gratuitamente por um período de 30 dias. Nele, é utilizado o algoritmo denominado *Structure from Motion* (SfM) (VERHOVEN, 2011), capaz de gerar de modelos tridimensionais representando a superfície de interesse.

O primeiro passo no processamento dos dados foi a importação das imagens a serem utilizadas no projeto, havendo uma exclusão prévia das fotos indesejadas, ou seja, aquelas em que apresentaram alguma imperfeição (*blur*), ou aquelas que não representavam a área de interesse. Posteriormente, foi executado o algoritmo de alinhamento das imagens, capaz de reconhecer pontos homólogos em diferentes imagens, mesmo em diferentes condições de luminosidade e escala, de forma a ordenar a disposição das mesmas, visto que os pontos denominados homólogos são utilizados para amarração (*matching*) entre imagens, gerando uma nuvem esparsa de pontos ao final do processo (Figura 17).

Figura 17 – Disposição das imagens após o processo de alinhamento



Fonte: Autoria própria (2017).

Posteriormente, o alinhamento das imagens foi otimizado através da inserção dos pontos de controle, previamente posicionados nas imagens sinalizadas pelo software (Figura 18). Esse processo é responsável por conectar o sistema de coordenadas da imagem com o sistema de coordenadas no terreno, realizando as devidas correções, além de efetuar calibrações por meio de informações relativas a câmera, promovendo resultados otimizados na sequência.

Figura 18 – Posicionamento dos pontos de controle




Fonte: Autoria própria (2017).

Feito isso, o próximo passo executado foi a construção da nuvem densa de pontos, em que o algoritmo utilizado pelo software é capaz de monitorar o movimento aparente das feições presentes nas diferentes imagens, explorando os princípios da estereoscopia e paralaxe, culminando em uma nuvem tridimensional representada por

milhões de pontos. Como método de filtragem da nuvem de pontos, foi escolhida a opção “*mild*”, que basicamente mantém o maior nível de detalhes do modelo, evitando que este seja suavizado. Outro importante parâmetro definido na geração da nuvem densa é relativo à sua qualidade, em que se definiu a opção “*high*”, que apesar de exigir maiores recursos computacionais, promove resultados mais refinados (Figura 19).


Figura 19 – Nuvem densa de pontos



Fonte: Autoria própria (2017).

Ao final, foi efetuada a reconstrução tridimensional do modelo, em que os pontos provenientes da nuvem densa são conectados por meio de uma triangulação (*Triangulated Irregular Network – TIN*), gerando uma malha denominada *Mesh*, que posteriormente foi derivada em um Modelo Digital de Elevação (Figura 20).

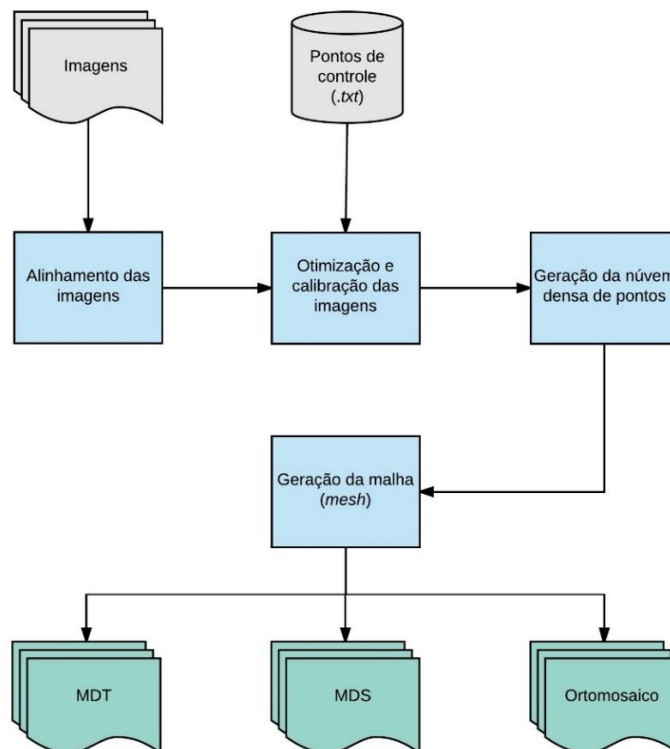
Figura 20 – Modelo Digital de Elevação (MDE)



Fonte: Autoria própria (2017).

Por fim, para que os dados resultantes pudessem ser manipulados em ambiente SIG, estes foram exportados para o formato .TIFF, extensão usada em dados matriciais com sistema de coordenadas associado.

Figura 21 – Fluxograma do processamento de dados no software Agisoft Photoscan



Fonte: Autoria própria (2017).


4.4.2 Procedimentos em ambiente SIG

Para a manipulação dos dados obtidos, bem como, a elaboração de mapas, foi utilizada a versão de avaliação do software ArcGIS, versão 10.2.2, disponibilizada gratuitamente por um período de 30 dias.

Primeiramente, foram importados todos os modelos digitais obtidos, assim como seus respectivos ortomosaicos, devidamente separados em *layers* de acordo com cada coleta. Posteriormente, através da ferramenta *Raster Calculator*, foi inserida a equação e os modelos digitais necessários para obtenção de cada *Crop Surface Model* (CSM). A equação, extremamente simples, é uma subtração entre o modelo digital de superfície pelo modelo digital de terreno, resultando em um terceiro modelo que representa a altura de plantas (CSM).

Para que os dados provenientes do CSM tivessem suas informações comparadas exatamente com a área amostrada a campo, foi necessária a geração de uma linha de corte, a qual foi delimitada com base no ortomosaico proveniente do aerolevante adicional efetuado em cada coleta (Figura 22).

Figura 22 – Delimitação da área amostrada

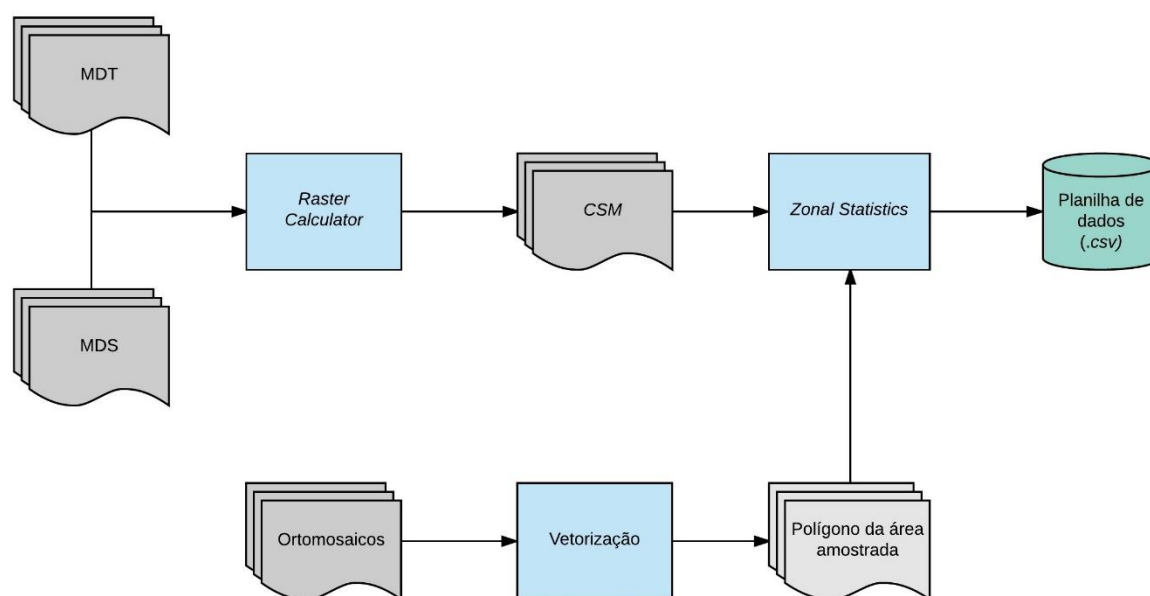


Fonte: Autoria própria (2017).

Como forma de extrair a média de altura proveniente das centenas de *pixels* do CSM recortado para cada uma das amostras, foi utilizada ferramenta *Zonal Statistics*, em que o CSM recortado é importado, juntamente com o vetor utilizado para o recorte, escolhendo a opção estatística *Mean*, que representa a média. A partir destas informações, o software calculou a média dos valores associados aos *pixels* para cada amostra, que posteriormente foi importada para a planilha de campo.

Ao final do trabalho, a partir da equação obtida pela posterior análise estatística, foram gerados mapas de produtividade, ilustrando a variabilidade espacial da produção de matéria seca dentro do experimento. Para isso, novamente utilizou-se a ferramenta *Raster Calculator*, inserindo a equação obtida na análise de regressão, sendo a altura de plantas coletada pelo RPAS a variável explicativa, e produtividade de matéria seca a variável resposta.

Figura 23 – Fluxograma do processamento em ambiente SIG



Fonte: Autoria própria (2017).

4.5 ANÁLISE ESTATÍSTICA

A análise estatística foi desempenhada com base em análises de regressão, em que se avaliou a correlação entre as variáveis estudadas, assim como os resíduos dos modelos. Para tanto, foi utilizado o software Microsoft Excel.

As análises de regressão foram realizadas combinando as seguintes variáveis: altura de plantas mensurada a campo e altura de plantas derivada do RPAS; altura de plantas derivada do RPAS e matéria verde acumulada; altura de plantas derivada do RPAS e matéria seca acumulada. Para todas as análises, foram extraídos gráficos, os quais facilitaram a interpretação dos dados.

Como forma de avaliar a confiabilidade dos modelos gerados, foram calculados alguns parâmetros, como o coeficiente de determinação (R^2), raiz quadrada do erro médio (Equação 1) e erro relativo (Equação 2).

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

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

5 RESULTADOS E DISCUSSÃO

5.1 PRODUTOS FOTOGRAMÉTRICOS OBTIDOS

Como resultado da aquisição e processamento das imagens coletadas pela plataforma RPAS, foram obtidos os produtos listados na tabela abaixo.

Tabela 3 – Informações relativas a cada modelo obtido

| Data de coleta | Produto obtido | Número de fotos | Recobrimento* | Altitude média (m) | Densidade de pontos (pts/m ²) | Resolução espacial (cm.px ⁻¹) |
|----------------|----------------|-----------------|---------------|--------------------|---|---|
| 04/06/2017 | MDT | 150 | >9 | 25,7 | 3228 | 1,76 |
| 11/08/2017 | CSM | 142 | >9 | 29,5 | 2916 | 1,85 |
| 25/08/2017 | CSM | 179 | >9 | 21,8 | 4056 | 1,57 |
| 06/09/2017 | CSM | 153 | >9 | 27,8 | 3052 | 1,81 |

* Número de imagens representando um mesmo ponto do modelo
Fonte: Autoria própria (2017).

Em termos de qualidade dos resultados, pode-se afirmar que a resolução espacial atingida foi suficiente para a natureza do estudo, ficando muito próxima a utilizada em pesquisas da mesma natureza. Se considerada a densidade de pontos (*pixels*) existente para cada modelo, em relação a população do cultivo, observa-se uma proporção de mais de 10 pontos para cada planta, o que certamente garantiu uma representação detalhada das informações presentes no campo.

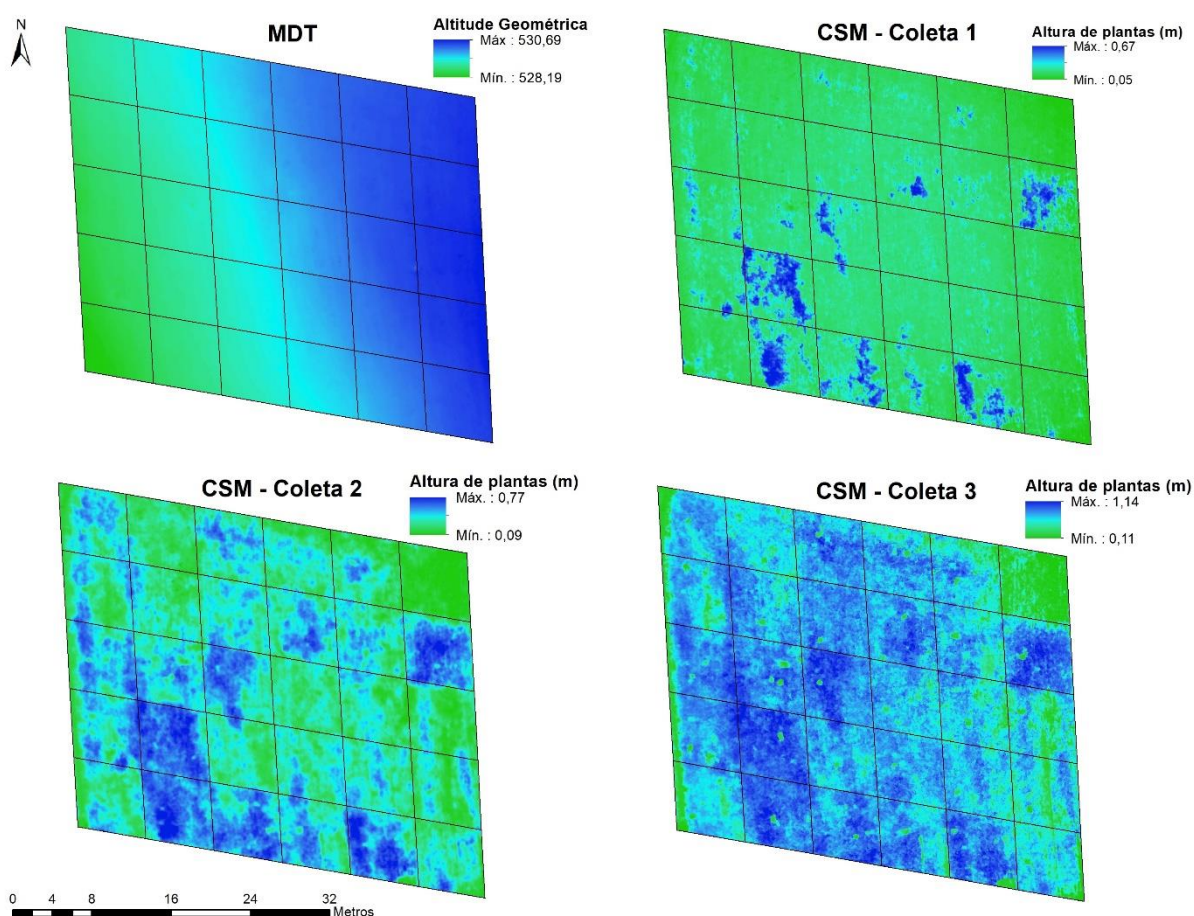
Outro importante resultado que remete a qualidade dos produtos obtidos é o recobrimento entre as imagens utilizadas, em que todas as missões realizadas neste estudo foram executadas com 90% de recobrimento longitudinal e lateral. Nesse sentido, todo e qualquer ponto presente nos modelos digitais gerados foi construído com base no processamento de mais de 9 imagens, as quais foram tomadas sob diferentes ângulos, abrangendo o alvo em questão.

Haala e Rothermel (2012) afirmam que modelos construídos com base em um número superior de imagens resultam em uma maior densidade de pontos, visto que algoritmo de estereoscopia é capaz de se beneficiar do maior número de imagens de

um mesmo alvo, passando a representar áreas antes oclusas. Outro fator impulsionado pelo recobrimento é a acurácia posicional do modelo, que é elevada à medida que se aumenta o recobrimento entre imagens, podendo alcançar a casa do milímetro (HARTMANN et al., 2012).

Através da representação gráfica dos modelos digitais obtidos (Figura 24), é possível evidenciar o incremento constante na altura de plantas ao longo do desenvolvimento da cultura, assim como, a variabilidade espacial condicionada pelos diferentes tratamentos do experimento, demonstrando a capacidade da ferramenta em monitorar a variação e a evolução da altura de plantas.

Figura 24 – Mapas ilustrando os modelos digitais obtidos



Fonte: Autoria própria (2017).

5.2 ANÁLISE DE REGRESSÃO

Para a realização das análises, utilizou-se o banco de dados resultante da biometria aferida à campo juntamente com os dados provenientes do RPAS, em que foram avaliados: altura de plantas, produção de matéria verde e produção de matéria seca. Para melhor compreensão dos resultados, a Tabela 4 abaixo apresenta a estatística descritiva do banco de dados.

Tabela 4 – Estatística descritiva dos dados mensurados à campo

| | Coleta | n | Média | Mínimo | Máximo | Desvio Padrão |
|---|-----------|----|---------|--------|--------|---------------|
| Altura de plantas à campo (cm) | 1 (11/08) | 30 | 20,15 | 12,13 | 30,63 | 5,14 |
| | 2 (25/08) | 30 | 57,82 | 37,75 | 77,38 | 9,58 |
| | 3 (06/09) | 29 | 65,62 | 49,88 | 80,75 | 6,36 |
| Altura de plantas - CSM (cm) | 1 (11/08) | 30 | 25,46 | 8,38 | 56,77 | 15,19 |
| | 2 (25/08) | 30 | 46,03 | 9,72 | 71 | 14,68 |
| | 3 (06/09) | 29 | 74,81 | 54,78 | 96,99 | 9,82 |
| Matéria verde acumulada (kg.ha⁻¹) | 1 (11/08) | 30 | 7953,33 | 3198 | 17934 | 4325 |
| | 2 (25/08) | 30 | 18690,4 | 6550 | 32298 | 6736,9 |
| | 3 (06/09) | 29 | 18268,1 | 10790 | 28854 | 4462,6 |
| Matéria seca acumulada (kg.ha⁻¹) | 1 (11/08) | 30 | 1494,27 | 688 | 3040 | 668,3 |
| | 2 (25/08) | 30 | 3341,3 | 1360 | 6272 | 1205,2 |
| | 3 (06/09) | 29 | 5055,59 | 3072 | 8148 | 1213,6 |

Fonte: Autoria própria (2017).

5.2.1 Altura de plantas

Nesta análise, foram utilizados os dados referentes à altura de plantas aferida à campo e a altura de plantas derivada do CSM, em cenários distintos, de acordo com a Tabela 5.

Tabela 5 – Resultados da análise de regressão para altura de plantas

| Coleta | Modelo | Número de amostras | Equação | R ² | RMSE (cm) | RE (%) |
|--------------------|--------|--------------------|------------------------|----------------|-----------|--------|
| N°1 (11/08) | Linear | 30 | $y = 0,3139x + 12,157$ | 0,86 | 1,92 | 9,54 |
| N°2 (25/08) | Linear | 30 | $y = 0,6243x + 29,082$ | 0,9149 | 2,79 | 4,84 |
| N°3 (06/09) | Linear | 29 | $y = 0,5684x + 23,101$ | 0,771 | 3,04 | 4,64 |

Fonte: Autoria própria (2017).

Para cada uma das coletas foi obtido um modelo linear, de alto nível de correlação ($R^2 > 0,7$), sendo o melhor cenário observado durante a segunda coleta (início do florescimento), e o pior na terceira amostragem (enchimento de grãos).

Este comportamento tem relação com o estágio de desenvolvimento da cultura, especialmente em termos de uniformidade do dossel, onde a segunda coleta, por coincidir com o pico de desenvolvimento, condicionou os melhores resultados. Por outro lado, a redução da correlação durante a terceira amostragem pode ser explicada pelo fato de que muitas parcelas se encontravam em senescência, resultando em um menor número de folhas, e por consequência, uma menor uniformidade no dossel.

Quando comparado a estudos de mesma natureza, os resultados podem ser considerados satisfatórios. Em pesquisa avaliando a utilização de sensores RGB na modelagem da altura de plantas para a cultura da cevada, Bendig et al. (2014) obteve um coeficiente de determinação (R^2) igual 0,92 na análise universal, em que foram avaliadas 18 cultivares em 2 tratamentos.

Da mesma forma, Shirrmann et al. (2016) atingiu resultados correlatos, em que, através dos dados de uma plataforma RPAS com sensor RGB a bordo, foram extraídos modelos com R^2 entre 0,87 e 0,90 para a cultura do trigo, sendo o melhor cenário observado no florescimento da cultura, assim como no presente estudo.

Se tratando de sensores ativos terrestres (TLS), Ehlert et al. (2008) atingiu um R^2 entre 0,93 e 0,99 para as culturas do canola, centeio e trigo. No entanto, o uso de sensores terrestres pode se tornar inviável na maioria das aplicações, dada a sua capacidade limitada a mensurar pequenas porções de área.

O estudo dos resíduos, representado pelo RMSE e RE, permitiu avaliar a magnitude dos erros resultantes do modelo, em que a primeira coleta apresentou o menor erro absoluto (1,92 cm), e a terceira, novamente, com o pior cenário (3,04 cm). No entanto, quando considerada a proporção do erro absoluto em relação à média da

variável resposta, a terceira amostragem condiciona os melhores resultados, com um erro na casa dos 4,64 %, dada a média superior da altura de plantas durante essa missão, o que diluiu o erro.

Cabe ainda ressaltar a dificuldade em correlacionar a altura de plantas obtida pelos métodos avaliados, em que a intensidade de amostragem efetuada à campo não foi compatível com a extraída pelo CSM. A altura de plantas derivada do modelo digital tem uma densidade de sub-amostras proporcional a sua resolução, que neste caso foi de aproximadamente $1,7 \text{ cm.px}^{-1}$, resultando em mais de 700 pontos por amostra ($0,5 \times 0,5 \text{ m}$), os quais compõe a média final da altura de plantas. Esse número é bem superior ao número de plantas existente na área amostrada, fazendo com que cada planta seja representada por inúmeros pontos, que se localizam tanto no ápice da planta quanto nas partes inferiores do dossel.

Assim, a forma de amostragem utilizada no presente estudo, em que se pressupôs a altura de plantas como a medida da parte basal até o nível da folha bandeira, com intensidade de amostragem de 8 plantas por parcela ($0,5 \times 0,5 \text{ m}$) não se equipara ao método anterior, sendo menos representativa. Além disso, pode ser considerada subjetiva, dada a variabilidade na altura de plantas dentro de uma mesma amostra, o que pode dificultar a obtenção de dados representativos.

Outro ponto observado, foi a instabilidade do modelo obtido na primeira coleta, onde as parcelas com altura de plantas inferior a média da missão tiveram medidas subestimadas. Isso ocorreu devido ao dossel do cultivo não estar completamente fechado nas parcelas subdesenvolvidas, fazendo com que muitos pontos existentes do modelo atingissem o nível do solo, o que diminuiu a média de altura proveniente do CSM nestas parcelas.

Por outro lado, um comportamento oposto foi observado durante a segunda e a terceira amostragem, em que altura de plantas derivada do RPAS foi, em algumas parcelas, superior a aferida a campo. Isso pode ser explicado pela metodologia utilizada para mensurar a altura de plantas a campo, onde foi considerada a distância entre a parte basal e a folha bandeira da planta. No entanto, ao iniciar o estágio reprodutivo, ocorre uma alteração morfológica na cultura, havendo um alongamento da porção superior para a emissão da espiga, resultando em um afastamento entre o ápice e a folha bandeira da planta. Assim, a biometria realizada a campo proporcionou

medidas inferiores à altura de plantas dimensionada através do RPAS, especialmente em parcelas de estádio reprodutivo mais avançado.

5.2.3 Produtividade de matéria verde

Para a modelagem da produção de matéria verde da aveia preta, foram realizadas regressões utilizando-se da altura de plantas proveniente do CSM, as quais foram subdivididas por coleta, além de uma análise universal, em que foi utilizado o conjunto total de dados (Tabela 6).

Tabela 6 – Resultados da análise de regressão para produção da matéria verde em função da altura de plantas proveniente do CSM

| Coleta | Modelo | Número de amostras | Equação | R ² | RMSE (kg.ha ⁻¹) | RE (%) |
|--------------------|-------------|--------------------|-------------------------|----------------|-----------------------------|--------|
| N°1 (11/08) | Linear | 30 | $y = 271,38x + 1044,6$ | 0,9083 | 1310,02 | 16,47 |
| N°2 (25/08) | Exponencial | 30 | $y = 5333,5e^{0,0257x}$ | 0,945 | 1661,8 | 8,89 |
| N°3 (06/09) | Exponencial | 29 | $y = 4020,9e^{0,0198x}$ | 0,6424 | 2690,335 | 14,73 |
| Universal* | Exponencial | 89 | $y = 4680e^{0,0208x}$ | 0,7228 | 5073,03 | 33,97 |

Fonte: Autoria própria (2017).

Para efeito de comparação, o mesmo foi repetido com os dados de altura mensurados à campo, de acordo com a Tabela 7.

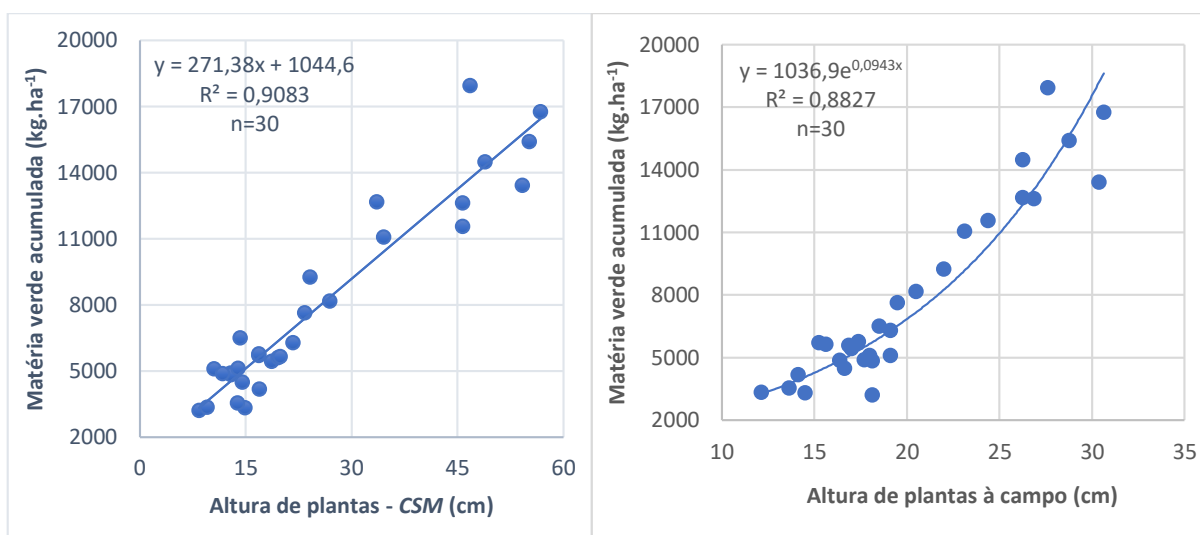
Tabela 7 – Resultados da análise de regressão para produção da matéria verde em função da altura de plantas mensurada à campo

| Coleta | Modelo | Número de amostras | Equação | R ² | RMSE (kg.ha ⁻¹) | RE (%) |
|--------------------|-------------|--------------------|-------------------------|----------------|-----------------------------|--------|
| N°1 (11/08) | Exponencial | 30 | $y = 1036,9e^{0,0943x}$ | 0,8827 | 1515,68 | 19,06 |
| N°2 (25/08) | Exponencial | 30 | $y = 1953e^{0,0378x}$ | 0,8724 | 2447,85 | 13,1 |
| N°3 (06/09) | Exponencial | 29 | $y = 2031,8e^{0,033x}$ | 0,7456 | 2297,226 | 12,58 |
| Universal* | Exponencial | 89 | $y = 3945,6e^{0,0248x}$ | 0,778 | 3506 | 23,48 |

Fonte: Autoria própria (2017).

Na primeira coleta, o modelo proveniente dos dados do RPAS se comportou de forma muito similar a metodologia convencional, com resultados pouco superiores, tanto em termos de correlação (R^2) quanto erro absoluto (RMSE), como mostra a Figura 25.

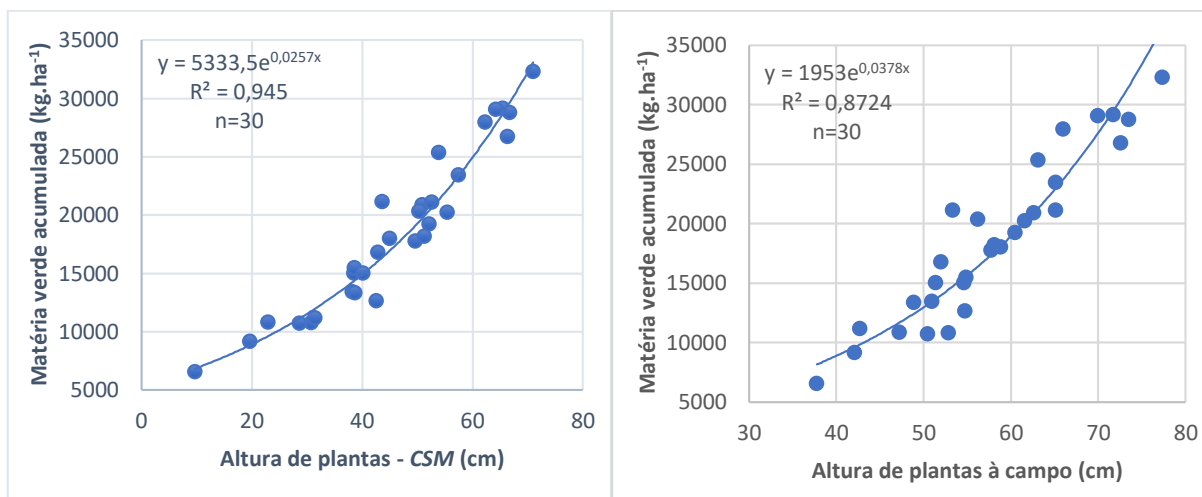
Figura 25 – Análise de regressão para produção de matéria verde com os dados referentes a primeira coleta.



Fonte: Autoria própria (2017).

Já na segunda amostragem, o modelo proveniente do CSM obteve os melhores resultados da análise, em que a regressão exponencial alcançou um R^2 de 0,945, com um erro relativo de 8,89 %. Em comparação, a regressão obtida através da metodologia convencional apresentou resultados inferiores, com correlação de 0,8724 e erro relativo de 13,1% (Figura 26).

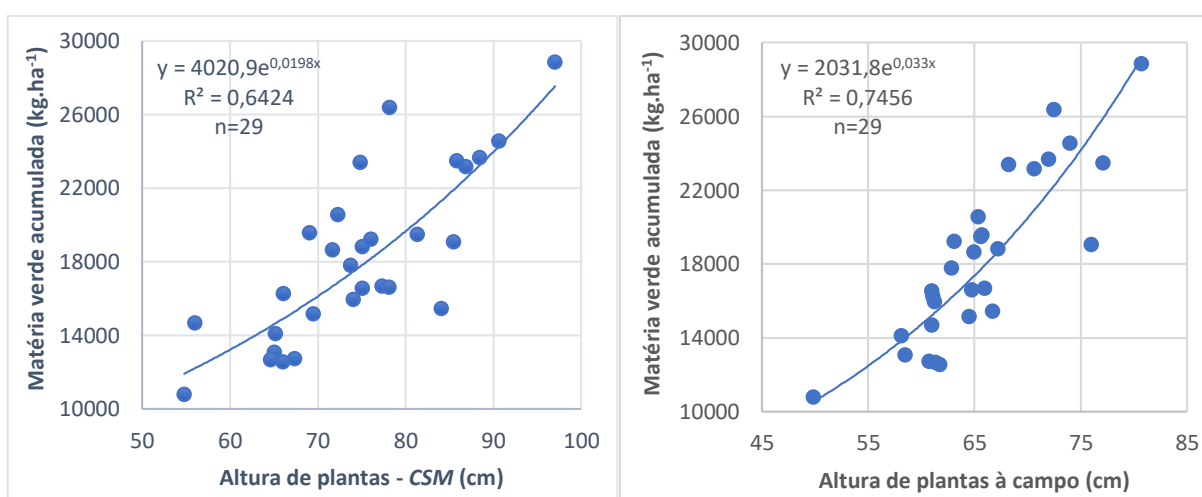
Figura 26 – Análise de regressão para produção de matéria verde com os dados referentes a segunda coleta.



Fonte: Autoria própria (2017).

A terceira, e última coleta, apresentou resultados inferiores as demais, em que a metodologia convencional se sobressaiu ao modelo gerado através do CSM. A regressão obtida através dos dados do RPAS resultou em uma correlação mediana ($R^2=0,6424$), enquanto a metodologia convencional alcançou o valor de 0,7456 (Figura 27). O erro relativo seguiu a mesmo padrão, resultando em 14,73 % e 12,58 %, respectivamente.

Figura 27 – Análise de regressão para produção de matéria verde com os dados referentes a terceira coleta.




Fonte: Autoria própria (2017).

O decréscimo na correlação entre altura de plantas e matéria verde acumulada pode ser explicado pelo estágio fenológico da cultura durante essa amostragem, caracterizado como enchimento de grãos. Nessa etapa, os fotoassimilados e nutrientes presentes nas folhas são direcionados para os grãos, causando um declínio no acúmulo de matéria verde. Além disso, a planta tende a cessar o seu crescimento, diminuindo a relação entre altura de plantas e matéria verde ou matéria seca acumulada.

A última análise envolvendo a produção de matéria verde utilizou todas as amostras provenientes das 3 coletas em uma única análise de regressão (Figura 28). Os modelos exponenciais apresentaram resultados próximos, onde a regressão proveniente dos dados de campo promoveu resultados levemente superiores, com coeficiente de determinação igual a 0,778 e erro relativo de 23,48 %. Por outro lado, a equação resultante dos dados coletados pelo RPAS teve correlação 0,7228, com erro relativo de 33,97 %.

Figura 28 – Análise de regressão para produção de matéria verde com o conjunto total de dados



Fonte: Autoria própria (2017).

De modo geral, os resultados para modelagem da produção de matéria verde em função da altura de plantas apresentaram resultados satisfatórios, dada a instabilidade desta variável, que se altera muito em função da quantidade de água presente na planta, influenciada não somente pelo estágio de desenvolvimento do

cultivo, mas pelas condições do tempo, como umidade relativa e precipitação pluviométrica (TILLY; AASEN; BARETH, 2015).

Nesse sentido, cabe ressaltar que os tratamentos presentes no experimento podem ter provocado alguma instabilidade nos resultados, especialmente quando considerado o déficit pluviométrico de 201 mm entre os meses de junho e agosto (POSSENTI et al. 2007), coincidindo com praticamente todo o período de desenvolvimento da cultura (Figura 29).

Figura 29 – Índice pluviométrico entre os meses de janeiro e agosto de 2017 para o município de Dois Vizinhos - PR



Fonte: Instituto Nacional de Meteorologia - INMET (2017).

Somado aos efeitos condicionados pelos tratamentos distintos, algumas parcelas apresentaram um certo subdesenvolvimento, apresentando um porte inferior ao esperado (Figura 24). Embora essa variabilidade possa exercer um efeito benéfico ao estudo em um primeiro momento, pois tende a melhorar a distribuição das amostras no modelo matemático, tornando o modelo mais robusto, também pode ser vista como um fator perturbador, uma vez que intempéries climáticas e aspectos nutricionais afetam o metabolismo das plantas, podendo alterar a relação entre altura de plantas e biomassa acumulada.

Como forma de minimizar estes efeitos, deve-se evitar a utilização do modelo universal, que apesar de ser mais versátil, tende a condicionar maiores erros quando

comparado aos modelos obtidos para os diferentes estádios de desenvolvimento da cultura.

Ao comparar os resultados obtidos no presente trabalho com os observados em pesquisas correlatas, é possível afirmar que estes foram satisfatórios. Shirrmann et al. (2016) em estudos com utilização de sensores RGB para modelagem da biomassa da cultura do trigo, obteve um modelo para estimativa de produção de matéria verde com R^2 entre 0,83 e 0,92, resultado similares ao do presente estudo, em que o coeficiente de determinação foi de 0,6424 a 0,945. No entanto, o erro relativo da pesquisa citada foi, de maneira geral, superior ao observado para a cultura da aveia preta, oscilando entre 14,98 e 18,4 %, enquanto resultados aqui apresentados ficaram entre 8,89 e 16,47 %.

De forma semelhante, Bendig et al. (2014) observou o mesmo padrão em seus estudos com a cultura da cevada, em que foram utilizados CSMs obtidos através de imagens coletadas por sensores RGB a bordo de uma plataforma RPAS. Em diversas regressões exponenciais, os referidos autores obtiveram R^2 variando entre 0,78 e 0,84.

Utilizando-se de um laser scanner terrestre (TLS), Tilly, Aasen e Bareth (2015) alcançaram um R^2 igual a 0,71 na análise de regressão entre a altura de plantas proveniente do CSM e a quantidade de matéria verde produzida na cultura da cevada. Esse resultado ilustra a dificuldade em modelar a produtividade de matéria verde das culturas em geral, onde mesmo os sensores ativos, que conseguem modelar a altura de plantas com alta precisão e detalhamento, não alcançam resultados altamente confiáveis.

5.2.4 Produtividade de matéria seca

Da mesma forma, para a modelagem da produção de matéria seca da aveia preta, foram realizadas regressões utilizando-se da altura de plantas proveniente do

CSM, as quais foram subdividas por coleta, além de uma análise universal, em que foi utilizado o conjunto total de dados (Tabela 8).

Tabela 8 – Resultados da análise de regressão para produção da matéria seca em função da altura de plantas proveniente do CSM

| Coleta | Modelo | Número de amostras | Equação | R ² | RMSE (kg.ha ⁻¹) | RE (%) |
|--------------------|-------------|--------------------|-------------------------|----------------|-----------------------------|--------|
| N°1 (11/08) | Linear | 30 | $y = 40,774x + 456,22$ | 0,8587 | 251,263 | 16,81 |
| N°2 (25/08) | Exponencial | 30 | $y = 1035,5e^{0,024x}$ | 0,9344 | 354,58 | 10,61 |
| N°3 (06/09) | Exponencial | 29 | $y = 1161,4e^{0,0193x}$ | 0,6481 | 715,62 | 14,15 |
| Universal* | Exponencial | 89 | $y = 814,33e^{0,025x}$ | 0,8969 | 695,76 | 21,23 |

Fonte: Autoria própria (2017).

Na sequência, a título de comparação, as mesmas regressões foram obtidas através dos dados de altura mensurados à campo, de acordo com a Tabela 9.


Tabela 9 – Resultados da análise de regressão para produção da matéria seca em função da altura de plantas mensurada à campo

| Coleta | Modelo | Número de amostras | Equação | R ² | RMSE (kg.ha ⁻¹) | RE (%) |
|--------------------|-------------|--------------------|-------------------------|----------------|-----------------------------|--------|
| N°1 (11/08) | Exponencial | 30 | $y = 275,99e^{0,0791x}$ | 0,8746 | 262,17 | 17,54 |
| N°2 (25/08) | Exponencial | 30 | $y = 385,26e^{0,0362x}$ | 0,9047 | 408,89 | 12,24 |
| N°3 (06/09) | Exponencial | 29 | $y = 636,3e^{0,0312x}$ | 0,7086 | 657,67 | 13,01 |
| Universal* | Exponencial | 89 | $y = 714,37e^{0,0282x}$ | 0,8673 | 655,72 | 20,01 |

Fonte: Autoria própria (2017).

A primeira amostragem teve resultados muito similares entre as duas metodologias (Figura 30), em que os dados coletados à campo apresentaram R² de 0,8746 contra 0,8587 da regressão de dados proveniente do CSM. No entanto, a equação obtida com dados de campo apresentou um erro relativo superior, perfazendo uma diferença de 0,73 %.

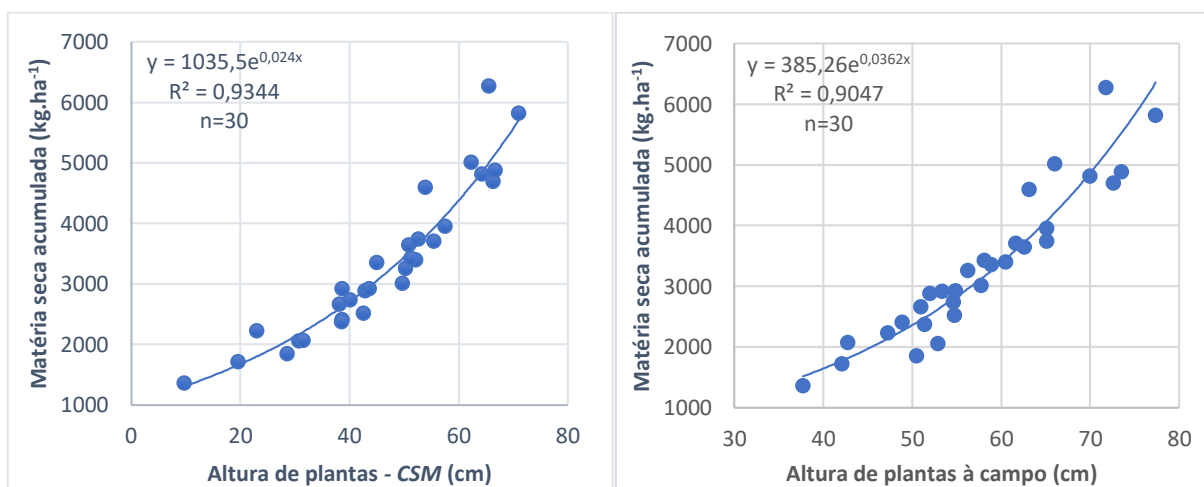
Figura 30 – Análise de regressão para produção de matéria seca com os dados referentes a primeira coleta.



Fonte: Autoria própria (2017).

Na segunda coleta (Figura 31), a exemplo da análise de matéria verde, foram obtidos os melhores resultados, tanto em termos de correlação quanto erro relativo. Nessa etapa, os dados provenientes do RPAS se demonstraram mais confiáveis que os coletados à campo, com R^2 de 0,9344 e erro relativo de 10,61 %. Já os dados mensurados a campo, também resultaram em uma alta correlação, alcançando 0,9047 e um erro relativo de 12,24%.

Figura 31 – Análise de regressão para produção de matéria seca com os dados referentes a segunda coleta.




Fonte: Autoria própria (2017).

A última amostragem novamente apresentou os piores resultados (Figura 32), em que as medidas coletadas à campo se demonstraram mais representativas quando comparadas as determinadas por meio do RPAS. Os resíduos do modelo

gerado com os dados de campo apresentaram um erro 1,14% menor, enquanto o R^2 foi de 0,7086, contra 0,6481 do modelo obtido através do CSM. Como já debatido na análise referente a produção de matéria verde, o declínio do coeficiente de determinação na última análise ocorre devido ao estágio fenológico da cultura, em que as plantas param de crescer, sendo o enchimento de grãos o principal responsável pelo aumento no acúmulo de matéria seca.

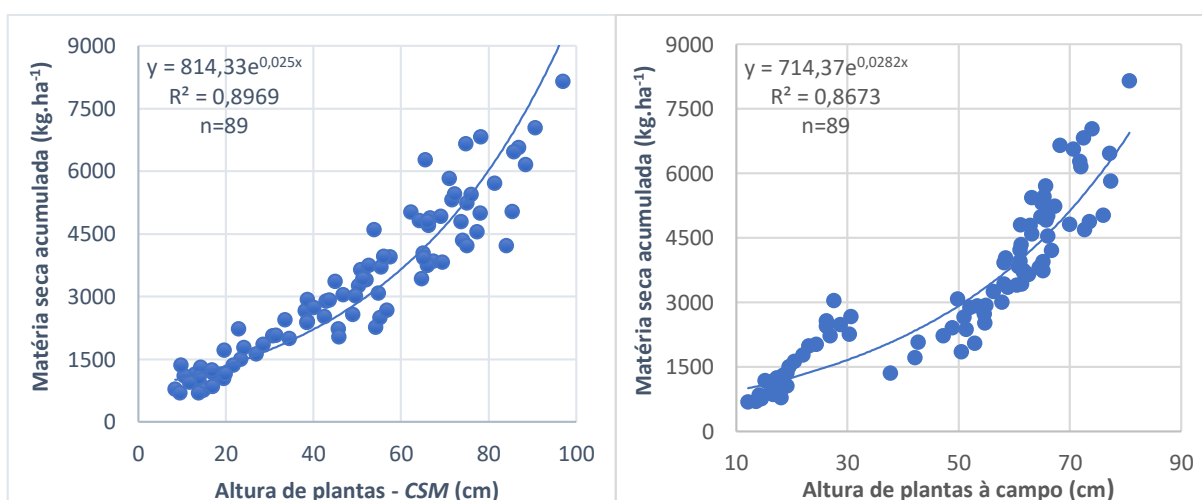
Figura 32 – Análise de regressão para produção de matéria seca com os dados referentes a terceira coleta.



Fonte: Autoria própria (2017).

Por fim, a última análise realizada utilizou o conjunto total de dados, compondo duas análises de regressão que resultaram em equações exponenciais (Figura 33). Os dados provenientes da plataforma RPAS alcançaram um R^2 de 0,8969 com erro relativo de 21,23 %. Por outro lado, o conjunto de dados mensurados à campo resultou em uma correlação de 0,8673 e erro relativo de 20,01 %, o que representa cerca de 650 kg.ha^{-1} .

Figura 33 – Análise de regressão para produção de matéria seca com o conjunto total de dados



Fonte: Autoria própria (2017).

No geral, a modelagem da produção de matéria seca alcançou resultados satisfatórios, tanto para o conjunto de dados provenientes do RPAS quanto para os dados medidos à campo. A diferença entre os dois métodos foi muito pequena em todas as regressões aqui testadas, demonstrando que as metodologias praticamente se equiparam de maneira geral.

Se tratando da análise universal, os resultados foram similares aos observados por Bendig et al. (2014) na cultura da cevada, resultando em um R^2 de 0,80. No entanto, o erro relativo foi praticamente o dobro do observado nesse estudo (44,61 %).

Shirrmann et al. (2016) em estudos com utilização de sensores RGB para modelagem da biomassa da cultura do trigo, alcançou resultados próximos aos aqui observados, com coeficiente de determinação entre 0,68 e 0,95. Com relação aos erros relativos, estes foram próximos aos obtidos nas missões individuais, partindo de 11,5 %, na primeira coleta, até os 17,07 % da última amostragem.

Também, Tilly, Aasen e Bareth (2015) em estudos envolvendo o uso de laser scanner terrestre (TLS) voltado a modelagem da produção de matéria seca para cultura da cevada, alcançou coeficiente de determinação igual a 0,85 em uma análise universal, resultado similar ao obtido.

Possoch et al., (2016) avaliou a utilização dos sensores RGB a bordo de um RPAS para a estimativa da produção de matéria seca em pastagem, onde o principal entrave fica por conta do porte reduzido das plantas, que no referido estudo, foi em média de 15 cm. Ainda assim, a análise de regressão executada alcançou um R^2 de 0,64, resultado superior ao observado com as medidas aferidas a campo ($R^2 = 0,62$).

Em comparação com a análise referente a produção de matéria verde, os resultados das análises de regressão apresentaram um comportamento mais estável, fato evidenciado pelos gráficos obtidos para as análises universais. Isso pode ser explicado pela flutuação do conteúdo de água nas plantas, que se altera em função de diversos fatores, especialmente o estágio de desenvolvimento da cultura, umidade do solo e condições atmosféricas (TILLY; AASEN; BARETH, 2015).

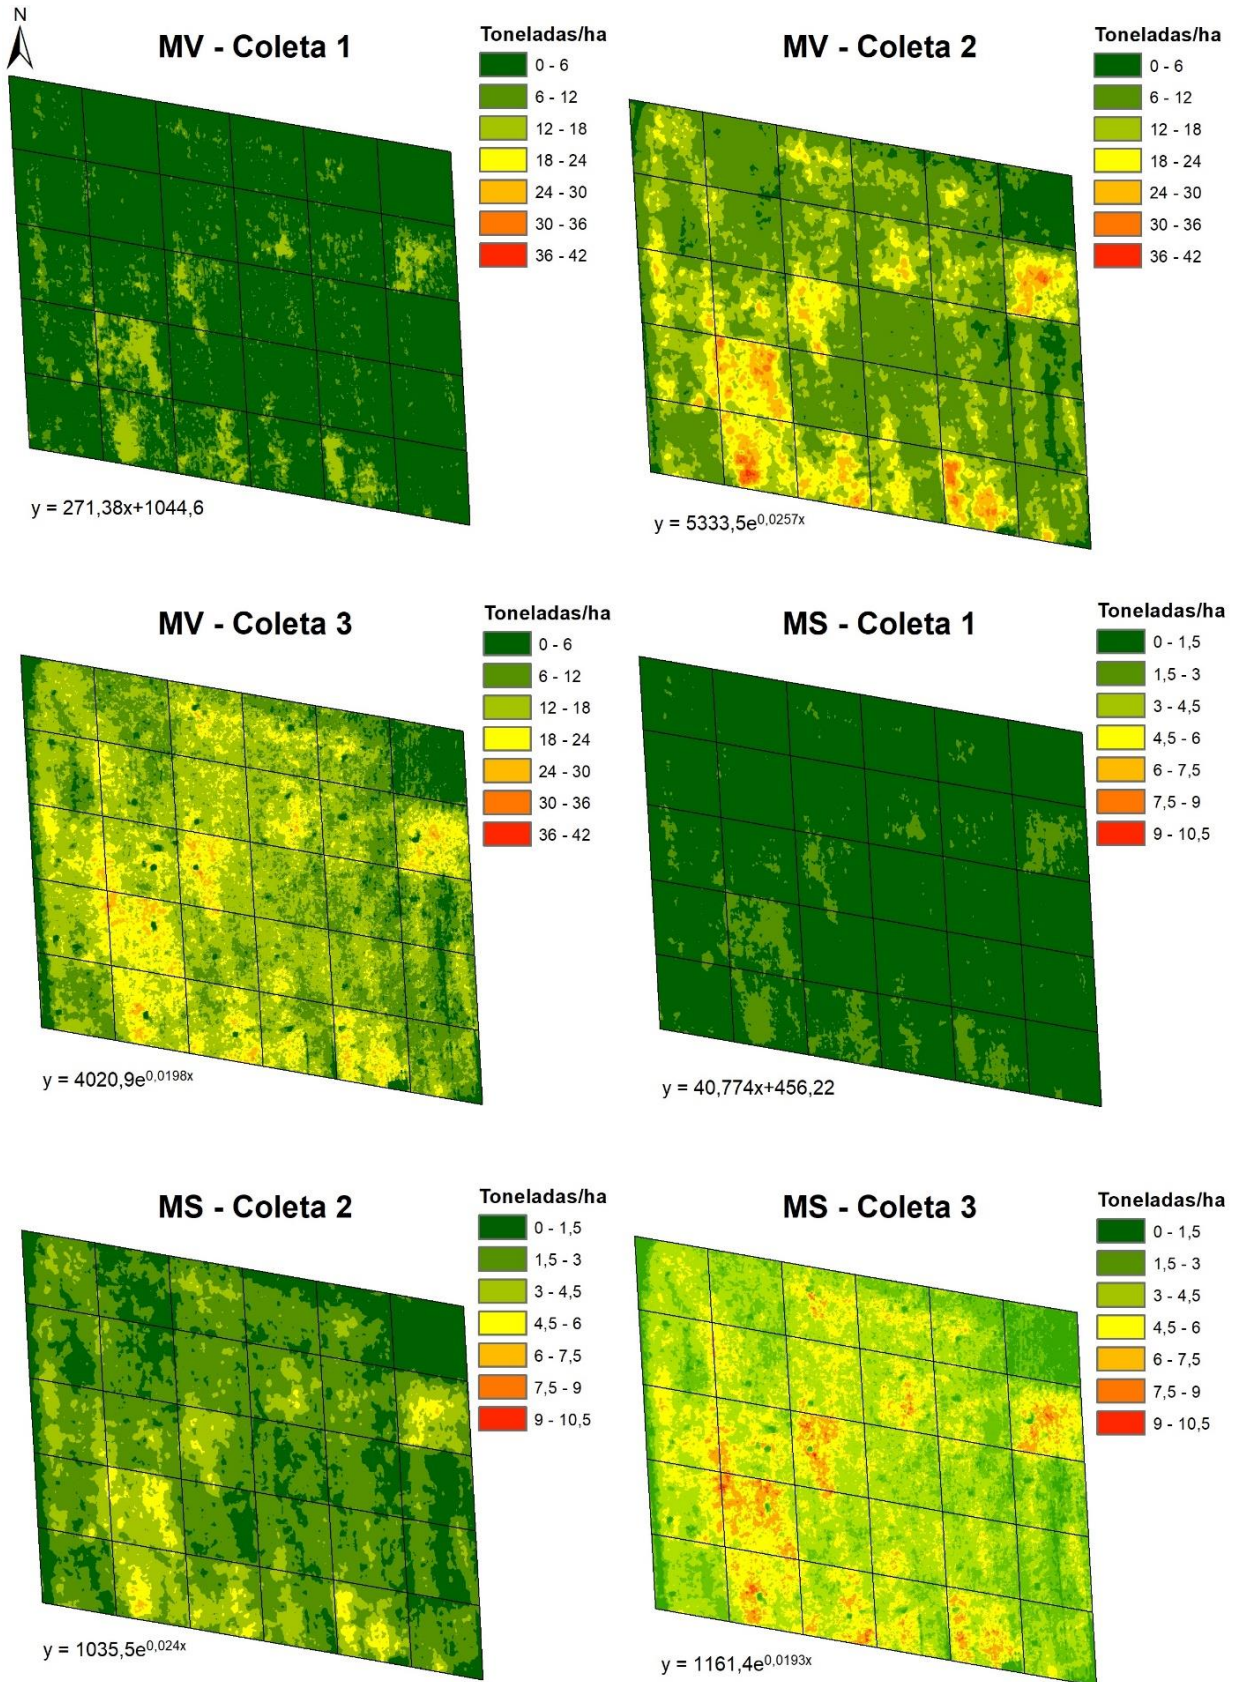
5.3 MAPAS DE PRODUTIVIDADE

A partir das equações obtidas através das análises de regressão, juntamente com os modelos digitais representando a altura de plantas (CSMs), foi possível a elaboração de mapas ilustrando a produtividade tanto para matéria seca, quanto para matéria verde na cultura da aveia preta (Figura 34).

Além de possibilitar a quantificação da produção em determinada área, os mapas de produtividade constituem uma importante ferramenta para que a variabilidade espacial da produtividade seja avaliada, permitindo identificar áreas pouco responsivas (zonas de manejo) e assim, otimizar as técnicas de manejo, reduzindo custos e maximizando a produtividade, princípio amplamente difundido pela Agricultura de Precisão (MOLIN, 2002).

A interpretação dos mapas de produtividade permite correlacionar diversos fatores que influenciam na produção ao longo do tempo, como a variação do tipo de solo na área plantada, níveis de acidez do solo em locais específicos, deficiência de fertilizantes, e até mesmo formulação inadequada de N-P-K, bem como falta ou excesso de água (CAPELLI, 2004).

Figura 34 – Mapas de produtividade ilustrando a matéria verde (MV) e matéria seca (MS) acumulada em função da altura de plantas proveniente do CSM



Fonte: Autoria própria (2017).

6 CONCLUSÕES

A utilização de imagens obtidas pela plataforma RPAS permitiu a obtenção de modelos digitais de terreno e de superfície com alto nível de detalhamento, compatíveis com aplicações que exigem produtos de qualidade em alta periodicidade, como é o caso da Agricultura de Precisão.

A modelagem da altura de plantas por meio de CSMs apresentou resultados satisfatórios para cultura da aveia preta, alcançando forte correlação com os dados aferidos à campo. A partir disso outras aplicações se tornam possíveis, como é o caso da estimativa da produção de biomassa dos cultivos.

Através de análises de regressão utilizando o conjunto de dados mensurado à campo, juntamente com a altura de plantas derivada dos CSMs, foram obtidos modelos capazes de estimar a quantidade de matéria verde e matéria seca produzida pela cultura da aveia preta de forma confiável, com resultados muitas vezes superiores aos observados na metodologia convencional. Além disso, as amostragens realizadas em diferentes estádios de desenvolvimento da cultura possibilitaram avaliar qual o momento mais adequado para prever a produtividade de biomassa da cultura.

O banco de dados gerado através do estudo possibilitou a obtenção de mapas temáticos ilustrando a produtividade de matéria verde e matéria seca na área de estudo. A interpretação destes dados permite monitorar a variabilidade espacial da produtividade frente a outros atributos, permitindo uma otimização na gestão e manejo da cultura.

7 CONSIDERAÇÕES FINAIS

Ainda que os resultados obtidos no presente trabalho comprovem a eficácia da metodologia na estimativa de parâmetros biofísicos da cultura da aveia preta, estudos mais aprofundados são necessários, dada a recente introdução desta tecnologia no mercado.

Um maior domínio dos algoritmos utilizados no processamento das imagens se faz necessário em virtude da complexidade destes procedimentos. A utilização de softwares voltados ao setor comercial, embora facilite o processamento como um todo, limita a personalização e aprofundamento das técnicas utilizadas, reduzindo o controle sob os resultados.

Como forma de consolidar a metodologia proposta, é de suma importância a implementação desta ferramenta no monitoramento de futuras safras, buscando expandir a sua utilização para maiores porções de área. Além de validar o uso da ferramenta em escala comercial, isso permitirá uma melhor compreensão das variáveis e das fontes de erro inerentes a coleta e processamento de dados, possibilitando a geração de produtos ainda mais confiáveis.

8 REFERÊNCIAS

ALVARENGA, R.C.; CABEZAS, W.A.L.; CRUZ, J.C.; SANTANA, D.P. Plantas de cobertura de solo para sistema plantio direto. **Informe Agropecuário**, v.22, p.25-36, 2001.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p.711-728, 2013.

BENDIG, J.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; EICHFUSS, S.; BARETH, G. Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. **Remote Sensing**, v. 6, n. 11, p.10395-10412, 2014.

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. 40, p. 4–6, 2013.

BHERING, S.B.; SANTOS, H.G. dos; BOGNOLA, I.A.; CÚRCIO, G.R.; MANZATTO, C.V.; CARVALHO JUNIOR, W. de; CHAGAS, C da S.; ÁGLIO, M.L.D.; SOUZA, J.S. de. **Mapa de solos do Estado do Paraná: legenda atualizada**. Rio de Janeiro: EMBRAPA/IAPAR, 74p. 2008.

BLASCHKE, T.; KUX, H. **Sensoriamento remoto e SIG avançados: novos sistemas e sensores inovadores**, 2 ed., São Paulo: Oficina de Textos, 304 p., 2007.

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**, v. 13, n. 3, p.2830-2847, 27 fev. 2013.

CAMPBELL, J. B.; WYNNE, R. H. **Introduction of Remote Sensing**. 5 ed. New York, Guilford Press, 667 p., 2011.

CAPELLI, N.L. **Agricultura de precisão-Novas tecnologias para o processo produtivo**. 2004. Disponível em: <<http://www.bases.cnptia.embrapa.br>> Acesso em: 11 nov. 2017.

EISENBEISS, H. **UAV photogrammetry**. 236 f. Tese (Doutorado). University Of Technology Dresden, Dresden, 2009.

DÀ-JIǺNG INNOVATIONS SCIENCE AND TECHNOLOGY CO. (DJI) (China). **Especificações**: Phantom 3 Advanced. 2015. Disponível em: <<http://www.dji.com/phantom-3-adv/info#specs>>. Acesso em: 10 out. 2017.

EHLERT, D.; HORN, H.; ADAMEK, R. Measuring crop biomass density by laser triangulation. **Computers And Electronics In Agriculture**, v. 61, n. 2, p.117-125, 2008.

EISENBEISS, H. **UAV photogrammetry**. 236 f. Tese (Doutorado). University Of Technology Dresden, Dresden, 2009.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. São Paulo: Oficina de Textos, 2011.

GRISE, M. M.; CECATO, U.; MORAES, A.; FACCIO, P. C. C.; CANTO, M. W.; JOBIM, C. C.; RODRIGUES, A. M. Avaliação do desempenho animal e do pasto na mistura aveia IAPAR 61 (*Avena strigosa* Schreb) e ervilha forrageira (*Pisum arvense* L.) manejada em diferentes alturas. **Revista Brasileira de Zootecnia**, v.31, n.3, p.1085-1091, 2002.

JORGE, L. A. C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. In: **Agricultura de precisão: resultados de um novo olhar**. 1 ed. Brasília: Embrapa, p. 109-134, 2014.

HAALA, N; ROTHERMEL, M. Dense Multi-Stereo Matching for High Quality Digital Elevation Models. **Photogrammetrie - Fernerkundung - Geoinformation**, v. 2012, n. 4, p.331-343, 2012.

HARTMANN, W.; TILCH, S.; EISENBEISS, H.; SCHINDLER, K. Determination of the UAV position by automatic processing of thermal images. International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**, v. 39, p. 111-116, 2012.

INCRA. **Norma Técnica para o Georreferenciamento de Imóveis Rurais**. 3 ed. 2013. Brasília, Disponível em: <<http://www.incra.gov.br/media/institucional/norma%20tecnica%20para%20georreferenciamento%20de%20imoveis%20rurais%203%20edi%C3%A7ao.pdf>>. Acesso em 20 de out. de 2017.

MASCHIO, A. V. **A estereoscopia: investigação de processos de aquisição, edição e exibição de imagens estereoscópicas em movimento**. 231f. Dissertação (Mestrado) – Pós-Graduação em Desenho Industrial, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Bauru, 2008.

MATESE, A.; TOSCANO, P.; DI GENNARO, S.F.; GENESIO, L.; VACCARI, F.P.; PRIMICERIO, J.; BELLI, C.; ZALDEI, A.; BIANCONI, R.; GIOLI, B. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. **Remote Sensing**, v. 7, n. 3, p.2971-2990, 2015.

MENESES, P. R. et al. **Introdução ao processamento de imagens de Sensoriamento Remoto**. Brasília: UNB, 2012. 276 p.

MOLIN, J.P. Definição de unidades de manejo a partir de mapas de produtividade. **Engenharia Agrícola**, Jaboticabal, v. 22, n. 1, p. 83-92, 2002.

MOREIRA, M. A.; RUDORFF, B. F. T. **Sensoriamento Remoto aplicado à agricultura**. São José dos Campos: INPE, 2002. (INPE-8984-PUD/62).

MOUTINHO, O. **Evaluation of Photogrammetric Solutions for RPAS: Commercial vs Open Source**. 2015. 120f. Dissertação (Mestrado) – Engenharia Geográfica, Universidade Do Porto, Porto, 2015.

MUNARETTO, L. **VANT e drones: a aeronáutica ao alcance de todos**. São José dos Campos: Edição independente, 2015.

POSSENTI, J.C.; GOUVEA, A.; MARTIN, T.; CADORE, D. Distribuição da precipitação pluvial em Dois Vizinhos, Paraná, Brasil. In: **Seminário de Produção Agropecuária, Dois Vizinhos, PR. Anais**. Dois Vizinhos, PR: UTFPR. p.1-3, 2007.

POSSOCH, M., BIEKER, S., HOFFMEISTER, D., BOLTEN, A., SCHELLBERG, J. AND BARETH, G. Multi-temporal crop surface models combined with the RGB vegetation index from UAV-based images for forage monitoring in grassland. **Isprs - International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, v. -1, p.991-998, 2016.

SCHIRRMANN, M.; GIEBEL, A.; GLEINIGER, F.; PFLANZ, M.; LENTSCHKE, J.; DAMMER, K.H.. Monitoring Agronomic Parameters of Winter Wheat Crops with Low-Cost UAV Imagery. **Remote Sensing**, v. 8, n. 9, p.706-725, 2016.

SHIRATSUCHI, L. S. et al. **Sensoriamento Remoto: Conceitos básicos e aplicações na Agricultura de Precisão**. In: BERNARDI, A. C. et al. Agricultura de Precisão: Resultados de um novo olhar. Brasília: Embrapa Instrumentação, p.58-73, 2014.

SILVA, E. T. J. B. Veículos aéreos não tripulados: panorama atual e perspectivas para o monitoramento de atividades ilícitas na Amazônia. In: **SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO**. Foz do Iguaçu: INPE. p. 9324- 9331, 2013.

SOUSA, H. L. Sensoriamento Remoto com VANTs: uma nova possibilidade para a aquisição de geoinformações. **Revista brasileira de Geomática**, Curitiba, v. 5, n. 3, p. 326-342, 2017.

SULEBAK, J.R. **Applications of digital elevation models**. DYNAMAP Project Oslo, 2000.

TEMBA, P. **Fundamentos de fotogrametria**. Belo Horizonte: UFMG; 2000. Disponível em: <<http://www.csr.ufmg.br/geoprocessamento/publicacoes/fotogrametria.pdf>>. Acesso em: 12 out. 2017.

TILLY, N; AASEN, H; BARETH, G. Fusion of Plant Height and Vegetation Indices for the Estimation of Barley Biomass. **Remote Sensing**, v. 7, n. 9, p.11449-11480, 2015.

VALAVANIS, K. P; VACHTSEVANOS, G. J. **Handbook of unmanned aerial vehicles**. Springer Netherlands, 2015.

VERHOEVEN, G. Taking computer vision aloft - archaeological three-dimensional reconstructions from aerial photographs with photostan. **Archaeological Prospection**, v. 18, n. 1, p.67-73, 2011.