

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA – CAMPUS MONTE
CARMELO
ENGENHARIA DE AGRIMENSURA E CARTOGRÁFICA**

CARLOS ALBERTO MATIAS DE ABREU JÚNIOR

**USO DE IMAGENS MULTIESPECTRAIS NA ESTIMATIVA DE
PRODUTIVIDADE EM ÁREAS DE CULTURAS CAFEEIRAS**

MONTE CARMELO

2019-2

CARLOS ALBERTO MATIAS DE ABREU JÚNIOR

**USO DE IMAGENS MULTIESPECTRAIS NA ESTIMATIVA DE
PRODUTIVIDADE EM ÁREAS DE CULTURAS CAFEEIRAS**

Trabalho apresentado como requisito para a obtenção de aprovação na disciplina de Trabalho de Conclusão de Curso 2 do curso de Engenharia de Agrimensura e Cartográfica da Universidade Federal de Uberlândia.

Orientador: Prof. Dr. George Deroco Martins.

MONTE CARMELO

2019-2

AGRADECIMENTOS

Neste momento, próximo ao fim de um ciclo, agradeço enormemente a todos que foram importantes de alguma forma em minha caminhada. Foram cinco anos de muitos aprendizados e aprimoramento moral, intelectual e social. Dessa forma, ressalto principalmente aqueles que mais me ajudaram neste período.

Agradeço primeiramente a Deus, por me permitir ter alcançado este objetivo, sempre me abençoando a medida do meu esforço e merecimento.

Aos meus pais, Carlos Alberto e Josina, que são minha base para tudo que tenho na vida. Jamais esquecerei os seus esforços incondicionais e empenho em sempre me proporcionar o melhor. Sem vocês tudo teria sido exponencialmente mais difícil. Vocês são o meu bem mais precioso.

Aos meus irmãos Jhonathan e Eduarda, por serem exemplos, e estarem ao meu lado me dando força e acreditando em mim.

Ao meu sobrinho Miguel, que sempre proporcionou bons momentos e por renovar minha felicidade com as suas visitas.

A minha namorada Pâmela, pelo seu companheirismo imensurável, que sempre me confortou e deixou meus dias mais leves e tranquilos.

Ao meu orientador, George Deroco, por toda sabedoria e conhecimento transmitidos ao longo desses anos e por toda confiança depositada em mim.

Ao professor Claudionor, por ter aberto a porta da ciência para mim, e me feito enxergar um novo caminho a ser seguido.

À Universidade Federal de Uberlândia – Campus Monte Carmelo, por todo o suporte fornecido durante a pesquisa e a minha formação.

A todos os demais docentes e colegas do curso de Engenharia de Agrimensura e Cartográfica que fizeram parte de alguma forma dessa etapa. Obrigado!

RESUMO

O Brasil se destaca entre os maiores produtores e exportadores de café do mundo, e segundo a expectativa da CONAB, para o país manter-se na frente às necessidades da demanda, do mercado interno e de exportação, o país deve cumprir a expectativa de produção esperada do produto no corrente ano-safra comercial. Por meio da agricultura de precisão, é possível gerar modelos, a partir de métodos de regressão, que identifiquem áreas com potencial para maiores e menores produtividades. Tendo em vista tais aspectos, neste trabalho objetivou-se a geração de modelos para estimativa de parâmetros agronômicos do café, tais como a produtividade, tipo de frutos advindos do processo de maturação e o peso total dos frutos. Para isto, foram utilizadas imagens oriundas de levantamentos aerofotogramétricos realizados com o drone Phantom 4 Advanced e imagens multiespectrais de sensores orbitais, tais como o satélite RapidEye e Sentinel 2. No primeiro experimento, para a variável produtividade, os melhores resultados de RMSE e R^2 (em porcentagem) foram obtidos pelos satélites Sentinel 2 e RapidEye, com os valores de 36,46% e 46,57% respectivamente. Para as variáveis frutos do tipo seco, cereja e peso total dos frutos, os modelos com menor resultado de RMSE foram obtidos pelo drone (seco e cereja) e RapidEye (fruto do tipo seco), com resultados de 31,20%, 61,81% e 23,58% respectivamente. Para R^2 os maiores resultados para os parâmetros citados anteriormente foram obtidos pelo Sentinel 2, drone e RapidEye com os valores de 48,19%, 27,53% e 48,2% respectivamente. No segundo experimento, foram comparados os resultados dos modelos obtidos entre as imagens orbitais corrigidas atmosféricamente e as sem correção atmosférica, para analisar onde se encontravam as maiores diferenças dos valores estimados pelos modelos nos dois cenários.

Palavras chave: Cafeicultura, Parâmetros agronômicos, Índices de vegetação, Mapas.

ABSTRACT

Brazil stands out among the largest coffee producers and exporters in the world, and according to CONAB's expectation, for the country to stay ahead of the demand, domestic and export needs, the country must meet the expected production. expected in the current crop year. Through precision agriculture, it is possible to generate models from regression methods that identify areas with potential for higher and lower yields. In view of these aspects, this work aimed to generate models for estimating coffee agronomic parameters, such as yield, type of beans from the maturation process and total weight of beans. For this, we used images from aerophotogrammetric surveys performed with the Phantom 4 Advanced drone and multispectral images of orbital sensors, such as the RapidEye and Sentinel 2 satellite. In the first experiment, for the productivity variable, the best RMSE and R^2 results were obtained by Sentinel 2 and RapidEye satellites, with values of 36.46 and 46.57 respectively. For the variables dry grain, cherry and total grain weight, the models with lower RMSE results were obtained by drone (dry and cherry) and RapidEye (dry grain), with results of 31.20, 61.81 and 23.58 respectively. For R^2 the highest results for the previously mentioned parameters were obtained by Sentinel 2 satellite, drone and RapidEye with values of 48.19, 27.53 and 48.2 respectively. In the second experiment, the results of the models obtained were compared between the atmospheric corrected orbital images and those without atmospheric correction, to analyze where the biggest differences of the values estimated by the models were in the two scenarios.

Keywords: Coffee growing, Agronomic parameters, Vegetation index, Maps.

LISTA DE FIGURAS

Figura 1	Reflectância de uma folha saudável	18
Figura 2	Iteração entre camadas de folhas e REM para a região do infravermelho próximo	19
Figura 3	Levantamento aerofotogramétrico a partir de parâmetros pré-estabelecidos em planejamento de voo	24
Figura 4	O TGI é definido como a área do triângulo sobre o espectro visível	29
Figura 5	Mapa de localização da área de estudo	32
Figura 6	Placa da câmara Mapir 3	Erro! Indicador não definido.
Figura 7	Drone Phantom 4 Advanced	34
Figura 8	Receptor GNSS RTK	34
Figura 9	Fluxograma metodológico	37
Figura 10	Exemplo da distribuição espacial de pontos para coleta in situ, gerada aleatoriamente pelo software QGIS, para compor o planejamento de campo	38
Figura 11	Histograma e curva de distribuição normal das variáveis de estudo	44
Figura 12	Gráficos de regressão da correlação dos valores de produtividade estimados em campo e os valores de radiométrica da imagem RGB do drone (reflectância da banda correspondente ao índice TGI)	50
Figura 13	Gráficos de regressão da correlação dos valores de produtividade estimados em campo e os valores de radiométrica da imagem multiespectral do satélite RapidEye	51
Figura 14	Gráficos de regressão da correlação dos valores de produtividade estimados em campo e os valores de radiométrica da imagem multiespectral do satélite Sentinel 2	52
Figura 15	Distribuição espacial da produtividade na área de estudo, proveniente do modelo aplicado sobre a banda com os valores de reflectância do índice TGI do drone	54
Figura 16	Distribuição espacial da produtividade na área de estudo, proveniente do modelo aplicado sobre a banda do infravermelho próximo do satélite Sentinel 2	55
Figura 17	Gráficos de regressão da correlação dos valores de frutos do tipo seco e cereja (Gráficos 1 e 2) estimados em campo e os valores de	

radiométrica da imagem RGB do drone (reflectância da banda correspondente ao índice TGI e VDVI)	56
Figura 18 Gráficos de regressão da correlação dos valores de peso total das amostras estimado em campo e os valores de radiométrica da imagem multiespectral do satélite RapidEye (reflectância da banda Red Edge)	57
Figura 19 Gráficos de regressão da correlação dos valores de fruto do tipo seco das amostras estimado em campo e os valores de radiométrica da imagem multiespectral do satélite Sentinel 2 (reflectância da banda correspondente ao índice ARVI)	58
Figura 20 Distribuição espacial dos frutos do tipo cereja na área de estudo, proveniente do modelo aplicado sobre a banda com os valores de reflectância do índice TGI do drone	60
Figura 21 Distribuição espacial dos frutos do tipo seco na área de estudo, proveniente do modelo aplicado sobre a banda com os valores de reflectância do índice TGI do drone	61
Figura 22 Distribuição espacial do peso total dos frutos na área de estudo, proveniente do modelo aplicado sobre a banda RedEdge do satélite RapidEye	62
Figura 23 Reflectância das bandas dos dados utilizados para correlação e geração dos modelos empíricos de estimativa de parâmetros agronômicos dos satélites RapidEye (1) e Sentinel 2 (2)	63
Figura 24 Diferença entre os modelos empíricos para estimativa de peso total, gerados através das imagens com e sem correção atmosférica, do satélite RapidEye	65
Figura 25 Diferença entre os modelos empíricos para estimativa de produtividade, gerados através das imagens com e sem correção atmosférica, do satélite Sentinel 2	66

LISTA DE TABELAS

Tabela 1	Parâmetros utilizados no planejamento de voo	39
Tabela 2	Análise descritiva das variáveis estudadas	43
Tabela 3	Correlação entre as bandas e índices de vegetação da câmara RGB embarcada no drone e os parâmetros agronômicos	45
Tabela 4	Correlação entre as bandas e IV do satélite RapidEye sem correção e os parâmetros agronômicos	46
Tabela 5	Correlação entre as bandas e os IV do satélite Sentinel 2 sem correção e os parâmetros agronômicos	47
Tabela 6	Correlação entre as bandas e os IV do satélite RapidEye com correção e os parâmetros agronômicos	48
Tabela 7	Correlação entre as bandas e os IV do satélite Sentinel 2 com correção e os parâmetros agronômicos	49
Tabela 8	Modelos matemáticos gerados empiricamente para estimativa de produtividade	53
Tabela 9	Modelos matemáticos gerados empiricamente para estimativa de parâmetros agronômicos	59

SUMÁRIO

1 INTRODUÇÃO	11
2 OBJETIVO	12
3 JUSTIFICATIVA	12
4 REVISÃO BIBLIOGRÁFICA	14
4.1 Produtividade de cultivos	14
4.1.1 Produtividade em culturas cafeeiras	15
4.2 Desenvolvimento dos frutos de café – processo de maturação e tipos de frutos	16
4.3 Sensoriamento remoto da vegetação	17
4.4 Sensoriamento remoto e a agricultura de precisão	19
4.5 Aeronaves remotamente pilotadas (ARP)	22
4.5.1 Legislação	22
4.5.2 Plano de voo	23
4.6 Processamento de Imagens	24
4.6.1 Correção Atmosférica	24
<i>4.6.1.1 Correção atmosférica pelo método Fast Line Atmospheric Analysis of Spectral Hypercubes (FLAASH)</i>	25
4.6.2 Índices de vegetação	26
4.7 Análise estatística de dados	30
5 MATERIAL E MÉTODOS	32
5.1 Área de estudo	32
5.2 Material	33
5.3 Métodos	36
5.3.1 Planejamento de campo	37
<i>5.3.1.1 Planejamento de voo</i>	39
5.3.2 Aquisição dos dados	39
<i>5.3.2.1 Georreferenciamento e coleta das amostras</i>	40
<i>5.3.2.2 Aquisição de imagens orbitais</i>	40
5.3.3 Processamento digital de imagens	41
<i>5.3.3.1 Correção atmosférica</i>	41
5.3.4 Experimentos realizados	41
<i>5.3.4.1 Experimento I</i>	41
<i>5.3.4.2 Experimento II</i>	42
6 RESULTADOS E DISCUSSÕES	43

6.1 Análise descritiva dos dados	43
6.2 Análise multivariada dos parâmetros agronômicos	45
6.2.1 Imagens orbitais sem correção atmosférica	46
6.2.2 Imagens orbitais com correção atmosférica	47
6.3 Experimento 1	49
6.3.1 Estimativa de modelos empíricos para predição de produtividade	49
6.3.1.1 <i>Distribuição espacial da produtividade sobre a área de estudo</i>	53
6.3.2 Estimativa de modelos empíricos para predição qualitativa de frutos	56
6.3.2.1 <i>Distribuição espacial dos parâmetros agronômicos sobre a área de estudo</i>	59
6.4 Experimento II: comparação entre os modelos com correção e sem correção	62
7 CONSIDERAÇÕES FINAIS	66
REFERÊNCIAS	68

1 INTRODUÇÃO

A produção de café impulsiona fortemente as atividades de indústria e comércio do Brasil, assim como gera uma gama de empregos nas regiões onde ocorre sua produção. Essa variedade de regiões produtoras e a extensão dessas áreas fazem com que o Brasil seja o maior produtor mundial de café e o segundo maior mercado consumidor (ARRUDA, 2017). A projeção realizada pelo Conselho dos Exportadores de Café do Brasil (CECAFÉ) aponta que até 2030 o consumo mundial deve aumentar por volta de 30% e atingir 204,65 milhões de sacas. Assim, para que o Brasil conserve sua posição no mercado é necessário que a produção nacional aumente por volta de 16,17 milhões de sacas até 2030 (EMBRAPA, 2018).

Para aumentar a produtividade, é necessário conhecer corretamente as variáveis facilitadoras e causadoras da variabilidade do café. Segundo Pereira et al. (2011), uma estratégia para aumentar a produtividade é a redução do espaçamento entre as linhas e as plantas na linha de plantio. Para Ferraz et al. (2012), quando se deseja aumentar a produtividade é fundamental conhecer o nível nutricional do solo. Nesse estudo, os autores avaliaram a variabilidade de fósforo e potássio ao longo de uma lavoura, e constataram que as áreas mais produtivas estavam onde os solos eram bem nutridos. Em contrapartida, a presença de patógenos em culturas cafeeiras é um dos principais causadores da queda de produção. Dentre os fitoparasitas, destacam-se os nematoides, que podem causar perdas consideráveis na área plantada, e consequente queda na produtividade (ITO, 2012).

Tendo isso em vista, o sensoriamento remoto surge como uma alternativa para a determinação de parâmetros agrônômicos, tais como a produtividade. A interação da radiação eletromagnética (REM) com os parâmetros agrícolas tem se mostrado eficiente na estimativa de produtividade de diversas culturas agrícolas, a partir de imagens orbitais. A fim de determinar a produtividade da cana-de-açúcar nas safras 2004/2005 2005/2006, Picoli et al. (2009), utilizaram imagens provenientes do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS).

Ao utilizar imagens provenientes do mesmo sensor, Johann et al. (2012) tentaram estimar a produtividade da soja e do milho no estado do Paraná. Através dos resultados gerados os autores constataram que a metodologia utilizada é altamente eficiente, e que pode ser replicada para o mapeamento dessas culturas. Além das culturas mencionadas também é possível constatar a eficiência do sensor na estimativa de produtividade do café (BISPO, 2018).

Nesse contexto, faz-se necessário que seja verificada a viabilidade dessa ferramenta como uma forma de manejo específica e local para a estimativa de produtividade, visto a sua vasta aplicabilidade com outros parâmetros agronômicos, e produtividade em larga escala. Diante do exposto, considerando o relativo sucesso na estimativa de produtividade em imagens orbitais de media resolução espacial, o presente trabalho levanta a hipótese de se prever produtividade e os tipos de frutos advindos do processo de maturação em escala local de culturas cafeeiras, através de produtos com alta resolução espacial, considerando parâmetros agronômicos estimados *in situ*.

2 OBJETIVO

O presente trabalho teve como objetivo estimar parâmetros agronômicos, tais como a produtividade e os tipos de frutos, de uma área de cultura cafeeira utilizando imagens multiespectrais. Tendo isto em vista, foram objetivos específicos:

- Avaliar o potencial das imagens multiespectrais na estimativa de parâmetros agronômicos em escala local;
- Avaliar a diferença entre as imagens orbitais corrigidas atmosféricamente ou não na predição de modelos empíricos.

3 JUSTIFICATIVA

É fato que o sensoriamento remoto, em razão de seu custo/benefício vem alcançando grande importância e sendo utilizado cada vez mais para o monitoramento de culturas e plantações agrícolas. Uma das tecnologias que tem impulsionado o sensoriamento remoto fortemente na Agricultura de Precisão (AP) são as Aeronaves Remotamente Pilotadas (ARP), que possibilitam o monitoramento mais frequente das plantações agrícolas, auxiliando nos processos de tomada de decisão nos principais meios agronômicos. A velocidade de disseminação desta tecnologia tem a tornado uma das mais importantes na AP atualmente (DAMIAN et al., 2016).

A AP tem como um de seus objetivos auxiliar a determinação de parâmetros agronômicos que facilitem as atividades de campo e aumentem a produtividade das lavouras. Para se estimar a produtividade de culturas agrícolas é necessário que se conheça o comportamento de cada cultura analisada, a fim de encontrar possíveis padrões de produção

característicos de cada plantação. Dessa forma, os principais desafios surgem de culturas que apresentam comportamentos mais específicos, como por exemplo, o café.

O café é uma das principais culturas cultivada no país. Entretanto, o comportamento dessa cultura apresenta algumas características próprias que dificultam a estimativa de sua produtividade. A bienalidade do café faz com que sua produção passe por anos de alta e baixa, que alternam entre si. Isso faz com que a determinação da sua produtividade dependa também da análise de séries históricas de dados, o que gera custos operacionais sistemáticos. Nesse contexto, a correlação dos dados estimados em campo com imagens de sensoriamento remoto apresentam grande potencial, principalmente para a redução de gastos e aumento do lucro obtido pelos produtores (SILVA; REIS, 2013).

Metodologias que visam o aumento do lucro nas plantações favorecem a todos os produtores, entretanto, o alto valor das tecnologias que forneçam esse aumento são por vezes restritivos. Uma parcela substancial da produção nacional parte de pequenos produtores (agricultura familiar), que conseqüentemente possuem menos recursos disponíveis para aplicação em tecnologias mais aprimoradas (BRASIL, 2018). Esse cenário faz com que as ARP e sensores de baixo custo tenham sido desenvolvidos (CUNHA; NETO, 2017) e ganhado mais espaço na agricultura. Paralelamente a isso, os modelos de estimativa de produtividade atuais visam principalmente a caracterização da produção em escala global. O que deixa lacunas e carência em metodologias científicas que visam estimar a produtividade local dos produtores.

Dessa forma, esse trabalho se mostra importante, pois seus resultados visam amparar um dos principais setores da economia nacional, assim como analisar a potencialidade das geotecnologias neste meio. Sendo assim, é visado também amparar os pequenos e médios produtores, além de propor uma nova metodologia que possa ser empregada na obtenção da parâmetros agrônômicos, tais como a produtividade e os tipos de frutos, em escala local.

4 REVISÃO BIBLIOGRÁFICA

4.1 Produtividade de cultivos

A produtividade de uma cultura agrícola pode ser definida como a quantidade de produção por unidade de área. Uma das formas de se estimar a produtividade é através dos Índices de vegetação (IV). Segundo Formaggio e Sanches (2017), o IV mais empregado para calcular o vigor físico das culturas é o NDVI.

Os mapas de produtividade servem, sobretudo para enfatizar quais áreas produzem mais, e quais áreas estão em déficit de produção. Entretanto, este não especifica quais causas estão por trás desse aumento ou queda de produtividade. Existem vários fatores que podem prever essa oscilação, tais como fitopatologias, questões pedológicas, deficiências nutricionais ou escassez hídrica.

Todavia, conhecer a produtividade de uma área, é essencial não só para estimar o seu lucro, mas também para realizar tomadas de decisões importantes sobre a lavoura. Os mapas obtidos podem não trazer a informação específica sobre quais fatores alteraram a produtividade nas parcelas da plantação, entretanto, auxiliam no direcionamento sobre quais áreas devem ser investigadas, o que o torna uma ferramenta essencial na AP.

Para estimar a produtividade é necessário estabelecer relações entre os dados de imagens com os parâmetros biofísicos mensurados em campo. Segundo Formaggio e Sanches (2017), ao se acoplar sensores que medem o fluxo de frutos colhidos a uma máquina colhedora, é possível imagear a colheita de frutos em cada área específica, para que sejam estabelecidas relações diretas entre o NDVI e a produtividade de cada parcela de produção. Após isso, é possível gerar um mapa com toda a produtividade do local.

A parte disso é imprescindível a compreensão de que cada mapa de produtividade apresenta a sua peculiaridade, assim como seus fatores específicos de produção. Sendo assim, quando são gerados modelos para mapear culturas agrícolas, estes modelos devem referir somente a plantação a qual os dados foram coletados. E, portanto, não servem para generalizar e especializar informações referentes a outras culturas e plantações, principalmente quando se tem alguma distância entre elas (FORMAGGIO; SANCHES, 2017).

4.1.1 Produtividade em culturas cafeeiras

O café é uma cultura bienal. Isso implica que, a sua produtividade passa por ciclos que alternados a cada ano, apresentam normalmente um ano de baixa e um ano de alta produção. A bienalidade do café, ou ainda, o diferencial produtivo anual do café, é um dos fatores que mais influência sua produtividade.

No Brasil, a bienalidade do café pode ser observada se considerarmos a série histórica de produtividade do país. Entretanto, existem fatores que amenizam essas diferenças na cafeicultura nacional. A diferença de idade entre as lavouras em todo país faz com que enquanto algumas plantações estejam na época de baixa, outras esteja na época de alta, o que diminui a oscilação entre as safras no cenário nacional. Estima-se que caso as safras tivessem um comportamento mais homogêneo, a diferença pudesse ser de até cinco vezes de um ano para o outro (DAMATTA et al., 2007; SILVA; TEODORO; MELO, 2008).

Segundo Silva e Reis (2013), a bienalidade do café pode ser justificada pela diferença de funções vegetativas e produtivas que podem afetar um mesmo ramo da planta. A insuficiência apresentada pelo café para produzir reservas que satisfaçam o crescimento e frutificação simultaneamente, faz com que em cada ano as reservas sejam utilizadas para uma função. Isto é, em um ano as reservas produzidas pelo café serão destinadas a frutificação, o que aumentará a sua produtividade. Por consequência, no outro ano tais reservas serão destinadas ao crescimento, o que acarretará uma queda na produtividade.

Existem ainda fatores relacionados ao stress individual de cada planta (MAZZAFERA; CARVALHO, 1987), ao espaçamento entre plantas (Pereira et al., 2011), as variáveis de fósforo e potássio no solo (FERRAZ et al., 2012), além de diferentes fontes de nitrogênio (LIMA et al., 2016) que contribuem com a variação da produtividade.

Além dos fatores dispostos acima, a produtividade do café ainda pode ser afetada pela presença de patógenos nas culturas. Entre eles, os aspectos relacionados à ocorrência de pragas e doenças durante o ciclo da cultura estão entre os mais significativos. Dentre os diversos fatores que causam sérios prejuízos e, principalmente perdas na produtividade na cultura do café estão os fitonematoides, onde os pertencentes ao gênero *Meloidogyne*, conhecidos como nematoides de galhas têm maior destaque (ITO, 2012).

Uma parcela substancial das espécies de nematoides do solo alimenta-se diretamente nas raízes das plantas, às vezes causando sintomas visíveis (SBN, 2016). No Brasil, *M. incognita*, *M. paranaensis* e *M. exigua* constituem as principais espécies por consequência dos danos que causam e pela ampla distribuição nas áreas produtoras de café (LUC;

SIKORA.; BRIDGE, 2005). Os nematoides danificam drasticamente a integridade das raízes, causando escamações em sua superfície, com aspecto de cortiça, com descascamento, rachaduras e pontos de lesões necróticas. Na parte aérea das plantas, os sintomas são clorose, desfolhamento, redução no crescimento e às vezes morte da planta (FERRAZ, 2012). Portanto, para que a produtividade de uma cultura cafeeira seja estimada com precisão, é importante que esses fatores estejam bem delimitados.

4.2 Desenvolvimento dos frutos de café – processo de maturação e tipos de frutos

Existem diversos fatores que podem influenciar e modificar as características físicas e químicas do café, dentre elas, podemos citar os fatores genéticos, ambientais, nutricionais, manejo da lavoura, colheita, preparo, etc. Dentre os apresentados, com exceção dos genéticos e ambientais, todos os outros fatores que envolvem as características físicas e químicas da planta podem ser controlados depois da implantação da lavoura. As manipulações ocorrem não só no manejo, mas também na fase de colheita e preparo do café, cujo são dedicados esforços para alcançar, e posteriormente, preservar a máxima qualidade do café (MESQUITA et al., 2016).

O café passa por diversas etapas de crescimento até atingir a sua completa maturação. Todos os cuidados dedicados a planta, desde o momento da sua plantação, são importantes, e impactarão de forma ímpar e direta na obtenção de cerejas sadias e graúdas. Na fase inicial de crescimento do café, os frutos chumbinhos ficam adormecidos durante um período próximo a seis semanas. Quando entram na etapa de crescimento e granação, o café se desenvolve rapidamente, até que o fruto verde atinja seu tamanho final. Alguns fatores podem prejudicar as etapas iniciais de crescimento e desenvolvimento do café, tais como o déficit hídrico, a deficiência nutricional e a incidência de doenças. Quando esses fatores ocorrem, podem resultar na queda prematura dos chumbinhos (MESQUITA et al., 2016).

Após isso, inicia-se o processo de formação da semente (endosperma), que a primeiro momento possui o aspecto leitoso. Nestas circunstâncias, ocorre uma pausa no crescimento durante um determinado período, para que aconteça o endurecimento da semente (granação). Da mesma forma que na etapa inicial, durante a formação do fruto pode haver prejuízos no seu desenvolvimento em função de estiagens prolongadas, altas temperaturas e deficiência nutricional. Esses fatores podem ocasionar o surgimento de frutos chochos e mal granados (MESQUITA et al., 2016).

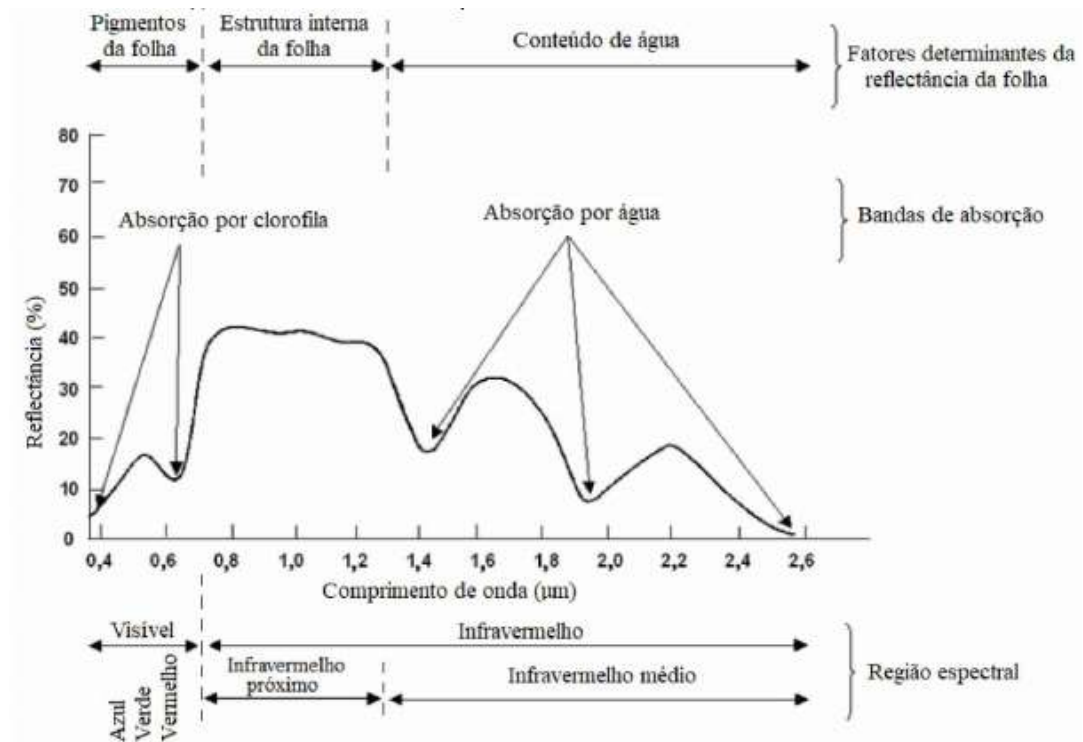
Depois da etapa de granação do fruto, inicia-se o processo de amadurecimento. A cor verde mais intensa do espaço ao verde-cana, que prossegue para o vermelho ou em alguns casos amarelo, dependendo da forma de cultivo adotada. No final do amadurecimento aparecem os frutos do tipo cereja. Após a maturação dos frutos, dá-se início ao processo de senescência do fruto e a seca gradativa da mucilagem. Nesta etapa, o fruto está vulnerável a infecções microbianas, originadas principalmente pela umidade relativa do ar. Essas infecções podem ocorrer tanto nos frutos que estão na planta, quanto nos já caídos, encontrados na parcela de varrição. No final dessa etapa é possível encontrar os frutos do tipo seco (MESQUITA et al., 2016).

4.3 Sensoriamento remoto da vegetação

O sensoriamento remoto tem como uma de suas aplicações a vegetação. Nessa subdivisão ele estuda a propagação da REM nesses ambientes, que podem ser desde florestas e matas fechadas, a diversas culturas de plantio. Embora existam inúmeras espécies e tipos de folhas, em todas elas a propagação da REM é dada através do seu comprimento de onda. Isso acontece devido a alguns fatores relacionados à fisiologia das folhas (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Os pigmentos fotossintetizantes possuem uma capacidade maior de absorção dos comprimentos de onda do visível. Isso faz com que a REM dessa região seja refletida com maior intensidade, garantindo assim uma melhor reflectância da vegetação nessa região do espectro eletromagnético. Entretanto, existem alguns fatores químicos que podem alterar a absorção de REM numa folha. Um deles é a presença de água, que tem facilidade para absorver radiações e conseqüentemente, reduzir a fluxo de energia refletida (PONZONI; SHIMABUKURO; KUPLICH, 2012). Na Figura 1 é apresentada a curva de reflectância de uma folha.

Figura 1 - Reflectância de uma folha saudável




Fonte: Adaptado Novo (2010).

Os componentes internos da folha responsáveis pela absorção na região do visível são encontrados nos cloroplastos. Segundo Ponzoni, Shimabukuro, Kuplich (2012), a absorção é dividida da seguinte forma: clorofila (65%), carotenos (6%) e xantofilas (29%). Esses valores podem diferenciar entre espécies. A clorofila é o único componente capaz de absorver a radiação proveniente da região do vermelho. No infravermelho próximo a absorção é pequena. Parte da REM é espalhada internamente, variando de acordo com as características fisiológicas da folha.

Essas interações com a folha acontecem uma por vez e consequentemente, ocorre em função da reflectância direcional hemisférica (apenas uma folha). Quando são realizados estudos em dosséis, ocorre uma pequena variação nas taxas de reflectância das folhas. Nesse contexto, é considerado então o fator de reflectância bidirecional, uma vez que fatores como a posição do sensor e a iluminação estão bem definidos (PONZONI; SHIMABUKURO; KUPLICH, 2012). A Figura 2 mostra como acontece a interação entre um dossel e a REM.

Figura 2 – Reflectância aditiva para a região do infravermelho próximo



Fonte: Ponzoni, Shimabukuro, Kupkich (2012).

Diante do exposto, constata-se que a reflectância na vegetação depende de alguns fatores internos das folhas, tais como as suas estruturas, e a presença de água. Dessa forma, caso a planta esteja contaminada por patógenos, que modifiquem a sua estrutura interna ou a presença de componentes químicos, suas propriedades espectrais serão alteradas. Quando ocorrem modificações nos pigmentos fotossintetizantes, a alteração ocorrerá na REM da região do visível. Quando ocorrem necroses nas folhas, a reflectância será afetada na região do infravermelho próximo (PONZONI; SHIMABUKURO; KUPLICH, 2012).

4.4 Agricultura de precisão

A AP tem como objetivo a otimização de diversas técnicas agrícolas. Em tempos mais remotos e em algumas localidades nos dias de hoje, as práticas executadas na agricultura baseavam-se, sobretudo, em médias. As médias eram utilizadas para inferir valores desde a aplicação de insumos, a condições do solo. Contudo, com o passar do tempo, ficou nítida a necessidade de aprimoramento dessas práticas de campo. Um dos fatores que expuseram essa carência, é que as variabilidades espaciais não eram corretamente levadas em conta (FORMAGGIO; SANCHES, 2017).

Com o exponencial crescimento populacional, veio a iminente necessidade do aumento de produção. Foi nesse momento que produtores agrícolas de todo mundo passaram a ansiar por padrões de produções que até então pareciam utópicos. Era preciso aumentar a produção e por consequência maximizar seus lucros, porém, sem aumentar a área de plantio e reduzindo impactos ambientais. Essas mudanças só seriam possíveis por meio da inserção de tecnologias no campo (FORMAGGIO; SANCHES, 2017).

Dessa forma, na última década, tem sido cada vez mais comum a inserção de ciências cartográficas para auxiliar nas práticas agrícolas. As principais áreas que colaboram com esse desenvolvimento são o sensoriamento remoto, os sistemas de informações geográficas (SIGs), além dos sistemas de posicionamento, tais como *Global Positioning System* (GPS). A junção dessas geotecnologias com a agricultura passou então a ser necessária para alcançar o objetivo de maximização dos lucros e preservação ambiental. Esse movimento passou a ser denominado de Agricultura de Precisão (FORMAGGIO; SANCHES, 2017).

Uma das formas de aperfeiçoar a sua produção e redução de custos, é com a melhor aplicação dos seus insumos e tratamentos. Quando conseguimos identificar quais áreas estão mais carentes de nutrientes ou que estão sendo atacadas por patógenos, podemos fazer tratamentos específicos e direcionados para aquele local, ao invés de fazer aplicações em toda lavoura. Nesse contexto, o sensoriamento remoto torna-se imprescindível, pois, através do estudo da interação da REM com as culturas, é possível determinar quais plantas estão saudáveis e quais estão fora do padrão de normalidade.

Quando abordamos o SR na AP, precisamos considerar as diversas plataformas que podem transportar os sensores. Sensores podem ser instalados em tratores, que praticam o manejo do solo, em plataformas aéreas, tais como as ARP, ou em satélites, nos casos orbitais. A escolha de qual meio de transporte utilizado dependerá da necessidade a ser atendida, assim como o tamanho das lavouras (FORMAGGIO; SANCHES, 2017).

Para demandas que exijam alta resolução espectral e temporal, como na detecção de ervas daninhas, são indicados sensores acoplados a tratores. Uma vez que estes estão muito próximos às áreas imageadas. Porém quando a necessidade é ter um mapeamento mais amplo e extensivo, a fim de detectar possíveis áreas com ataque nas reboleiras, ou algum problema de crescimento, o ideal é utilizar sensores acoplados a ARPS, ou satélites. Entretanto, é importante destacar que os satélites a serem empregados são aqueles com alta resolução espacial, além de bandas multiespectrais (FORMAGGIO; SANCHES, 2017).

A presença de bandas que abrangem uma maior ordem do espectro eletromagnético vem da necessidade de utilizar os canais do infravermelho próximo e visível. Isso acontece

devido os principais IV serem calculados com bandas desses canais. Normalmente são utilizados o vermelho e o infravermelho próximo (FORMAGGIO, SANCHES, 2017).

Entretanto, existem algumas limitações quanto ao uso de sensores orbitais na AP. A primeira delas é que imagens com alta resolução espacial não são disponibilizadas de forma gratuita. Outro aspecto importante é a resolução temporal, que em casos de monitoramentos de algumas culturas específicas precisam ser maiores. Contudo, para análises pontuais e específicas, a utilização de sensores orbitais pode ser uma opção viável (FORMAGGIO; SANCHES, 2017).

Para o monitoramento contínuo de culturas, o principal meio utilizado são as ARP. Com o uso dessa tecnologia é possível fazer análises extremamente rápidas, o que auxilia o produtor na tomada de decisão. A velocidade da obtenção de respostas, pros problemas demandados é outro fator que tem impulsionado cada vez mais o SR na AP. Estudos como o de Beeri e Peled (2009), apud Formaggio e Sanches, (2017) que visam analisar o uso de SR em tempo real na agricultura, mostram resultados que podem ser encarados como otimistas. No estudo mencionado, os autores constataram a obtenção de resultados com SR num prazo de 45 horas, sendo que pelos métodos tradicionais a espera era de cinco a sete dias.

Além da possibilidade da tomada de decisões em tempo real, o SR tem-se destacado devido à forte correlação de imagens com as variáveis agronômicas para auxílio em práticas de planejamento de plantio e monitoramento. A interação da REM proveniente da região do infravermelho próximo e Red Edge com os parâmetros agronômicos tem se mostrado promissoras para a estimação dessas variáveis através de imagens multiespectrais. Como é descrito no estudo de Oliveira (2015), em que foi estimada a produtividade de cana-de-açúcar em função de índices de vegetação a partir de dados multiespectrais. Como também, Beck et al. (2015), verificaram o potencial de sensores instalados em plataformas orbitais na detecção de nematoides na cultura de pinheiros.

Estudo recentes de Ramoelo et al. (2015), utilizaram a espectrorradiometria para estimar o teor de clorofila de culturas atacadas por pragas. Nesses estudos, os autores encontraram uma alta correlação entre as bandas de absorção da clorofila a e b, centradas no espectro do vermelho, com a deficiência nutricional (nitrogênio) nas folhas das plantas.

Além da estimativa de produtividade e detecção de patógenos nas culturas cafeeiras e o teor de clorofila, também é possível constatar o uso do SR na AP em estudos de monitoramento da condição hídrica, levantamento do número de plantas, detecção de falhas de plantio.

4.5 Aeronaves remotamente pilotadas (ARP)

As ARP apresentam constante evolução tecnológica, graças a sua rápida utilização. Os primeiros registros do uso de ARP são de 1979, quando foram realizados os primeiros testes com VANT em fotogrametria. Posteriormente, Zischinsky et al. (2000), utilizaram um modelo similar ao drone para a geração de um modelo 3D de uma mina. Não mais tarde, esta tecnologia começou a despertar interesse na agricultura (ALBERS; NYQUIST; PURDY, 1996).

Diante da necessidade de realizar monitoramentos contínuos em culturas agrícolas, as ARP vêm ganhando cada vez mais espaço na agricultura. Um dos fatores que facilitam a inserção destas, é o maior controle sobre a resolução temporal. Imagens oriundas de sensores orbitais obedecem ao cumprimento das órbitas dos satélites em torno da Terra. Portanto, sua periodicidade não pode ser quebrada, o que compromete o monitoramento de algumas culturas. Já as imagens registradas por ARPS, podem ser capturadas a qualquer momento, não dependendo de qualquer outro fator externo para a obtenção (DAMIAN et al., 2016).

A variabilidade da resolução temporal, aliada ao desenvolvimento de câmaras multiespectrais de pequeno porte, tem impulsionado o uso do sensoriamento remoto na agricultura. Através dos canais do infravermelho próximo, é possível monitorar a qualidade e desenvolvimento da plantação. Assim como a detecção de diversos patógenos que agridem as culturas agrícolas.

4.5.1 Legislação

No Brasil as legislações vigentes para o uso de ARP podem ser encontradas de forma complementares na Agencia Nacional de Aviação Civil (ANAC), Agencia Nacional de Telecomunicações (ANATEL) e Departamento de Controle do Espaço Aéreo (DECEA) (ANAC, 2017). De forma geral, o uso desses equipamentos é dividido principalmente com relação a seu peso (Quadro 1).

Quadro 1: Classes e tamanhos para RPAS

Classes	Classe 1	Classe 2	Classe 3
Peso máximo de decolagem	Acima de 150Kg	Entre 25Kg e 150Kg	Abaixo de 25Kg

Fonte: Adaptado ANAC (2017).

Existem ainda normas com relação a distância mínima de segurança para o voo desses veículos. De acordo com a ANAC (2017), a altura mínima permitida é de 30 metros com relação as pessoas. Caso sejam executados voos com distâncias inferiores a essa é necessário que haja um acordo mútuo entre o operador e as pessoas daquele local. Além disso também é destacado a idade mínima exigida de 18 anos para pilotar as aeronaves.


É importante destacar que a legislação vigente é aplicada apenas para aeronaves remotas que o piloto pode interferir. ARP que funcionam de forma automática, sem a interferência de um piloto remotamente, são expressamente proibidas e ainda não possuem normas que permitam sua utilização (ANAC, 2017).

4.5.2 Plano de voo

Uma das etapas mais importantes do levantamento aerofotogramétrico é o planejamento de voo. Quando o planejamento é bem executado, é possível economizar custos adicionais. Nessa etapa são determinados fatores como a resolução das imagens que serão obtidas, assim como qual equipamento tem capacidade de executar o planejamento de voo com melhor custo benefício.

Além disso, para a execução de um levantamento aerofotogramétrico é imprescindível que seja estabelecido a sobreposição longitudinal, sobreposição lateral, altura de voo, distância entre as fotos tomadas e conseqüentemente, o espaçamento no terreno das linhas de voo (GONÇALVES, 2006). Para que possa ser estabelecida a sobreposição entre as imagens é importante que sejam tomadas pelo menos duas fotos. Os valores estabelecidos para esses parâmetros variam de acordo com a finalidade do projeto, sendo que este pode possuir desde fins cadastrais a fins de monitoramento agrícola. Normalmente, os valores mínimos determinados para sobreposição longitudinal e lateral são respectivamente 60% e 30% (COELHO; BRITO, 2007).

Figura 3 - Levantamento aerofotogramétrico a partir de parâmetros pré-estabelecidos em planejamento de voo



Fonte: Adaptado de Tommaselli (2009).

Outros elementos de extrema importância são a distância focal e a escala de voo. A escala de voo representa a relação direta entre o tamanho medido na imagem e a sua representação espacial no terreno. Esse parâmetro ditará a variação dos demais para que ele seja alcançado. Outra consequência gerada na escolha da escala de voo é quais equipamentos serão capazes de atender a escala escolhida, além da velocidade de voo e sua consequente duração (COELHO; BRITO, 2007).

Dispondo dos elementos anteriores, é crucial que se conheça a área a ser mapeada. As dimensões do local a ser mapeado influenciarão o número de linhas de voo, assim como a quantidade de fotos que serão tomadas e os demais parâmetros para a execução do levantamento aerofotogramétrico (COELHO; BRITO, 2007).

4.6 Processamento de Imagens

4.6.1 Correção Atmosférica

Quando se captura imagens em sensoriamento remoto e o sensor está acoplado a algum sistema orbital, as imagens registradas conterão erros radiométricos. Este erro está intrínseco às imagens, mesmo que o sistema esteja funcionando devidamente. As duas

principais fontes de propagação deste erro são: atenuação atmosférica e atenuação topográfica (JESSEN, 2015).

A atmosfera tem interferência nas imagens de duas maneiras completamente distintas. Ela pode atuar como um refletor, incrementando o sinal de radiância registrado pelo sensor, ou então ela pode absorver o sinal, atenuando a intensidade de energia que é transmitida ao alvo na superfície terrestre. Ressalta-se que em qualquer uma das situações o efeito é propagado durante toda imagem (MENESES; ALMEIDA, 2012).

Entretanto, mesmo que o efeito atmosférico esteja presente nas imagens, a sua correção não é indicada necessariamente a todos os casos. Dessa forma, irá depender para qual finalidade seus dados estão sendo usados. Como por exemplo, quando são realizados estudos envolvendo classificadores, tais como o classificador de máxima verossimilhança (MAXVER). Se a intenção for comparar imagens de duas datas diferentes, para analisar as suas diferenças, o uso de correção atmosférica não se faz necessário (JESSEN, 2015).

Todavia, quando a intenção do estudo é comparar dados biofísicos que serão extraídos de corpos d'água ou vegetação, a correção atmosférica é necessária. Isso porque caso o dado não seja corrigido, pode haver diferenças significativas na reflectância ou emitância, eventualmente perdida pelo efeito atmosférico. O mesmo se aplica quando a intenção é comparar dados biofísicos de datas diferentes, obtidos por imagens diferentes (JESSEN, 2015).

4.6.1.1 Correção atmosférica pelo método Fast Line Atmospheric Analysis of Spectral Hypercubes (FLAASH)

Existem vários algoritmos desenvolvidos para correção de imagens. Eles vão desde os mais simples, como *Dark Object Subtract* (DOS), até alguns mais complexos como o FLAASH. O FLAASH foi desenvolvido inicialmente pelo *Air Force Phillips Laboratory*. Este algoritmo é capaz de corrigir efeitos atmosféricos nos comprimentos de onda entre 400 a mais ou menos 3000 nanômetros. Dessa forma, é possível operar com os canais do visível, (verde, vermelho e azul), além do canal do infravermelho próximo (ENVI, 2009).

Dessa forma, o FLAASH é um dos mais sofisticados modelos de transferência radiativa. Trata-se de uma função que está no código de transferência radiativa MODTRAN4+. Sua capacidade para correção atmosférica é elevada, tanto de imagens multiespectrais quanto hiperspectrais. Ele possibilita a correção de vários aspectos como vapor d'água, oxigênio, dióxido de carbono, metano, ozônio, espalhamento de aerossol e

outros efeitos adjacentes (RUDJORD; TRIER, 2012). Além disso, a correção no módulo FLAASH requisita alguns dos parâmetros de navegação do sensor no momento de aquisição da cena. Ele baseia-se principalmente em fatores como hora e data de obtenção da cena, altitude, fator de escala, modelo atmosférico, modelo aerossol, absorção de água, entre outros (RUDJORD; TRIER, 2012).

4.6.2 Índices de vegetação

O sensoriamento remoto aplicado à vegetação está em constante desenvolvimento. Este desenvolvimento vem atrelado a fatores como a introdução de novos conceitos, além do aprimoramento computacional. A junção desses fatores permite a criação de novos modelos para tratar a reflectância da vegetação. De forma genérica, alguns desses modelos são conhecidos por IV. Os IV são de extrema importância para o estudo da vegetação, uma vez que a maioria desses modelos visa destacar a intensidade da reflectância da vegetação nas imagens.

Para Silva et al. (2018), um método bastante utilizado na realização da análise da cobertura vegetal é o NDVI, que tem seus valores obtidos a partir de imagens digitais. O cálculo do NDVI é realizado a partir das bandas do vermelho e infravermelho. Os valores NDVI são indicados pelo intervalo que varia de -1 a +1. Sendo que próximo de -1 indica a ausência de vegetação, mostrando um baixo ou nulo teor de clorofila e quanto mais próximo de +1, maior a presença de vegetação no local, ou seja, maior teor de clorofila. O NDVI, pode ser calculado pela equação 1, proposta por Rouse et al. (1974).

$$NDVI = \frac{IVP - V}{IVP + V} \quad (1)$$

Onde:

- NDVI é o Índice de Vegetação por Diferença Normalizada;
- IVP é a reflectância proveniente do canal do infravermelho próximo da região do infravermelho;
- V é a reflectância proveniente do canal vermelho da região do visível.

Elaborado por Buschmann e Nagel (1993), o *Normalized Difference Red Edge Index* (NDRE) é um índice de vegetação que trabalha com as bandas que operam no comprimento

de onda do infravermelho próximo e do RedEdge. Com construção semelhante ao NDVI, este índice é obtido pelo simples razão entre a diferença e a soma das bandas do IVP e RedEdge. Este índice pode ser ainda melhor que o NDVI em alguns casos, uma vez que substitui a banda do vermelho, que contém uma absorção maior de REM, pela banda do RedEdge, que é refletida com maior intensidade quando em contato com a vegetação (GITELSON; MERZLYAK, 1996).

$$NDRE = \frac{IVP - RE}{IVP + RE} \quad (2)$$

Onde:

- NDRE é o Índice de Vegetação por Diferença Normalizada do vermelho limítrofe;
- IVP é a reflectância proveniente do canal do infravermelho próximo da região do infravermelho;
- RE é a reflectância proveniente do canal RedEdge.

Diante das limitações do NDVI sobre os efeitos atmosféricos, e conseqüentemente, do NDRE posteriormente, Kaufman e Tanré (1992), formularam um novo índice de vegetação, o *Atmospherically Resistant Vegetation Index* (ARVI). Diferentemente do NDVI, este índice utiliza a banda do azul, com a intenção de eliminar os efeitos dos aerossóis e ozônio sobre as imagens (Equação 3).

$$ARVI = \frac{(IVP - (V - A))}{(IVP + (V * A))} \quad (3)$$

Onde:

- ARVI é o Índice de *Atmospherically Resistant Vegetation Index*;
- IVP é a reflectância proveniente do canal do infravermelho próximo da região do infravermelho;
- V é a reflectância proveniente do canal do vermelho;
- A é a reflectância proveniente do canal azul.

Segundo Jiang et al. 2008, o *Enhanced Vegetation Index* (EVI) foi criado para aperfeiçoar a identificação da vegetação em regiões de alta concentração de biomassa. A sua formulação tem como origem a junção dos índices ARVI e o *Soil-Adjusted Vegetation Index* (SAVI). Esse índice apresenta como vantagem uma melhor eficiência no processo de amenização dos efeitos de atenuação atmosférica e do solo sobre a vegetação.

$$EVI = \frac{IVP - V}{IVP + (C_1 * V) - (C_2 * A) + L} \quad (4)$$

Onde:

- EVI é o *Enhanced Vegetation Index*;
- IVP é a reflectância proveniente do canal do infravermelho próximo da região do infravermelho;
- V é a reflectância proveniente do canal do vermelho do espectro visível;
- A é a reflectância proveniente da banda azul do espectro visível;
- C_1 é o coeficiente de correção atmosférica para banda do vermelho;
- C_2 é o coeficiente de correção atmosférica para banda do azul;
- L é o fator de correção para interferência do solo.

Os índices de vegetação apresentados se assemelham principalmente por utilizarem a banda do infravermelho próximo. Entretanto, existem alguns IV centrados na utilização das bandas do espectro visível. Um desses índices é o *Visible Difference Vegetation Index* (VDVI). Este índice utiliza todas as bandas do espectro visível (verde, vermelho e azul) e possui seus resultados entre os valores de -1 a 1. Proposto por Wang et al. (2015), o VDVI pode ser considerado como o índice com melhor acurácia para extração da vegetação em sensores que trabalham apenas com comprimentos de onda do visível, sendo que, em alguns casos, seus resultados conseguem atingir aproximadamente 90% de acurácia


$$VDVI = \frac{(2 * VERDE - VERMELHO - AZUL)}{(2 * VERDE + VERMELHO + AZUL)} \quad (5)$$

Onde:

- VDVI é o *Visible Difference Vegetation Index*;
- VERDE é a reflectância proveniente do canal do verde do espectro visível;
- VERMELHO é a reflectância proveniente do canal do vermelho do espectro visível;
- AZUL é a reflectância proveniente da banda azul do espectro visível.

Outro índice que trabalha com o espectro do visível é o *Triangle Greenness Index* (TGI). Este IV é baseado na formação de um triângulo sobre o espectro do visível. Cada um dos vértices do triângulo está posicionado sobre os sinais de reflectância do vermelho, verde e azul, como demonstra a Figura 4 (HUNT JR. et al., 2011).

Figura 4 - O TGI é definido como a área do triângulo sobre o espectro visível



Fonte: Hunt JR. et al., 2011.

Segundo McKinnon e Hoff (2017), analisando o sensor de uma câmera CMOS, e considerando os seus comprimentos de ondas, normalizados pelo sinal do verde, podemos descrever a equação do TGI como:

$$TGI = G - 0,39 * R - 0,61 * B \quad (6)$$

Onde:

- TGI é o *Triangle Greenness Index*;
- G é a reflectância proveniente do canal verde da região do visível;
- R é a reflectância proveniente do canal vermelho da região do visível;
- B é a reflectância proveniente do canal azul da região do visível.

4.7 Análise estatística de dados

Modelos são tentativas de representar as variáveis da natureza de forma matemática. Eles dependem da correlação entre dois ou mais parâmetros, para que um seja estimado em função do outro. Dessa forma, antes de se gerar um modelo é necessário verificar se os dados de estudo apresentam correlação entre si. Para isso, são utilizadas ferramentas estatísticas, para determinar se os parâmetros podem variar um em função do outro. Nesse contexto, a correlação de Pearson pode ser utilizada.

Para obter uma forte correlação entre os dados analisados, é essencial que a amostra de estudo não contenha *outliers*. *Outliers* são dados que apresentam comportamento discrepante com relação ao resto da amostra. Eles podem ser causados em decorrência de erros grosseiros cometidos na obtenção da amostra de dados. Para verificar se uma amostra contém *outliers* é essencial analisar o comportamento da amostra. Uma das formas de se analisar o comportamento dos dados é através da análise dos resíduos normalizados.

Os resíduos podem ser obtidos através da diferença entre cada um dos valores amostrados e média. A partir disso, para normalizá-los é preciso que cada resíduo seja dividido pelo valor do desvio padrão da amostra (Equação 7). Dessa forma, o resultado encontrado pode ser analisado em função da distribuição normal (Para mais detalhes, consultar ROFATTO et al., 2018).

$$r = \frac{(x - \bar{x})}{\sigma} \quad (7)$$

Onde:

- r é o resíduo normalizado
- x é o valor de um dado da amostra
- \bar{x} é a média dos valores da amostra
- σ é o desvio padrão da amostra

A análise de resíduos garante maior segurança para a manipulação de dados. Tendo em vista a eficácia do controle de qualidade, após uma amostra ser filtrada, é possível calcular qual a intensidade de correlação entre duas variáveis. Amostras que possuem forte correlação podem ser passíveis de gerarem modelos. Uma das formas da geração de modelos é a regressão, que está estreitamente ligada com a correlação. A regressão gera um modelo matemático onde é possível estimar uma variável de estudo em função de outra.

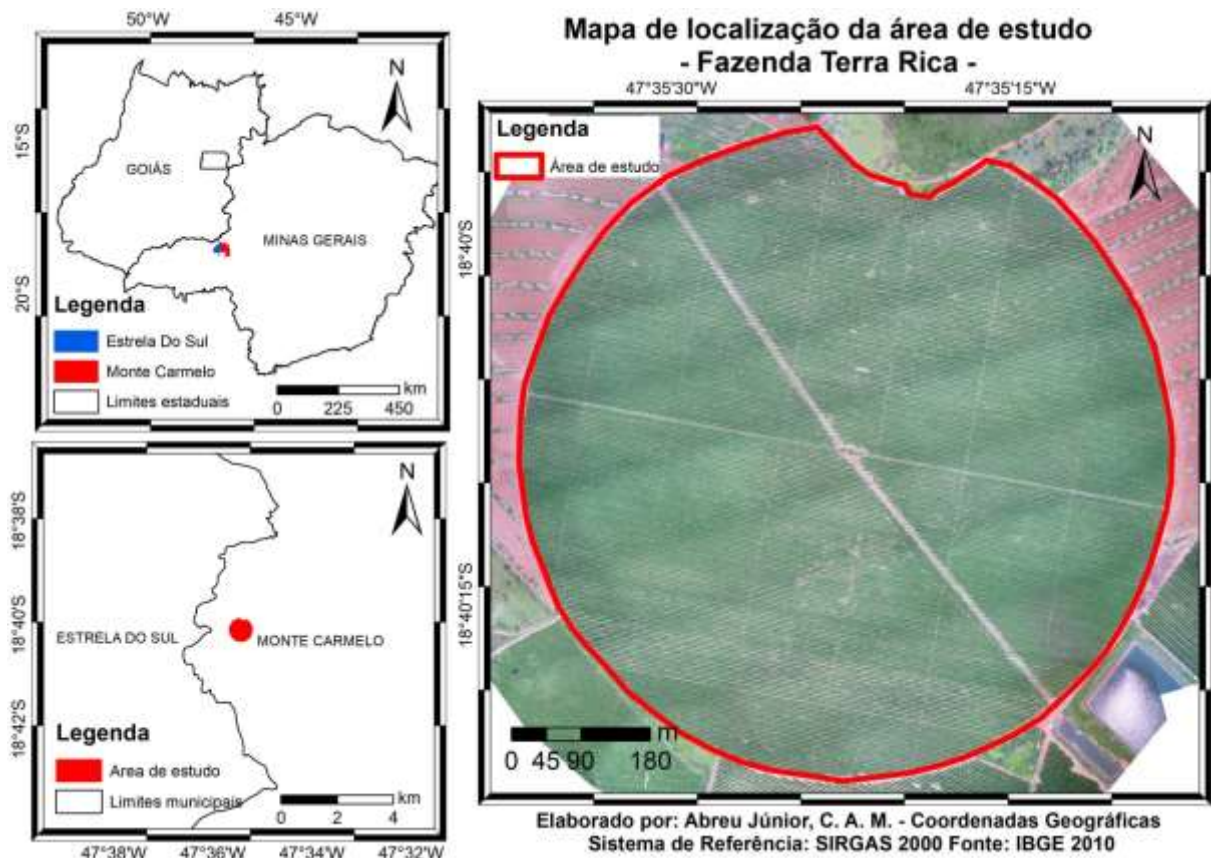
A regressão pode gerar modelos estatísticos lineares ou não lineares. O modelo é linear quando a quantidade de interesse, normalmente representada pela média de valores Y , é característica linear dos parâmetros. Quando esta condição não se aplica, o modelo estatístico é não linear.

5 MATERIAL E MÉTODOS

5.1 Área de estudo

A área de estudo deste trabalho foi a Fazenda Terra Rica, localizada no município de Monte Carmelo, próximo à divisa com o município de Estrela do Sul. A área se encontra na mesorregião do Triângulo Mineiro e Alto Paranaíba (Figura 5). O solo característico da região é o Latossolo vermelho e a cultura de cultivo é o café arábica, variedade catuaí 144. A área total da plantação é de 45 ha, e esta localizada numa altitude de aproximadamente 820m.

Figura 5 - Mapa de localização da área de estudo



Fonte: O autor.

A mesorregião do Triângulo Mineiro e Alto Paranaíba é uma das principais produtoras de café no estado. Segundo Carneiro et al. (2005), as propriedades apresentam tamanho médio de 100 ha, e produção média de 40 a 45 sacas de café. Um dos fatores que favorece o plantio de café nessa região é o clima. As temperaturas médias da mesorregião variam entre 18°C e 21°C durante o inverno, sendo caracterizado pelo clima quente e seco, o que favorece o

cultivo do café nesta região por não possuir geadas. Além disso, os cafés são cultivados a uma altitude de aproximadamente 850 metros (VALE; CALDERARO; FAGUNDES, 2014).

5.2 Material

Para o desenvolvimento deste trabalho, foram utilizados diversos materiais. Cada material, foi aplicado em uma etapa específica da execução do trabalho, sendo assim, foram dispostos em três grupos principais, que são: planejamento de campo, levantamento dos dados em campo, processamento e análise dos dados.

Na etapa de planejamento de campo, o intuito principal foi montar um cronograma de execução para que no dia do levantamento, as etapas pudessem ser executadas de forma otimizada, e a tentar amenizar ao máximo os possíveis imprevistos. Para isso, foram utilizados:

- Imagem RGB. Essa imagem foi utilizada para definir a amostragem dos pontos que foram mensurados no dia do levantamento de campo;
- Notebook Dell Inspiron 14 3000 Series, I14-3442-A40, Intel Core i5, Placa de vídeo dedicada de 2GB, Memória de 8GB DDR3, Disco rígido de 1TB;
- *Software QuantumGis 2.18*. O *software* foi utilizado para a geração dos pontos onde foram coletadas as amostras, tendo em vista que este possui ferramentas que facilitam a disposição aleatória de pontos; e
- *Software Drone Deploy*, que foi utilizado para elaborar o plano de voo.

A próxima etapa foi o levantamento de campo. Foram realizados o levantamento aerofotogramétrico da área, além da mensuração e georreferenciamento das amostras de campo. Para este, foram utilizados os seguintes dados:

- Drone Phantom 4 Advanced, que foi utilizado para realizar o levantamento aerofotogramétrico da área, acoplado com a câmara RGB padrão e a câmara Mapir 3 (Figura 7); e

Figura 6 - Drone Phantom 4 Advanced



Fonte: O autor.

- Receptor GNSS - RTK (*Global Navigation Satellite System - Real Time Kinematic*) (Figura 8), utilizado para georreferenciar às amostras coletadas.

Figura 7 - Receptor GNSS RTK



Fonte: O autor.

O processamento e análise dos dados foram executados integralmente em laboratório, e para tal foram utilizados:

- Notebook Dell Inspiron 14 3000 Series, I14-3442-A40, Intel Core i5, Placa de vídeo dedicada de 2GB, Memória de 8GB DDR3, Disco rígido de 1TB;
- *Software Pix4d*, que foi utilizado para a geração dos mosaicos;
- Imagens multiespectrais de sensores orbitais, disponibilizadas para pesquisa pelos sites www.planet.com e www.usgs.gov, para RapidEye e Sentinel 2 respectivamente (Quadro 4 e 5);

Quadro 4 – Informações do satélite RapidEye

Número da banda	Nome da banda	Resolução espectral (λ)(nm)
B01	Azul	440-510
B02	Verde	520-590
B03	Vermelho	630-690
B04	Vermelho limítrofe	690-730
B05	Infravermelho Próximo	760-880

Fonte: EngeSat (2019).

Quadro 5 – Informações do satélite Sentinel 2 2

Número da banda	Nome da banda	Resolução espectral (λ)(nm)
B02	Azul	490
B03	Verde	560
B04	Vermelho	665
B08	Infravermelho Próximo	842

Fonte: EngeSat (2019).

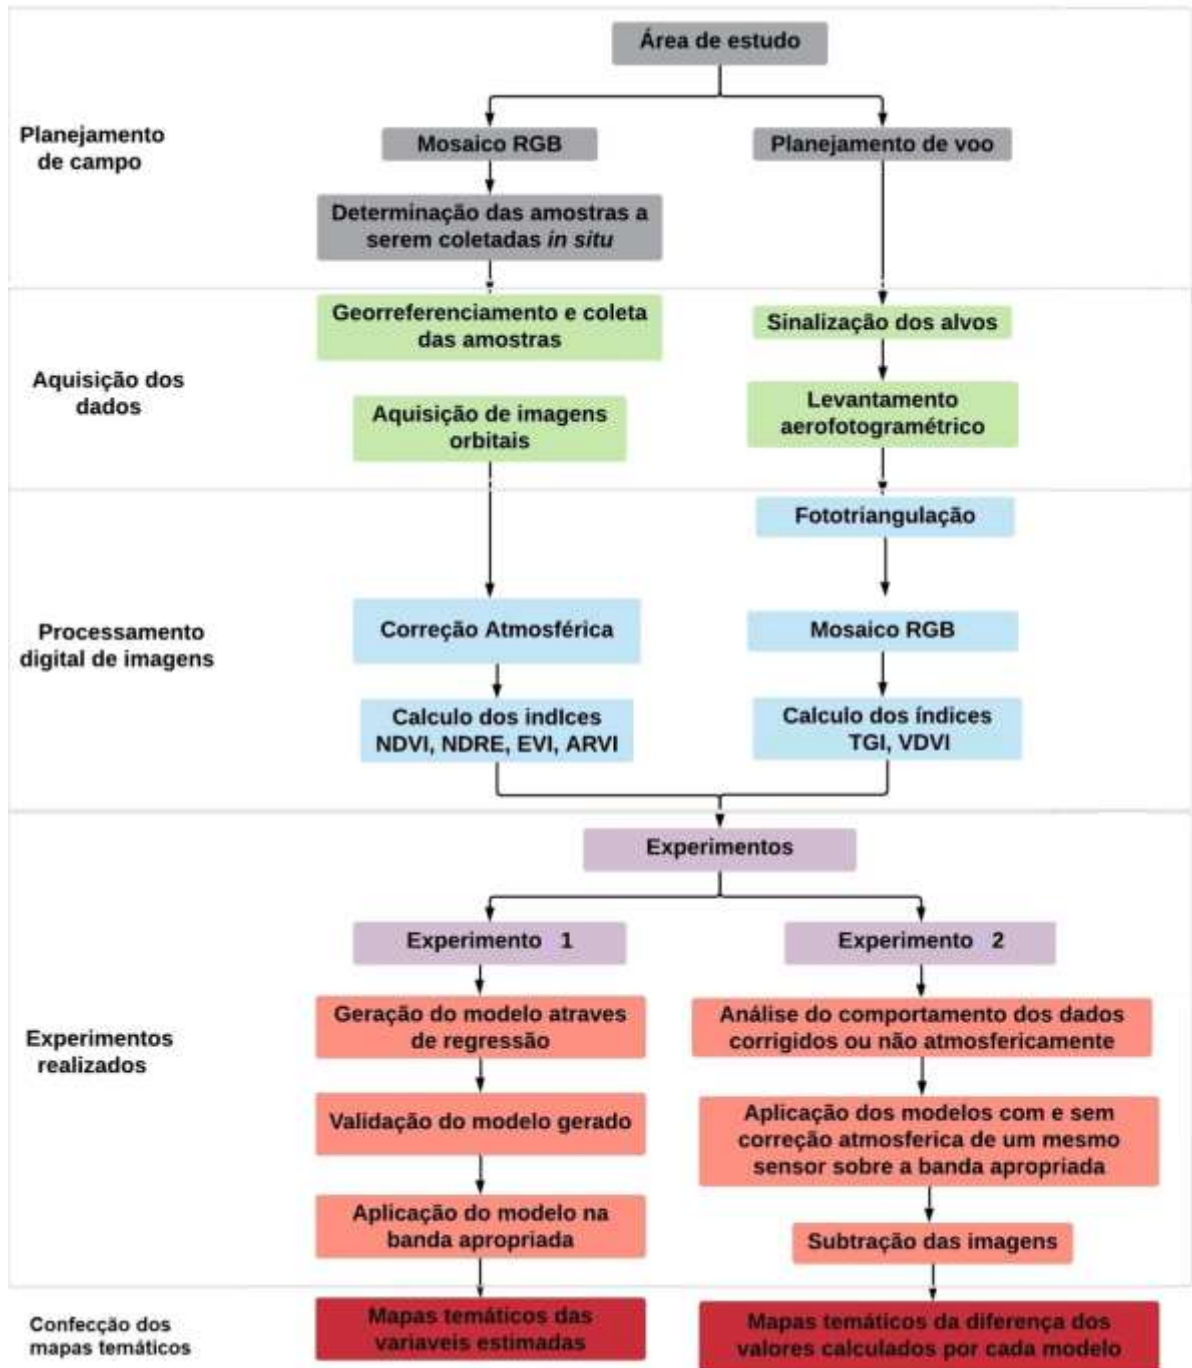
- *Software ENVI Classic 4.8*, que foi utilizado para o cálculo dos IVs, correção atmosférica das imagens obtidas por sensores orbitais, pelo método FLAASH, e extração dos valores de reflectância das imagens;
- *Software Mapir 3 Camera Control*, que foi utilizado para calibração radiométrica do mosaico proveniente da câmara Mapir 3;
- *Software Minitab 16 e Excel 10*, que foram utilizados para análises estatísticas, tabulação de dados, e geração de eventuais gráficos; e

- *Software ArcGis 10.3*, que foi utilizado para a confecção dos mapas.

5.3 Métodos

A fim de facilitar a compreensão e organização do trabalho, foi elaborado o fluxograma metodológico, que dispõe as atividades que foram executadas de forma contínua e cronológica. O fluxograma está dividido em quatro etapas principais, sendo elas: 5.3.1 Planejamento de campo, 5.3.2 Aquisição dos dados, 5.3.3 Processamento digital de imagens, 5.3.4 Experimentos realizados e 5.3.5 Confecção dos mapas temáticos.

Figura 8 - Fluxograma metodológico



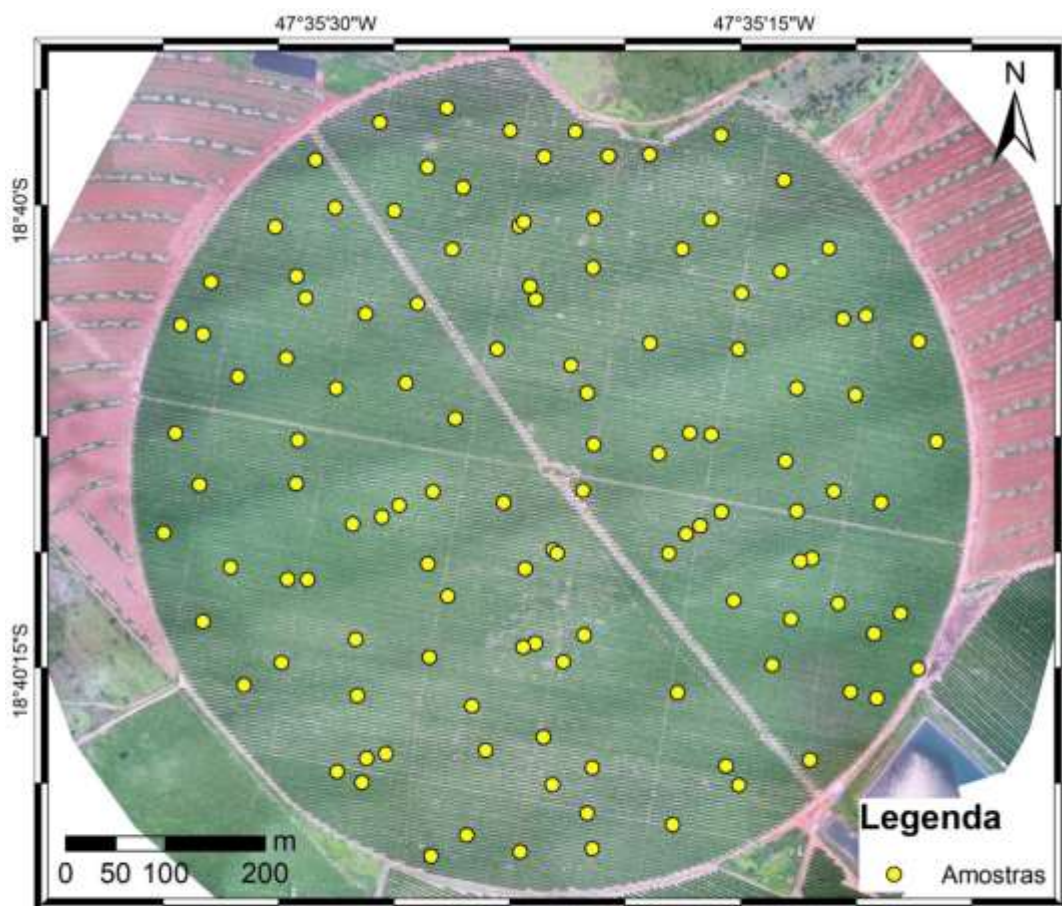
Fonte: O autor.

5.3.1 Planejamento de campo

Para a execução desta etapa, foi utilizado um mosaico RGB com as informações da área de estudo. Para determinar quais locais seriam escolhidos para recolher as amostras de

frutos do café *in situ*, foi utilizado o *software QuantumGis 2.18*. O *software* possui uma ferramenta de geração de pontos aleatórios, que foi utilizada para selecionar quais seriam os locais com informação coletada (Figura 10). Inicialmente, foram amostrados 100 pontos no planejamento de campo. Desses pontos, 80% foi utilizado para geração do modelo, e 20% para validação. Dessa forma, foi possível garantir a aleatoriedade dos dados, para que os mesmos não ficassem enviesados.

Figura 9 - Exemplo da distribuição espacial de pontos para coleta *in situ*, gerada aleatoriamente pelo *software QuantumGIS 2.18*, para compor o planejamento de campo



Fonte: O autor.

Para localizar os pontos determinados no mapa (Figura 10), foi utilizada a divisão existente entre as ruas de plantio da área de estudo. As divisões estão dispostas da seguinte forma: existem seis ruas ortogonais que atravessam as ruas horizontais ao longo de toda área. Sendo assim, são formadas sete parcelas principais ao longo do mapa. Dessa forma, para localizar os pontos dentro de cada parcela, foi feito a contagem do número total de ruas em

cada parcela, e conseqüentemente, foi anotado as ruas que existem pontos. Após isso, foi marcada uma planta principal, que corresponderia ao ponto gerado aleatoriamente. Esse procedimento foi realizado principalmente para que o processo de campo fosse otimizado.

5.3.1.1 Planejamento de voo

Para finalizar o planejamento de campo, foi necessário traçar o plano de voo. O planejamento de voo foi executado através do *software Drone Deploy*. Este *software* permite calcular os elementos necessários para processar um mosaico em cima da área de estudo. Nessa fase, foram definidos o número de faixas necessárias de voo, assim como o número de fotos, sobreposições lateral e longitudinal, altitude de voo e todos os demais parâmetros abordados na seção 4.5.2. A Tabela 1 apresenta-se os valores dos parâmetros que foram utilizados no planejamento de voo.

Tabela 1 - Parâmetros utilizados no planejamento de voo

Parâmetro	Valor
Tempo de voo	9 min e 45 seg
Altitude de voo	242 m
GSD	6cm
Sobreposição lateral	80%
Sobreposição longitudinal	80%
Quantidade de fotos	86
Data	28/05/2019

5.3.2 Aquisição dos dados

Nesta etapa do trabalho foi executado todo o planejamento feito na seção anterior. Para determinar a produtividade da lavoura, foi coletado amostras de café em pontos específicos previamente determinados. O georreferenciamento desses pontos foi feito utilizando um receptor GNSS.

Deve-se ressaltar que para o levantamento de campo foi necessário garantir a acurácia das coordenadas das amostras *in situ*, uma vez que no processo de correlação das variáveis

relacionadas à produtividade com as imagens foi necessário retirar os valores de reflectância das mesmas plantas onde foram colhidas as amostras.

5.3.2.1 Georreferenciamento e coleta das amostras

A primeiro momento, foi necessário instalar a base do par de receptores GNSS. A base foi fixada em um ponto estratégico, que estava em um ambiente o mais aberto o possível, a fim de amenizar possíveis erros e imprecisões nas coordenadas. Após isso, o receptor foi utilizado para mensurar as coordenadas dos pontos amostrados, utilizando o método de posicionamento relativo.

Em cada ponto amostrado, foram colhidos os frutos de cinco pés de café, sendo que foram selecionados duas plantas a esquerda, e duas plantas a direita da planta marcada na etapa de planejamento de campo. Dessa forma, foram extraídos todos os frutos de café das plantas selecionadas. Após isso, os frutos foram pesados, para obter a variável peso total. Em seguida, foi realizado o processo de maturação dos frutos, onde estes eram classificados em quatro classes, sendo elas: verde, cana, cereja e seco. A produtividade foi estimada posteriormente em laboratório, após as etapas de secagem e beneficiamento dos frutos, sendo esta estimada em sacas por hectares.

5.3.2.2 Aquisição de imagens orbitais

As imagens orbitais foram utilizadas no intuito de estabelecer comparações com as imagens provenientes do levantamento aerofotogramétrico, já que elas possuem uma resolução espacial inferior que as imagens obtidas por drone, além de possuírem efeitos e distorções proporcionados pela atmosfera.

Desta forma, seria possível avaliar o experimento sobre duas perspectivas diferentes. Foram utilizadas imagens provenientes dos sensores *RapidEye Earth Imaging System* (REIS) - RapidEye e *Multi-spectral Instrument* (MSI) - Sentinel 2. Foram escolhidas as imagens orbitais com datas iguais a 30/05/2019, para o satélite Sentinel 2 e 26/05/2019 para o satélite Rapideye.

5.3.3 Processamento digital de imagens

Após o levantamento aerofotogramétrico, foi feita a fototriangulação das imagens obtidas pelo sensor RGB. O processo de correspondência entre as imagens e a fototriangulação foram feitas pelo *software Pix4D*. No final desse processamento foram calculados os IVs para todos os sensores (orbitais e aerofotogramétrico). Para os sensores que operam com bandas multiespectrais, foram calculados os índices que trabalham com o IVP e o vermelho limítrofe. Para o mosaico RGB foram calculados os IV específicos para sensores que operam com as bandas do visível.

5.3.3.1 Correção atmosférica

Para as imagens proveniente dos satélites Sentinel 2 e RapidEye, foi feita a correção atmosférica utilizando o *software ENVI Classic 5.0*. Foi realizada a correção atmosférica dos dois sensores orbitais utilizados, para reduzir as interferências na reflectância do parâmetro estimado. Considerando a variabilidade apresentada pelo café, em função da sua bienalidade, e a relação direta deste com a produtividade da cultura, a correção atmosférica das imagens orbitais torna-se, a princípio, recomendável, uma vez que qualquer atenuação dos valores de reflectância pode causar confusões entre as plantas que mais produzem e as que menos produzem.

5.3.4 Experimentos realizados

5.3.4.1 Experimento I

A correlação entre dois parâmetros é um índice essencial para verificar se as variáveis apresentam alguma relação aparente e direta entre elas. Medidas que apresentam fortes correlações podem possuir boa confiabilidade para gerar modelos. As variáveis agrícolas utilizadas para calcular a correlação neste trabalho foram produtividade, presença de nematoides juvenis no talhão de estudo, que foram constatados através da análise de solo realizada em laboratório, com amostras colhidas na área de estudo, peso total dos frutos colhidos, e os seus respectivos tipos (verde, cana, cereja e seco).

Antes de iniciar as etapas de geração de modelos, foi realizada a análise descritiva das variáveis agrícolas estudadas. Os resultados obtidos pela correlação de Pearson, juntamente

com os resultados da estatística descritiva das variáveis foram utilizados como base para a tomada de decisão, de prosseguir ou não com determinada variável para o processo de geração dos modelos. Sendo assim, alguns parâmetros agronômicos não tiveram modelos gerados para a sua estimativa, uma vez que suas estatísticas não apresentaram valores significativamente relevantes.

Sendo assim, foi testada a correlação dos parâmetros agronômicos com todas as bandas das imagens orbitais e aerofotogramétrica, além dos seus IV. Para o satélite RapidEye, foram utilizados os IV NDRE e NDVI, que são comumente utilizados com variáveis agrícolas. Para o satélite Sentinel 2, foram selecionados os IV EVI e ARVI. Para o mosaico RGB foram calculados o TGI e o VDVI. A partir disso, selecionaram-se os dados que apresentaram melhores resultados.

Diante dos dados com maior correlação, foi analisado se estes possuíam alguma tendência, isto é, se a distribuição espacial deles no eixo cartesiano apresentava um comportamento linear, quadrático ou exponencial, ou de alguma outra natureza. Para isso, foram plotados os pontos amostrais referentes aos valores das amostras mensuradas em campo, com relação a reflectância das imagens utilizadas, sendo que, no eixo das ordenadas foram colocados os parâmetros agronômicos, e no eixo das abcissas, os valores de reflectância das imagens utilizadas.

Após esta identificação, os dados foram direcionados para o modelo de regressão que mais se ajustasse a eles. A partir disso, foram gerados os modelos de estimativa de produtividade e da concentração de cada tipo de fruto, em função da reflectância dos *pixels* obtidos na imagem. Após isso, para a validação dos modelos foram calculados alguns parâmetros estatísticos, tais como o RMSE em porcentagem e o R^2 . O critério escolhido para confecção dos mapas foi o de menor RMSE para cada variável.

5.3.4.2 Experimento II

Para realizar o segundo experimento foi considerado apenas os modelos advindos de sensores orbitais, uma vez que o intuito da análise foi comparar os valores obtidos pelos modelos com e sem correção atmosférica. Diante disto, foram selecionados os modelos que apresentavam os menores valores de RMSE em porcentagem, de cada satélite, sendo eles, o modelo para estimativa de peso total dos frutos, do satélite RapidEye e o modelo para estimativa de produtividade do satélite Sentinel 2.

Primeiramente foram gerados dois gráficos com os valores de reflectância dos pontos amostrados *in situ* de cada imagem (com e sem correção atmosférica), sendo cada gráfico referente a um satélite. A intenção foi analisar se o comportamento dos dados de reflectância dispostos no eixo cartesiano era próximo nas imagens com e sem correção atmosférica.

Após isso, aplicaram-se os modelos com e sem correção atmosférica, sobre as bandas apropriadas, gerando assim duas imagens para cada parâmetro agrônomico no seu respectivo sensor. Em seguida, foi feita a subtração entre as imagens (com e sem correção atmosférica) de cada parâmetro agrônomico, a fim de detectar as discrepâncias entre cada valor estimado pelos modelos por *pixel*. Com a imagem resultante dessa subtração, foram feitos dois mapas, um para cada parâmetro agrônomico, a fim de analisar as áreas onde as diferenças foram maiores, entre os modelos de predição comparados, para assim detectar se existiu alguma diferença significativa entre os valores estimados pela imagem corrigida atmosféricamente e a sem correção.

6 RESULTADOS E DISCUSSÕES

6.1 Análise descritiva dos dados

A Tabela 2 apresenta os resultados da análise preliminar dos dados de estudo.

Tabela 2 - Análise descritiva das variáveis estudadas

Variável (unidade)	Média	Desvio padrão	Coefficiente de variação	Mín	Quartil 1	Quartil 3	Máx
Verde (nº de frutos)	61,97	43,21	69,73	5	22,75	100,25	169
Cana (nº de frutos)	10,379	7,135	68,74	1	5	13	37
Cereja (nº de frutos)	45,28	24,14	53,33	5	27,75	62,25	101
Seco (nº de frutos)	266,9	110,9	41,56	65	178	323	576
Nematoides (quant/1ml)	1,375	1,805	131,25	0	0	2	11
Produtividade (sacas/ha)	20,88	14,09	67,48	4,3752	7,41	33,66	44,54
Peso Total (Kg)	3,975	1,164	29,29	0,365	3,7	4,745	5,6

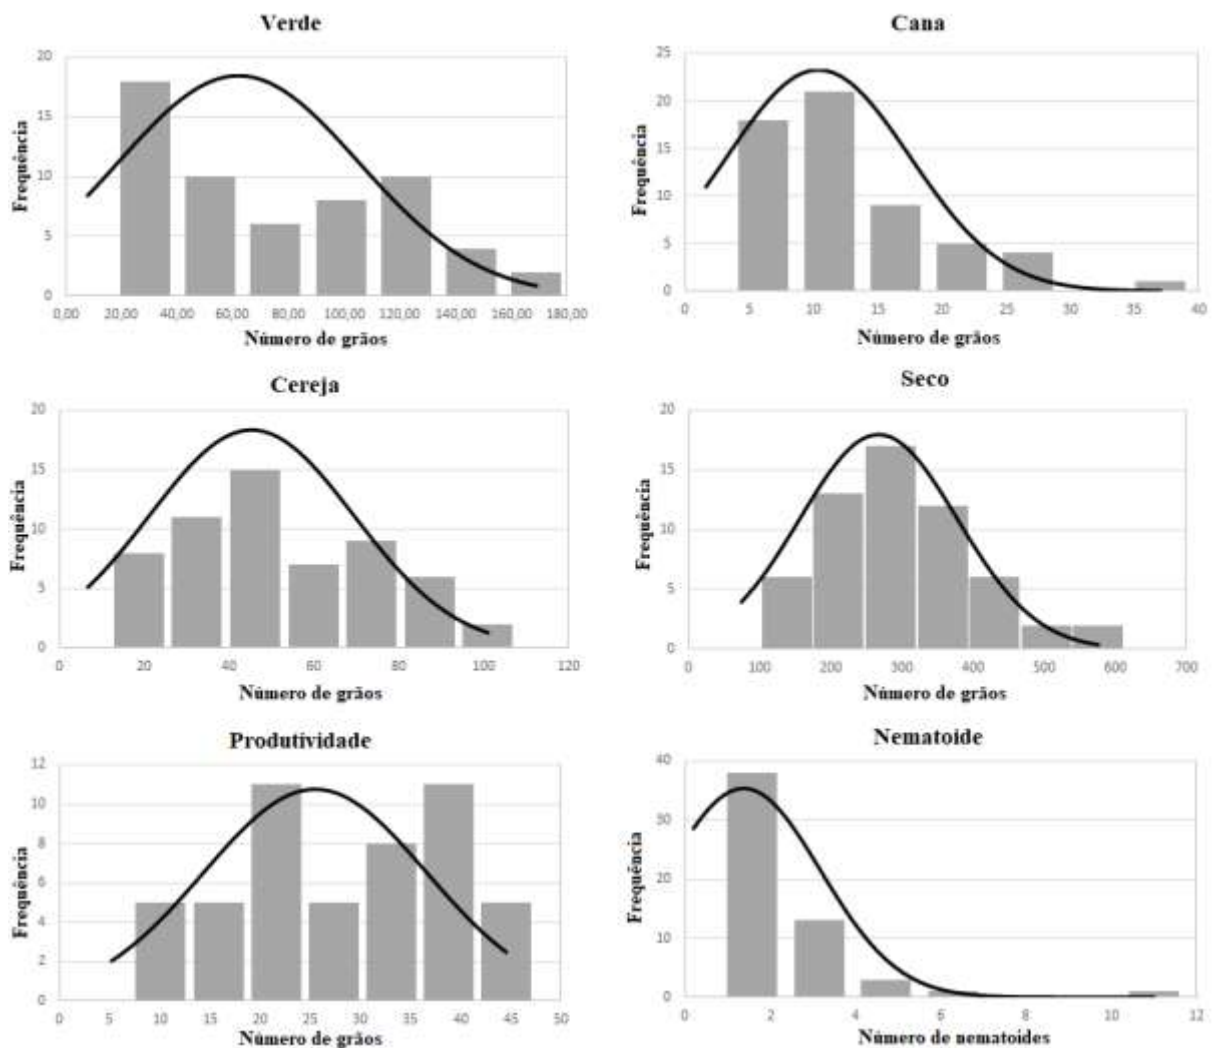
Os da Tabela 2, com exceção dos nematoides, são correspondentes a cinco plantas. Analisando o coeficiente de variação das variáveis, apenas os nematoides apresentaram um valor superior a 100%, o que indica que os dados apresentam uma variação alta e baixa homogeneidade, o que é um indicativo de possível inviabilização da variável para geração de

modelos. As demais variáveis apresentaram resultados inferiores a 100%, sendo os menores valores registrados pelos parâmetros peso total (29,29) e frutos seco (41,56).

Analisando os valores de primeiro e terceiro quartil, novamente a variável com maior discrepância foi o nematoide. Apenas 25% dos dados apresentam valores superiores a 2, sendo que o valor máximo encontrado é de 11. Além disso, pelo menos um quarto dos dados apresentam valores iguais à zero, o que aponta mais uma vez uma variação muito alta entre os dados amostrados.

A Figura 11 apresenta os histogramas das variáveis estudadas, juntamente com a curva normal de cada parâmetro.

Figura 10 - Histograma e curva de distribuição normal das variáveis de estudo



Fonte: O autor.

Através da análise gráfica, a variável que apresenta maior simetria é o fruto do tipo seco, isto é, são os dados que possuem o melhor ajuste, se comparado com os demais parâmetros. Tendo isto em vista, juntamente com os dados da estatística descritiva, a variável fruto do tipo seco mostra-se como a mais propícia para a geração de modelos, devido ao comportamento dos dados amostrados.

Em contrapartida, o histograma e a curva de distribuição normal do parâmetro nematoide apresentam uma forte tendência para esquerda, o que caracteriza uma curva assimétrica positiva, com a mediana inferior à média. O mesmo ocorre com a variável fruto do tipo cana, que apresenta um comportamento gráfico similar. Além disso, é possível notar a presença de um possível conjunto de *outliers* nos dois gráficos, já que nos nematoides o intervalo de 10 a 12 apresenta baixa frequência, e esta distante dos demais, assim como ocorre no fruto do tipo cana, no intervalo de 35 a 40.

Os frutos do tipo verde, cereja e a produtividade apresentam dois picos em seus histogramas, o que caracteriza dados bimodais. Esse comportamento sugere a existência de dois grupos, com valores condensados em dois pontos distintos do eixo. No caso do fruto do tipo cereja e da produtividade, um dos picos ocorre dentro do valor de média da amostra, ao passo que para o fruto do tipo verde, nenhum dos picos ocorre próximo a este valor.

6.2 Análise multivariada dos parâmetros agronômicos

Os resultados foram dispostos em tabelas, no qual cada uma possui o resultado de um sensor específico, tendo sido analisado a câmara acoplada ao drone (Tabela 3), aos sensores orbitais, com correção atmosférica (Seção 6.2.1) e sem correção atmosférica (Seção 6.2.2).

Tabela 3 - Correlação entre as bandas e índices de vegetação da câmara RGB embarcada no drone e os parâmetros agronômicos

Bandas/IVs	Verde	Cana	Cereja	Seco	Nematoide	Produtividade	Peso Total
Vermelho	0,153	0,096	-0,112	-0,068	0,127	-0,099	0,148
Verde	0,260	0,101	-0,040	-0,241	0,119	-0,275	-0,032
Azul	-0,037	-0,001	-0,463	-0,129	0,080	0,056	0,061
TGI	0,406	0,116	0,443	-0,570	0,059	-0,488	-0,231
VDVI	0,062	-0,059	0,536	-0,238	-0,094	-0,239	-0,377

O sensor acoplado ao drone registra comprimentos de onda apenas do espectro visível, sendo assim, foram utilizados apenas IV que trabalham com esses comprimentos de onda. A Tabela 3 mostra que os melhores resultados foram obtidos com o índice TGI para as variáveis frutos do tipo verde (0,406), cana (0,116), seco (-0,570) e produtividade (-0,488). Para frutos do tipo cereja, o índice que apresentou melhor correlação foi VDVI com o valor de 0,536. A variável nematoide não apresentou nenhum resultado significativo, sendo o maior deles encontrado na correlação com a banda do vermelho (0,127).

Diante do exposto, foram escolhidos os maiores resultados obtidos em análise geral, entre todas as variáveis estudadas. Os frutos do tipo seco e cereja foram utilizados para prosseguir na etapa de geração de modelos, uma vez que ambos ultrapassaram o valor de correlação de 0,500.

6.2.1 Imagens orbitais sem correção atmosférica

A Tabela 4 mostra os resultados para os dados do satélite RapidEye sem correção atmosférica.

Tabela 4 - Correlação entre as bandas e IV do satélite RapidEye sem correção e os parâmetros agronômicos

Bandas/IVs	Verde	Cana	Cereja	Seco	Nematoide	Produtividade	Peso Total
Azul	-0,310	-0,151	-0,038	0,448	-0,178	0,405	0,148
Verde	-0,245	0,009	-0,076	0,421	-0,061	0,387	0,400
Vermelho	-0,162	-0,048	-0,034	0,363	-0,200	0,242	0,329
RedEdge	0,324	0,038	-0,006	0,323	-0,180	0,538	0,621
IVP	0,027	0,136	-0,069	-0,071	-0,198	-0,115	-0,015
NDRE	0,280	0,040	-0,040	-0,299	0,032	-0,490	-0,524

Analisando a Tabela 4, o maior resultado foi registrado pela interação da banda do Red Edge com o peso total, sendo este superior aos valores entre a mesma variável e os IV. A banda também mostrou ter uma correlação significativa com a variável produtividade. Em ambos os casos, os valores ultrapassaram 0,500. Sendo assim, estas variáveis foram escolhidas para dar continuidade no processo de geração de modelos.

Nas demais variáveis apenas o fruto do tipo seco ultrapassou o valor de 0,400. Os piores resultados foram registrados novamente pelo fruto do tipo cana, e os nematoides. Esses resultados corroboram ainda mais com o encontrado na estatística descritiva dos dados, cujo essas variáveis apresentavam conjunto de dados pouco homogêneos. A Tabela 5 apresenta os resultados extra o satélite Sentinel 2 e os parâmetros de estudo.

Tabela 5 - Correlação entre as bandas e os IV do satélite Sentinel 2 sem correção e os parâmetros agronômicos

Bandas/IVs	Verde	Cana	Cereja	Seco	Nematoide	Produtividade	Peso Total
Azul	-0,392	-0,178	-0,159	0,628	-0,034	0,539	0,288
Verde	-0,261	-0,096	-0,147	0,512	0,036	0,421	0,292
Vermelho	-0,264	-0,151	-0,150	0,499	0,089	0,188	0,183
IVP	0,502	0,128	0,115	-0,581	-0,088	-0,630	-0,482
EVI	-0,512	-0,165	-0,158	0,678	0,063	0,600	0,449
ARVI	0,518	0,172	0,155	-0,694	-0,048	-0,618	-0,456

Embora o satélite Sentinel 2 possua o sensor testado com menor resolução espacial, os resultados obtidos de correlação deste com os parâmetros agronômicos foram os maiores obtidos dentre os três analisados. A variável fruto do tipo seco, e produtividade, tiveram valores que ultrapassaram 0,600 (em módulo), sendo que, estes valores foram obtidos quando correlacionadas com o índice ARVI (-0,694) e o IVP (-0,630) respectivamente para frutos do tipo seco e produtividade. Sendo assim, foram escolhidas essas 2 variáveis para prosseguir no processo de elaboração de modelos.

As variáveis fruto do tipo cana, e nematoides apresentaram novamente os resultados mais baixos de correlação, sendo estes iguais a -0,096 e 0,036 respectivamente. Dessa forma, essas variáveis não foram capazes de apresentar resultados significativos com nenhum dos sensores utilizados. Portanto, não foram utilizadas na sequência do trabalho.

6.2.2 Imagens orbitais com correção atmosférica

A Tabela 6 mostra os resultados para o satélite RapidEye.

Tabela 6 - Correlação entre as bandas e os IV do satélite RapidEye com correção e os parâmetros agronômicos

Bandas/IVs	Verde	Cana	Cereja	Seco	Nematoide	Produtividade	Peso Total
Azul	-0,317	-0,120	-0,037	0,450	-0,176	0,376	0,301
Verde	-0,249	0,021	-0,071	0,422	-0,060	0,364	0,348
Vermelho	-0,161	-0,051	-0,025	0,360	-0,200	0,229	0,256
RedEdge	0,337	0,078	0,012	0,326	-0,180	0,473	0,499
IVP	0,011	0,183	-0,081	-0,056	-0,198	-0,124	0,087
NDRE	0,301	0,014	-0,059	-0,307	0,065	-0,463	0,394

Assim como ocorrido anteriormente, as variáveis com maior destaque foram fruto do tipo seco e produtividade. Entretanto, os valores de correlação foram levemente menores, sendo o maior valor obtido entre a correlação do peso total com a banda do RedEdge (0,499), seguido pela produtividade correlacionada com a mesma banda, apresentando o valor de 0,473. A variável fruto do tipo seco também apresentou um valor próximo a estes (0,450), entretanto, correlacionada com a banda do azul. Para geração do modelo, foram consideradas as variáveis produtividade e peso total, para que fossem gerados modelos das mesmas variáveis nas duas situações (imagem com e sem correção).

Os demais parâmetros não apresentaram resultados próximos a isso, sendo todos inferiores a 0,340. Por esse motivo não foram levadas adiante no processo de geração dos modelos.

A Tabela 7 apresenta os dados de correlação para a imagem do satélite Sentinel 2 corrigida atmosféricamente.

Tabela 7 - Correlação entre as bandas e os IV do satélite Sentinel 2 com correção e os parâmetros agronômicos

Bandas/IVs	Verde	Cana	Cereja	Seco	Nematoide	Produtividade	Peso Total
Azul	-0,417	-0,147	-0,129	0,635	-0,151	0,466	0,308
Verde	-0,295	-0,121	-0,152	0,534	-0,098	0,466	0,273
Vermelho	-0,328	-0,156	-0,147	0,543	-0,115	0,272	0,189
IVP	0,553	0,151	0,123	-0,595	-0,056	-0,671	-0,466
EVI	-0,568	-0,166	-0,149	0,700	-0,117	0,637	0,450
ARVI	0,559	0,175	0,146	-0,710	0,118	0,641	-0,447

Neste sensor os resultados de correlação seguiram o mesmo padrão da imagem sem correção. Os maiores resultados foram obtidos pelas variáveis fruto do tipo seco, verde e produtividade. O maior valor encontrado entre todos os sensores analisados, com ou sem correção, foi obtido nesta análise, onde o fruto do tipo seco obteve resultado de 0,710 quando correlacionado com a variável do tipo seco. Dessa forma, para a geração do modelo foram consideradas essas três variáveis.

Todavia, o resultado encontrado com o índice EVI (0,700), também é considerável. Segundo Amaral et al. (2013), o índice EVI pode ser utilizado como um parâmetro para a estimativa de produtividade. No trabalho, os autores utilizaram o índice sobre imagens do satélite MODIS para geração de um modelo no qual obtiveram resultados “convincentes”, para estimativa de produtividade.


Os demais parâmetros também seguiram os mesmos padrões, e nenhum obteve resultado superior a 0,500. Sendo assim, essas variáveis também não tiveram continuidade quando analisadas com esse sensor.

6.3 Experimento 1

6.3.1 Estimativa de modelos empíricos para predição de produtividade

A Figura 12 mostra os dados plotados do drone.

Figura 11 - Gráficos de regressão da correlação dos valores de produtividade estimados em campo e os valores de radiometria da imagem RGB do drone (reflectância da banda correspondente ao índice TGI)

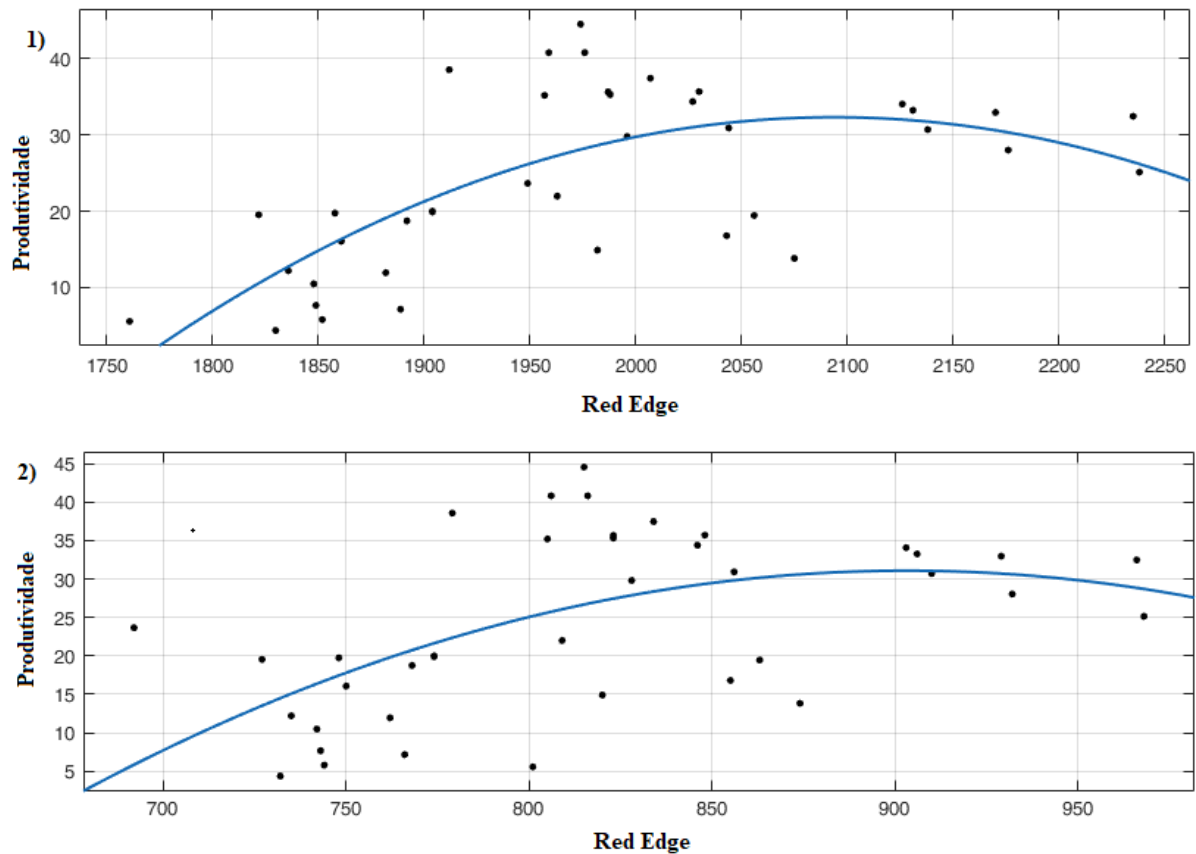


Fonte: O autor.

A partir da análise gráfica é possível notar que os valores de produtividade decrescem a medida que os valores de reflectância do índice TGI aumentam. Dessa forma, embora dispersos, os dados apresentam uma tendência decrescente, que se aproxima a uma reta, caracteriza de uma curva de polinômio de primeiro grau. Sendo assim, para este caso foi selecionado o modelo de regressão simples, entre duas variáveis.

As Figuras 13 e 14 mostram gráficos de regressão dos sensores orbitais provenientes do satélite RapidEye e Sentinel 2, respectivamente. Em cada figura, existe o gráfico originado dos valores corrigidos atmosféricamente, e dos valores sem correção atmosférica, para que fosse possível observar as principais diferenças entre esses valores.


Figura 12 - Gráficos de regressão da correlação dos valores de produtividade estimados em campo e os valores de radiometria da imagem multiespectral do satélite RapidEye



Fonte: O autor.

Na Figura 13 no primeiro gráfico os pontos plotados representam os valores do sensor com correção atmosférica, ao passo que o segundo gráfico os pontos sem correção. Em ambos os casos, é possível notar uma tendência quadrática no comportamento dos dados, sendo que na Figura 13.1, a curva se dispõe de forma mais acentuada, e na Figura 13.2, ela apresenta-se mais suavizada. Nesse contexto, para as duas situações optaram-se por gerar um modelo pelo método de regressão quadrático, no qual a equação de resposta foi definida pelo polinômio do segundo grau.

Figura 13 - Gráficos de regressão da correlação dos valores de produtividade estimados em campo e os valores de radiometria da imagem multiespectral do satélite Sentinel 2



Fonte: O autor.

Na Figura 14.1, o gráfico apresenta os pontos amostrados entre os valores corrigidos atmosféricamente da banda do IVP com a produtividade, e a Figura 14.2 os mesmos valores, porém sem correção. Ao compararmos os dois gráficos, o comportamento dos dados com e sem correção atmosférica apresentam tendências diferentes entre si. Enquanto o primeiro gráfico os dados se dispõem de forma quadrática, no segundo gráfico, os dados apresentam-se mais linearizados. Tendo isto em vista, para a geração dos modelos, foram utilizados métodos de regressão diferentes para cada conjunto de amostra, sendo eles: quadrático e simples respectivamente.

A Tabela 8 apresenta as equações geradas para cada conjunto de dados apresentado anteriormente. Nela, estão dispostas informações referentes ao tipo de sensor, se a equação é originada dos dados com ou sem correção atmosférica, seguidos pela fórmula, RMSE em porcentagem e o R^2 .

Tabela 8 - Modelos matemáticos gerados empiricamente para estimativa de produtividade

Sensor	Correção Atm.	Modelo	RMSE%	R ²
Drone	Não	$59,73 - 0,825 * TGI$	37,44	23,97
RapidEye	Não	$-0,000295 * RE^2 + 1,235 * RE - 1261$	54,35	46,57
Sentinel 2	Não	$-0,0001509 * IVP^2 + 0,7209 * IVP - 827,5$	36,46	45,96
RapidEye	Sim	$-0,0005657 * RE^2 + 1,022 * RE - 430,4$	48,12	29,87
Sentinel 2	Sim	$187,6 - 0,01354 * IVP$	38,64	43,53

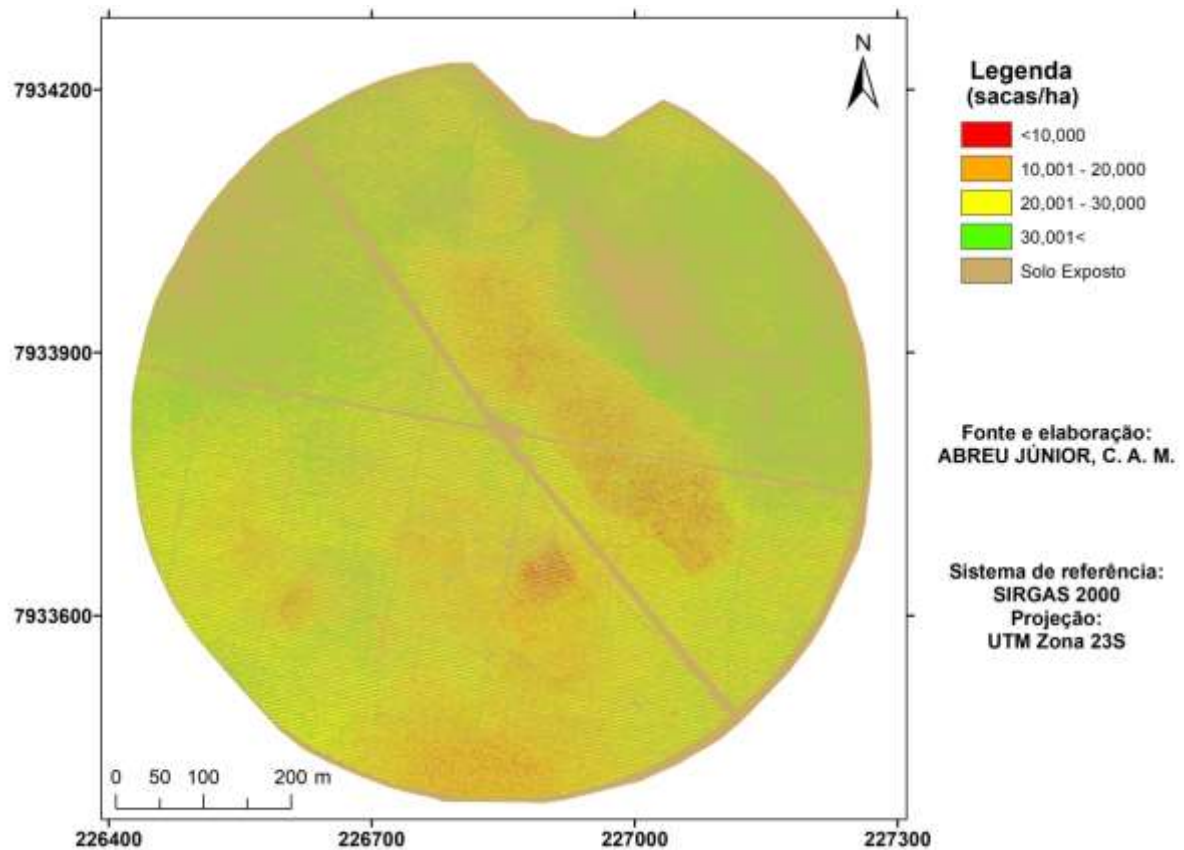
Na Tabela 8, analisando os resultados, nota-se que o modelo que apresentou melhor resultado, no que diz respeito ao RMSE, foi o proveniente do sensor Sentinel 2 sem correção atmosférica, embora este tenha sido o sensor que possui a maior resolução espacial dentre todos os testados. O segundo melhor foi o modelo oriundo do drone, seguido pelo modelo do satélite Sentinel 2 com correção atmosférica. Os piores resultados vieram do satélite RapidEye, sendo desta vez, o modelo gerado através dos dados corrigidos atmosféricamente o que apresentou melhor resultado.

Ao analisarmos o R², os melhores modelos passam a serem os originados dos satélites RapidEye e Sentinel 2, sem correção atmosférica, respectivamente, seguidos pelos modelos desde mesmo satélite, porém corrigidos. O menor R² é encontrado no drone, sendo este igual a 23,97. Em uma análise conjunta, na estimativa de produtividade, com as plataformas testadas, os resultados de R² e RMSE parecem não ter uma relação direta, já que no drone, os parâmetros apresentaram resultados opostos, sendo esta plataforma a que apresentou o segundo melhor RMSE e o pior R², com valores iguais a 37,44 e 23,97 respectivamente.

6.3.1.1 Distribuição espacial da produtividade sobre a área de estudo

A Figura 15 mostra o resultado da distribuição espacial da variável produtividade sobre a imagem do drone.

Figura 14 - Distribuição espacial da produtividade na área de estudo, proveniente do modelo aplicado sobre a banda com os valores de reflectância do índice TGI do drone

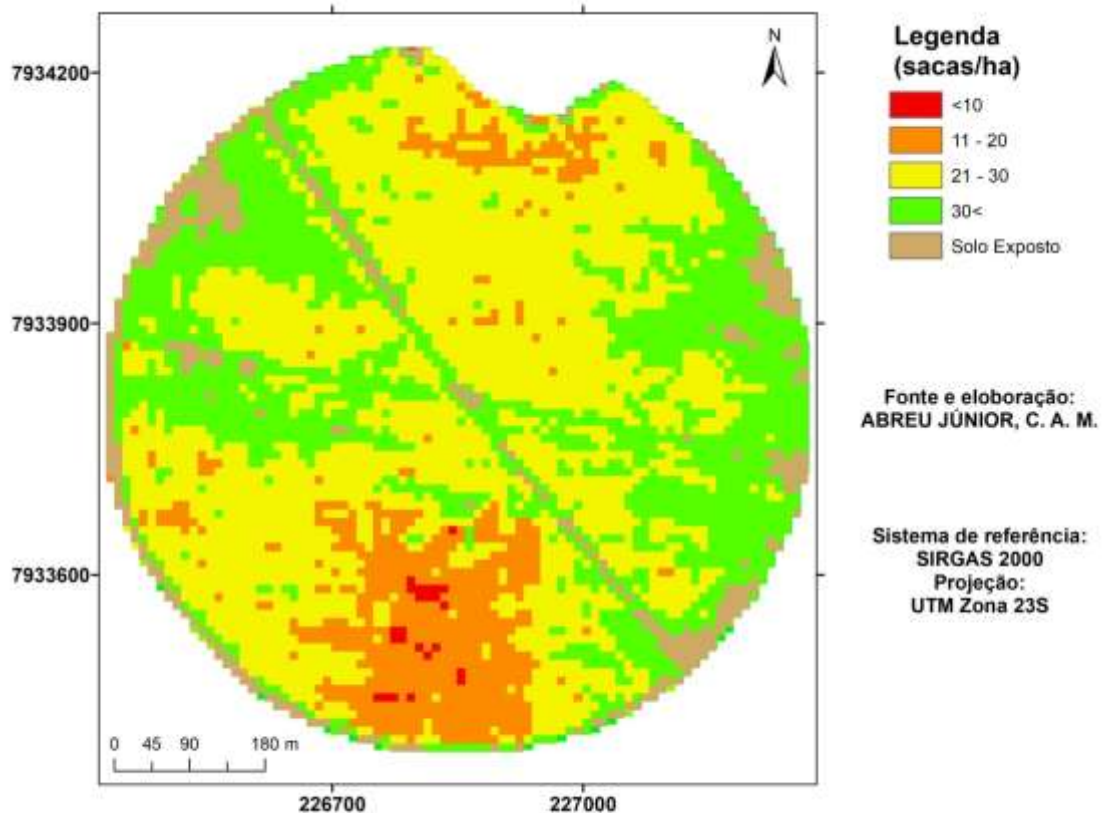


Fonte: O autor.

A Figura 15 apresenta o mapa gerado pela equação do drone. A produtividade é dada em sacas por hectares, e foi dividida em 4 classes, sendo elas: valores inferiores a 10 sacas, em vermelho, valores entre 11 a 20 sacas, em laranja, valores entre 21 a 30 sacas, em amarelo, e superiores a 30 sacas, em verde. O solo exposto ficou caracterizado pela cor marrom. Analisando o mapa, observa-se que a parte sul do pivô teve mais focos com produção inferior a 10 sacas/ha. Além disso, existe outra grande mancha com produção inferior 10 sacas/ha no sentido transversal, próximo aos carregadores. Esses focos podem estar relacionados com a presença de nematoides existentes na área.

A Figura 16 apresenta o mapa de produtividade gerado pela equação do satélite Sentinel 2, sobre a imagem com correção atmosférica.

Figura 15 - Distribuição espacial da produtividade na área de estudo, proveniente do modelo aplicado sobre a banda do IVP do satélite Sentinel 2




Fonte: O autor.

Ressalta-se que foi utilizada a mesma classificação de cores e de sacas nas duas imagens. Embora possua uma resolução espacial inferior a todas as outras plataformas testadas, a imagem proveniente do satélite Sentinel 2, apresenta comportamento semelhante ao mapa da Figura 15. Neste mapa, assim como no anterior, os principais focos de baixa produtividade são encontrados na parte sul do pivô. A principal diferença fica em função da detecção do solo exposto, que não aparece delimitado de forma muito precisa na Figura 16, quando comparado com a Figura 15. Além disso, em alguns *pixels* na borda do pivô foram calculados erroneamente como solo exposto, sendo que fazem parte da área plantada. Entretanto, de forma geral, o mapa também possibilita a identificação das áreas com menor produtividade.

6.3.2 Estimativa de modelos empíricos para predição qualitativa de frutos

A Figura 17 mostra os resultados gerados do drone.

Figura 16 - Gráficos de regressão da correlação dos valores de frutos do tipo seco e cereja estimados em campo e os valores de radiometria da imagem RGB do drone (reflectância da banda correspondente ao índice TGI e VDVI)

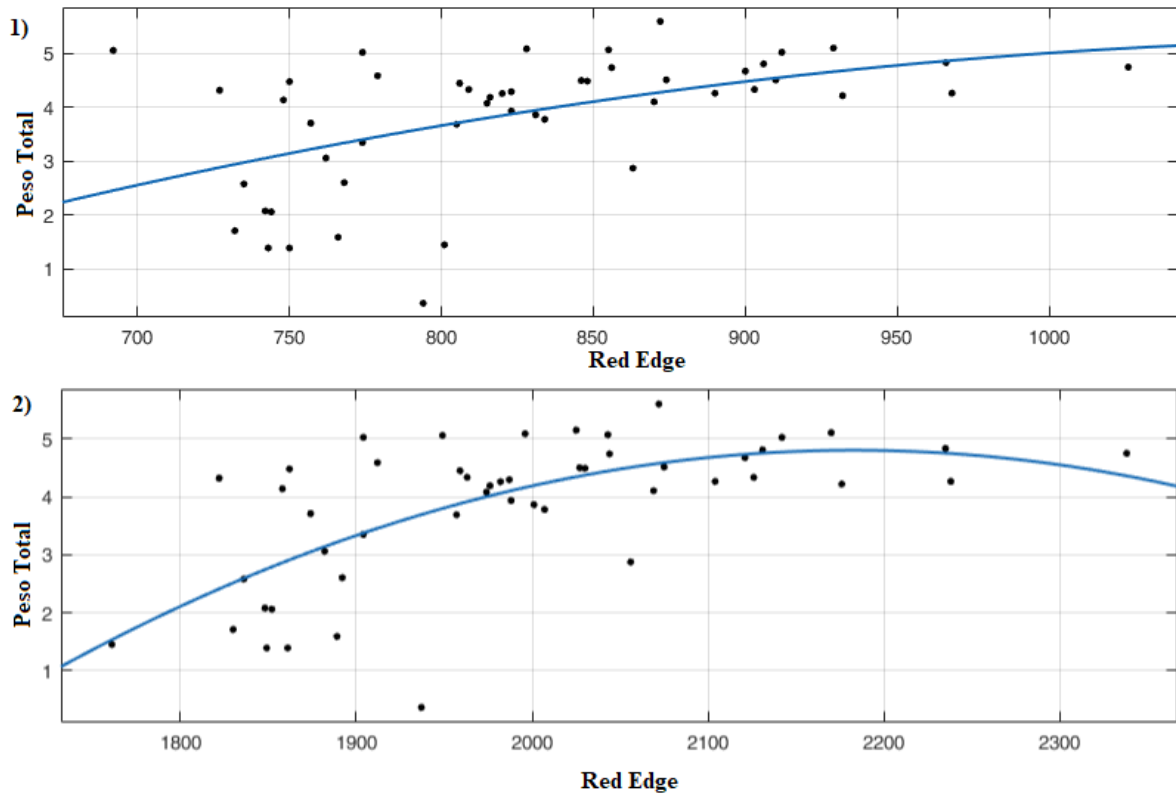


Fonte: O autor.

Na Figura 17, em ambos os casos, a curva que melhor se ajustou aos dados plotados foi a reta. Entretanto, na Figura 17.1, os dados apresentam comportamento decrescente, sendo que os maiores valores de fruto seco são encontrados com os menores dos valores do índice TGI, ao passo que no Figura 17.2, os dados apresentam comportamento crescente, sendo que quanto maior o valor do índice VDVI, maior é a quantidade de frutos cereja. Sendo assim, para a geração dos modelos foi utilizado o método de regressão simples.

As Figuras 18 e 19 apresentam os gráficos de distribuição das amostras do mesmo parâmetro, em função da imagem de cada satélite. Porém são comparadas as imagens corrigidas atmosféricamente com as não corrigidas atmosféricamente.


Figura 17 - Gráficos de regressão da correlação dos valores de peso total das amostras estimado em campo e os valores de radiometria da imagem multiespectral do satélite RapidEye (reflectância da banda Red Edge)



Fonte: O autor.

Na Figura 18.1, estão apresentados os dados relacionados com a imagem corrigida atmosféricamente, e a Figura 18.2 com a imagem sem correção. Para o satélite RapidEye, ambos os conjuntos de dados, tanto da imagem corrigida, quanto da imagem sem correção, apresentaram comportamento quadrático. Entretanto na Figura 18.1 a curva exibe-se de forma mais acentuada que na Figura 18.2, que possui um comportamento mais suave. Dessa forma, em ambos os casos, foram utilizados modelos de regressão quadrática para gerar as equações, sendo o resultado final um polinômio do segundo grau.

Figura 18 - Gráficos de regressão da correlação dos valores de fruto do tipo seco das amostras estimado em campo e os valores de radiometria da imagem multiespectral do satélite Sentinel 2 (reflectância da banda correspondente ao índice ARVI)



Fonte: O autor.

Na Figura 19.1 esta apresentado o conjunto de dados correlacionado com a imagem corrigida atmosféricamente, e na Figura 19.2, com a imagem sem correção. Em ambos os gráficos, nota-se que o melhor ajuste foi proporcionado por uma reta simples. Entretanto, ressalta-se a semelhança do comportamento entre os dois conjuntos de dados, sendo muito similares um ao outro, no qual a principal diferença esta nos valores do índice calculado, sendo na Figura 19.1 o intervalo de 0,46 a 0,60 e na Figura 19.2 de 0,49 a 0,64. Essa diferença é justificável uma vez que os valores de número digitais da imagem são alterados quando corrigidos atmosféricamente.

A Tabela 9 apresenta os modelos gerados através do método de regressão dos conjuntos de dados mostrados anteriormente. Na Tabela 9, está indicada a plataforma pelo qual se obteve a imagem, a variável resposta do modelo, se houve correção atmosférica, o modelo originado, e seu respectivo RMSE em porcentagem e o R^2 .

Tabela 9 - Modelos matemáticos gerados empiricamente para estimativa de parâmetros agronômicos

Sensor	Variável est.	C. Atm.	Modelo	RMSE%	R ²
Drone	Fruto seco	Não	$621,59 - 8,4429 * TGI$	31,20	27,16
Drone	Fruto cereja	Não	$-33,45 + 458,8 * VDVI$	61,81	27,53
Rapid Eye	Peso total	Não	$-82,78 - 0,00001838 * RedEdge^2 + 0,08024 * RedEdge$	24,81	42,86
Sentinel 2	Fruto seco	Não	$2013 - 3169 * ARVI$	45,68	48,2
Rapid Eye	Peso total	Sim	$-0,00001729 * RedEdge^2 + 0,03765 * RedEdge - 15,35$	23,58	25,21
Sentinel 2	Fruto seco	Sim	$2012,7 * - 3169,2 * ARVI$	45,43	48,19

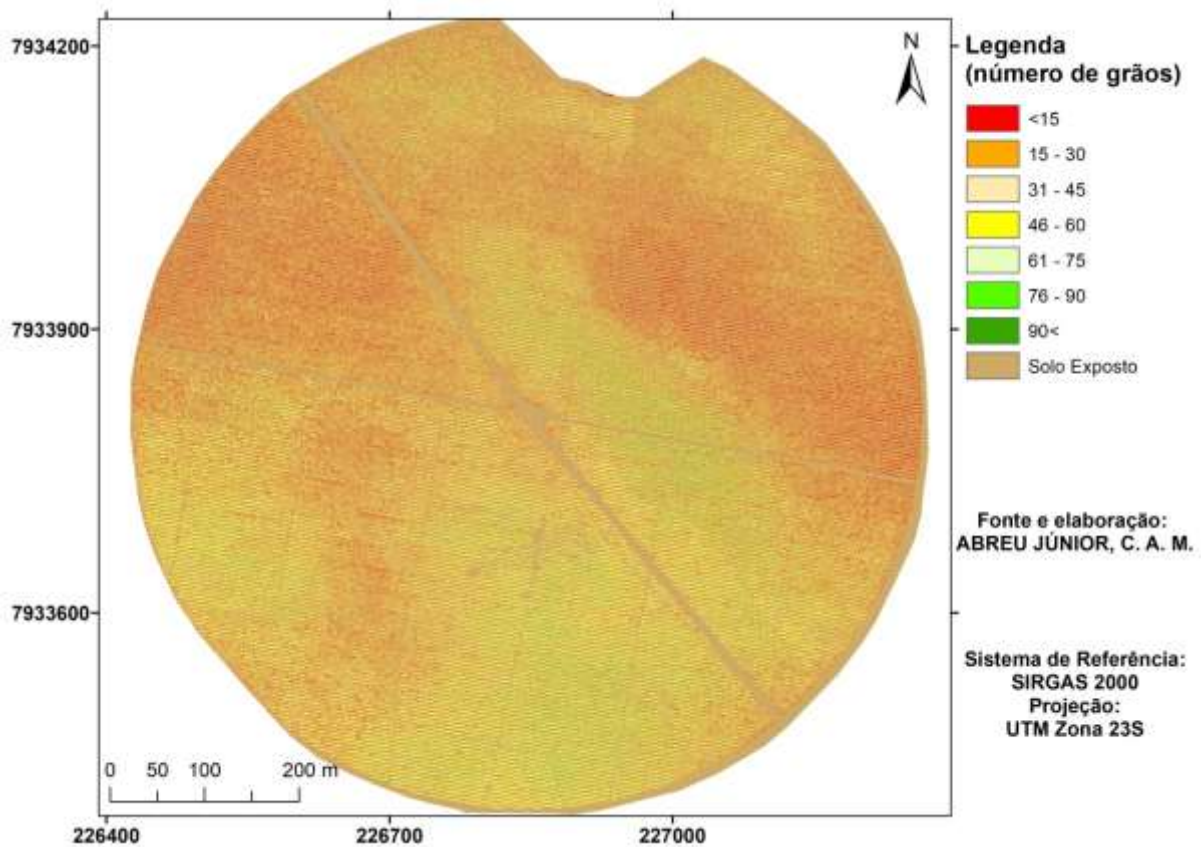
Diante dos resultados de RMSE e R² de cada modelo apresentado na Tabela 9, observa-se que os melhores resultados encontrados para esses parâmetros pertencem aos satélites RapidEye (com correção atmosférica) e Sentinel 2, respectivamente. Os valores de R² obtidos pelos modelos do satélite Sentinel 2, para as imagens com e sem correção atmosférica, são muito próximos um do outro, sendo a diferença não significativa para esse tipo de análise. No satélite RapidEye a diferença entre os valores de R² é de quase 10% entre os dois tipos de imagem. Para o drone, na comparação de dois tipos de frutos diferentes, os valores de R² também são muito próximos.

Os valores de RMSE quando comparados entre os sensores orbitais também são próximos um do outro, sendo para as imagens Sentinel 2 a diferença inferior a 0,3% e para as imagens RapidEye inferior a 1,3%. O maior erro registrado pertence ao modelo para predição de frutos do tipo cereja, sendo o erro total igual a 61,81%, sendo este o modelo menos confiável dos apresentados. Entretanto, esse resultado corrobora com o encontrado na análise descritiva das variáveis, onde o valor do coeficiente de variação dos frutos cereja foi igual a 53,33%.

6.3.2.1 Distribuição espacial dos parâmetros agronômicos sobre a área de estudo

A Figura 20 mostra a distribuição espacial dos frutos do tipo cereja, sobre a imagem do drone.

Figura 19 - Distribuição espacial dos frutos do tipo cereja na área de estudo, proveniente do modelo aplicado sobre a banda com os valores de reflectância do índice VDVI do drone




Fonte: O autor.

Na Figura 20, foram utilizadas classes para representar a distribuição espacial de frutos cereja na área de estudo. As classes variam de 15 em 15 frutos, tendo como limiar mínimo valores menores que 15 e máximo maiores que 90 frutos. Foi usado um degrade do vermelho para o verde, no qual verde representa os valores de alta concentração de frutos cereja, e vermelho de baixa concentração dos mesmos frutos. Analisando a Figura 20, as áreas com maior intensidade de frutos do tipo cereja estão localizadas na parte sul do pivô de estudo, enquanto a parte norte apresenta menor intensidade de frutos.

A Figura 21, apresenta a distribuição espacial dos frutos do tipo seco na área de estudo, em função do modelo gerado do drone.

Figura 20 - Distribuição espacial dos frutos do tipo seco na área de estudo, proveniente do modelo aplicado sobre a banda com os valores de reflectância do índice TGI do drone

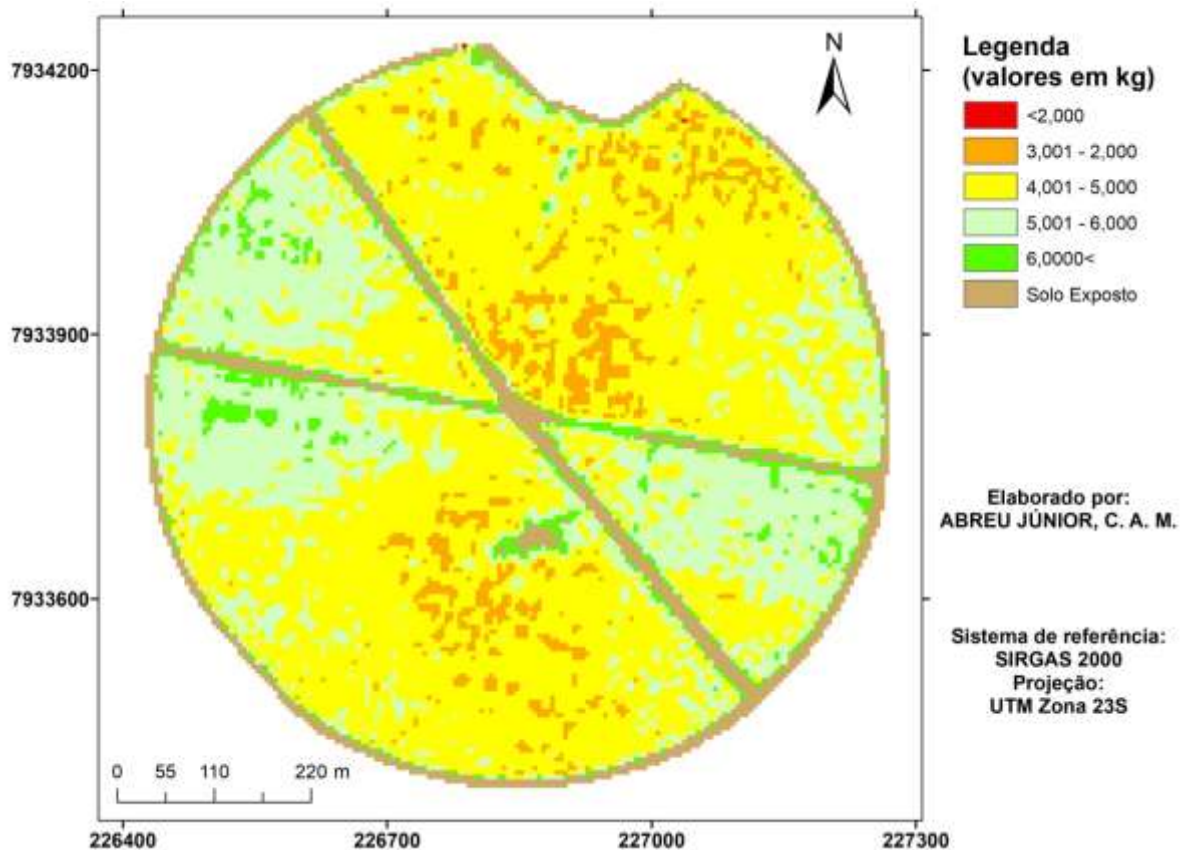


Fonte: O autor.

Na Figura 21 foi utilizado o mesmo modelo de representação gráfica, para cores e tonalidades na geração do mapa, que foi utilizado na Figura 20. Nesta imagem, a maior concentração de frutos seco aparecem parte norte do pivô de estudo. Em contrapartida, os principais focos com baixa intensidade de frutos estão na região sul. Existe uma mancha, transversal, com baixos valores de frutos paralelos ao carreador. Ao compararmos as Figuras 20 e 21 é possível notar que a distribuição espacial dos frutos do tipo cereja e seco são proporcionalmente inversos, isto é, as áreas com maior intensidade de frutos seco apresentam menor quantidade de frutos cereja, e vice-versa.

A Figura 22 apresenta os resultados da variável peso total, geradas através da imagem corrigida atmosféricamente do satélite RapidEye.

Figura 21 - Distribuição espacial do peso total dos frutos na área de estudo, proveniente do modelo aplicado sobre a banda RedEdge do satélite RapidEye



Fonte: O autor.

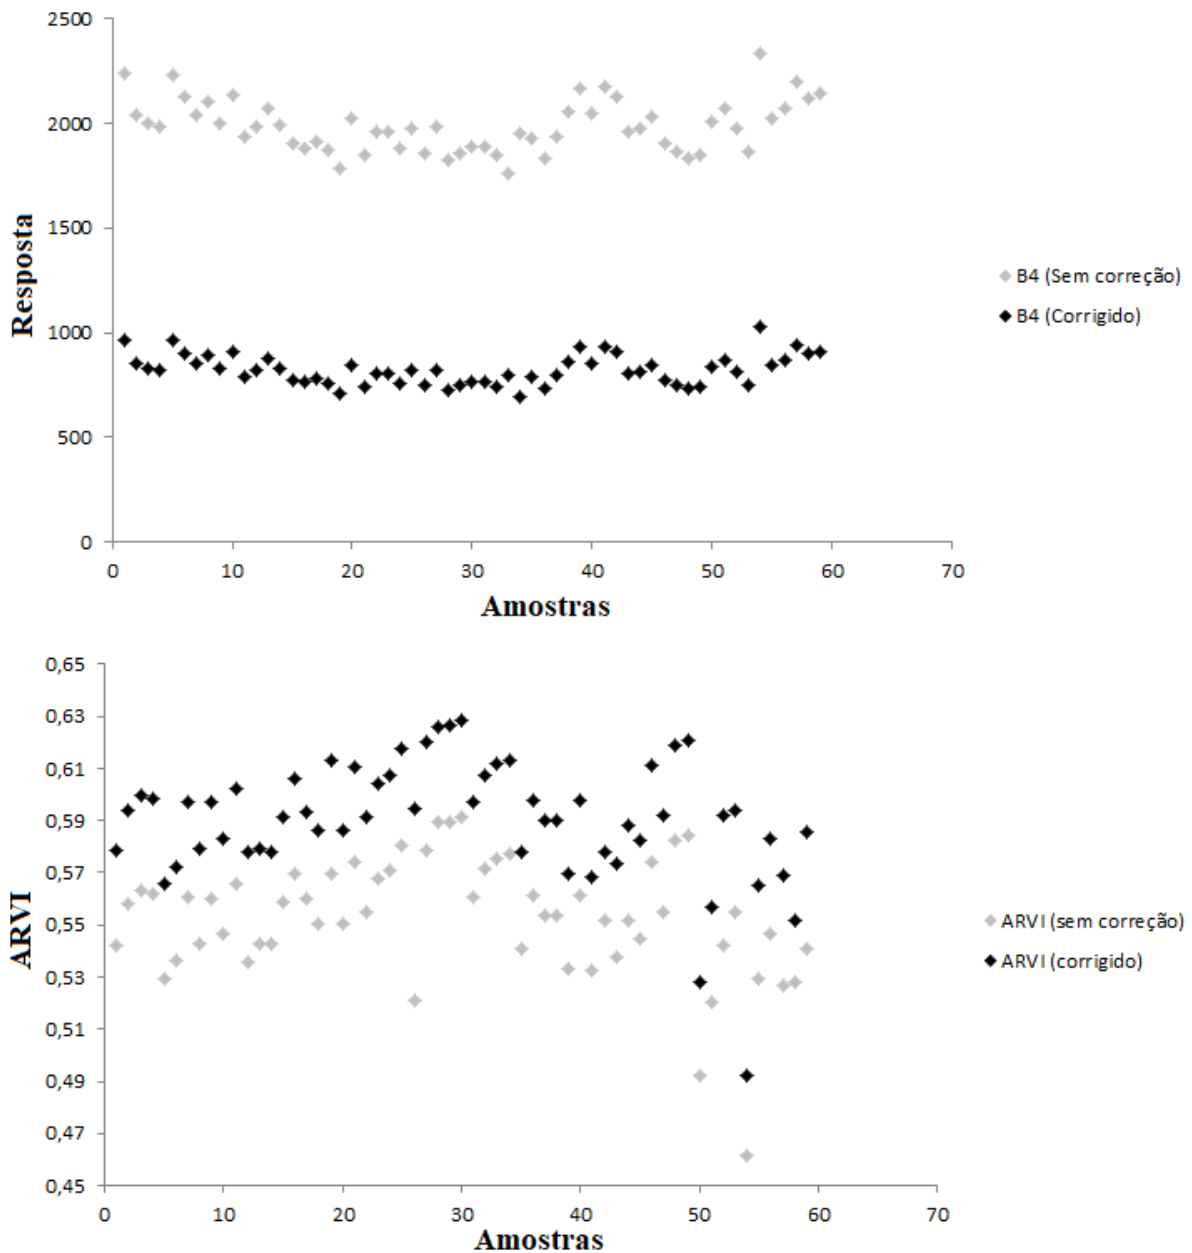
Na Figura 22 o intervalo de classes utilizado começa com o limiar mínimo de valores inferiores a dois quilogramas, e acresce de um em um até o limite superior, de seis quilogramas ou mais. Os maiores valores são representados pelos tons de verde, ao passo que os menores são representados pela cor vermelha. Analisando a imagem, é possível notar que a maior parte do pivô é predominada pela cor amarela, que representa o intervalo intermediário de peso total dos frutos (4 a 5 kg). Os maiores valores estão concentrados na parte superior esquerda do mapa e também no lado direito, na mesma amplitude.

6.4 Experimento II: comparação entre os modelos com correção e sem correção

Diante dos resultados apresentados nas seções anteriores, e dos modelos empíricos gerados para a estimativa de parâmetros agrônômicos, foi feito uma análise gráfica entre o comportamento da reflectância obtida pelos sensores orbitais utilizados, com e sem correção atmosférica. Na Figura 23.1 foi retratada a banda Red Edge do satélite RapidEye, e na Figura

23.2, o IV ARVI. Ambos os dados foram utilizados para gerarem os modelos de seus respectivos sensores, uma vez que obtiveram as melhores correlações conforme apresentado nas seções 6.2.1 e 6.2.2.

Figura 22 - Reflectância das bandas dos dados utilizados para correlação e geração dos modelos empíricos de estimativa de parâmetros agrônômicos dos satélites RapidEye (1) e Sentinel 2 (2)



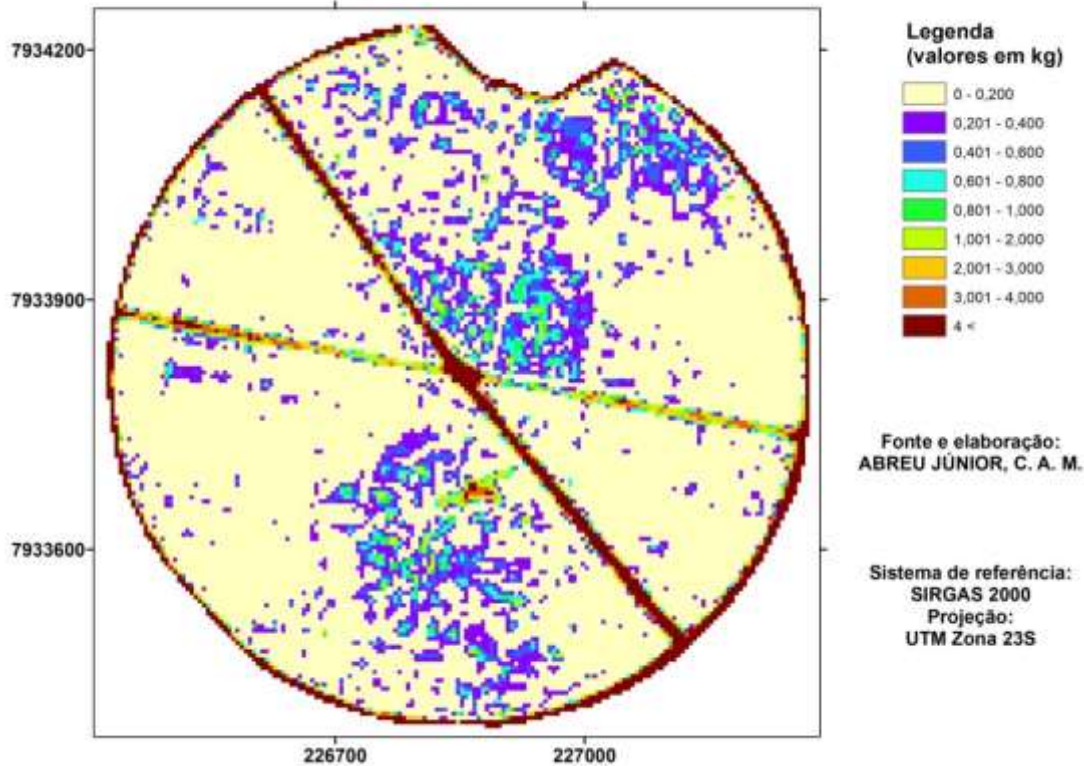
Fonte: O autor.

Analisando o comportamento dos dados da Figura 23, é possível observar que a tendência apresentada pelas curvas, em ambos os sensores, tanto com correção atmosférica, quanto sem, apresentam a mesma tendência ao longo das amostras utilizadas. A principal variação ocorre no intervalo no qual a amplitude dos dados ocorrem. No satélite RapidEye (Figura 23.1), os dados sem correção atmosférica estão situados em uma faixa espectral superior que os dados corrigidos, sendo os intervalos de aproximadamente 2000 a 2500 valor e abaixo de 1000 nanômetros, para dados sem correção atmosférica e corrigidos respectivamente. Já no satélite Sentinel 2 (Figura 23.2), isso se inverte. Os dados sem correção atmosférica ocupam um campo inferior do que os dados corrigidos atmosféricamente. Porém, nesse contexto, a distância entre as duas curvas é menor, sendo que uma parte dos dados ocupa a mesma amplitude nos dois casos.

Diante da semelhança apresentada na tendência dos dados espectrais utilizados para geração dos modelos de predição, foram gerados dois mapas (Figuras 20 e 21), em que é mostrado a diferença entre os valores obtidos pelos modelos corrigidos e não corrigidos atmosféricamente. Os mapas foram gerados através da subtração entre as bandas com os valores das variáveis agronômicas estimadas pelos modelos. Dessa forma, os mapas apresentam a mesma unidade de medida para determinação dos parâmetros, porém mostra o tamanho da diferença encontrada entre os modelos.

A Figura 24 apresenta o mapa oriundo do satélite RapidEye, no qual foi estimado o peso total dos frutos. Os valores são dados em kg.

Figura 23 - Diferença entre os modelos empíricos para estimativa de peso total, gerados através das imagens com e sem correção atmosférica, do satélite RapidEye

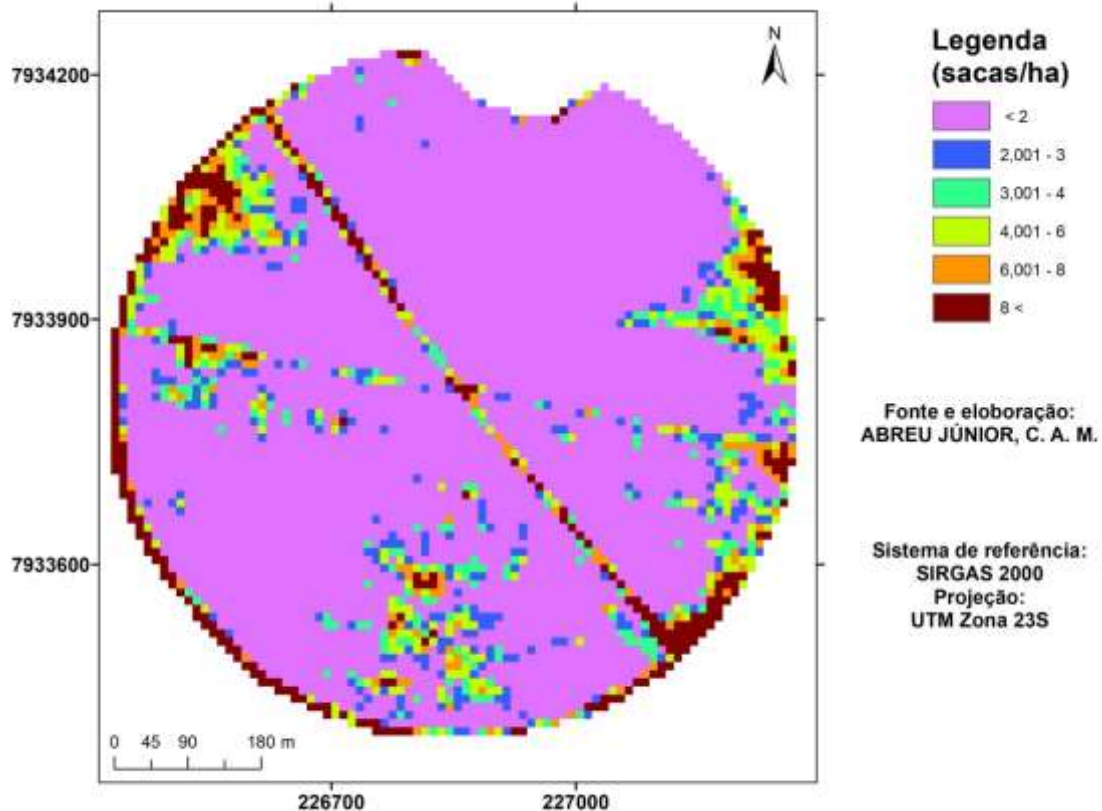


Fonte: O autor.

Na Figura 24, foram utilizados dois intervalos para incrementação das classes, uma vez que as maiores diferenças encontrada ao decorrer do mapa são inferiores a 1 kg. É possível notar que a maior parte do mapa apresenta diferenças iguais ou inferiores a 0,2 kg. Posteriormente, as cores roxa e azul são a que mais se destacam. Dessa forma, a maior parte das diferenças no mapa é encontrada abaixo de 0,6 kg, entre os dois modelos, corrigidos e não corrigidos atmosféricamente. Os maiores valores são encontrados principalmente na área coberta por solo exposto, o que não é significativo dado o propósito dos modelos.

A Figura 25 apresenta o mapa das diferenças do satélite Sentinel 2, para a estimativa de produtividade.

Figura 24 - Diferença entre os modelos empíricos para estimativa de produtividade, gerados através das imagens com e sem correção atmosférica, do satélite Sentinel 2



Fonte: O autor.

Na Figura 25 a maior parte do mapa apresenta valores inferiores a 2 sacas/ha de diferença. Posteriormente, os intervalos de 2 a 3 e 3 a 4 sacas/ha são os que aparecem em maior quantidade, porém, em menor quantidade que a primeira classe. As maiores diferenças são encontradas novamente nas áreas onde possui solo exposto, o que não é muito significativo para o modelo.

7 CONSIDERAÇÕES FINAIS

As imagens multiespectrais apresentaram resultados promissores e com grande potencial de desenvolvimento a medida que foram dedicadas novas pesquisas nesse sentido. Na imagem do drone, o modelo para predição de frutos do tipo seco apresentou correlação de -0,570 na etapa de análise multivariada, REMSE e R^2 igual a 31,20% e 27,16% respectivamente. Na estimativa de produtividade, os resultados encontrados para correlação, RMSE e R^2 , foram -0,488 e 37,44% e 23,97% respectivamente. Considerando que este

equipamento é de baixo custo, e conseqüentemente, fácil acesso aos produtores, os resultados podem ser encarados com certo otimismo para auxiliar o monitoramento agrícola de pequenos e médios produtores.

Para as mesmas variáveis, o satélite Sentinel 2 mostrou-se com um enorme potencial, uma vez que as correlações entre as variáveis retornaram o valor de 0,710 para frutos seco e 0,671 (ambos os valores em modulo) para produtividade. Os modelos tiveram resultados de RMSE e R^2 iguais a 38,64% e 43,53% para produtividade e 45,43% e 48,19% para frutos do tipo seco. Os resultados são interessantes principalmente se comparados com as imagens do satélite RapidEye, que não mostraram resultados muito melhores, o que talvez torne o satélite Sentinel 2 mais viável dado seu custo gratuito.

Considerando as imagens de levantamento aerofotogramétrico, o melhor IV que correlacionou com os parâmetros agrônômicos foi o TGI, já nas imagens oriundas de sensores orbitais, o melhor IV foi o ARVI. Além de obterem os maiores valores de correlação na maioria dos casos, esses IV apresentaram um melhor ajusta com cada parâmetro agrônômico, quando analisado estatísticas como o R^2 e RMSE.

Os parâmetros agrônômicos nematoides, frutos do tipo verde e cana não mostraram-se aptos a serem estimados por nenhum dos sensores utilizados. Todavia, estes resultados foram previstos desde a etapa de análise descritiva das variáveis de estudo. Sendo assim, para que esses parâmetros sejam estimados é necessário que sejam pesquisadas e testadas novas metodologias.

As diferenças entre os resultados obtidos das imagens corrigidas atmosféricamente ou não se apresentaram aceitáveis, sendo que os maiores valores foram encontrados em regiões de solo exposto, que não são o objetivo do modelo. Sendo assim, os resultados podem servir como uma análise inicial da lavoura, dependendo dos objetivos do produtor. Todavia, as diferenças foram encontradas através de modelos simples ou quadráticos de regressão. Considerando isso, sugere-se que haja estudos mais aprofundados, para a geração de modelos mais robustos de predição, para que talvez seja possível encontrar resultados ainda menores entre a diferença de imagens corrigidas atmosféricamente ou não.

REFERÊNCIAS

- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Regras da ANAC para uso de drones entram em vigor.** BRASIL. 2017. Disponível em :<
<http://www.anac.gov.br/noticias/2017/regras-da-anac-para-uso-de-drones-entram-em-vigor>>. Acesso em 15 abr. 2019.
- ALBERS, B. J.; NYQUIST, J. E.; PURDY, C. B. The department of energy's use of airborne remotely piloted vehicles for environmental management. In: ANNUAL ASSOCIATION FOR UNMANNED VEHICLE SYSTEMS INTERNATIONAL SYMPOSIUM AND EXHIBITION, 23., 1996, Orlando. **Proceedings...** p. 839-848
- AMARAL, G.M.; et al. Processamento digital de imagens MODIS com obtenção do EVI para aplicação de modelos de estimativa de produtividade para o café nos municípios de Barra do Choça, Barreiras, Bonito, Itamaraju, Luís Eduardo Magalhães e Prado/BA. In: Simpósio Brasileiro de Sensoriamento Remoto, XVI, 2013, Foz do Iguaçu. **Anais...** São Jose dos Campus - SP: Instituto Nacional de Pesquisas Espaciais, 2013 p. 1680-1687.
- ARRUDA, Rosalina Oliveira. **A produção de café arábica e sua relação com o crédito rural nos principais estados produtores do Brasil.** 2017. 21 f. TCC (Graduação) - Curso de Ciências Contábeis, Universidade Federal de Uberlândia, Uberlândia, 2017.
- BECK, P. S. A et al., The feasibility of detecting trees affected by Pine Wood Nematode using remote sensing. Europe Commission. **Joint Research Centre.** Institute of Environment and Sustainability, Italy. 2015. 34p.
- BISPO, R. C. **Uso da estabilidade temporal para estimativa de produtividade de café.** 2018. 114 f. Tese (Doutorado) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2018.
- BUSCHMANN, C.; NAGEL E. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. **International Journal of Remote Sensing**, 711-722, jan. 1993.
- BRASIL. **Agricultura familiar do Brasil é 8ª maior produtora de alimentos do mundo.** 08 jun. 2018. Disponível em: <<http://www.brasil.gov.br/noticias/economia-e-financas/2018/06/agricultura-familiar-brasileira-e-a-8a-maior-produtora-de-alimentos-do-mundo>>. Acesso em: 19 maio 2019.
- BRYN, L. M. **Página dinâmica para aprendizado do sensoriamento remoto.** 2008. 153 f. Dissertação (Mestrado) - Concentração e Desenvolvimento de Metodologias em Sensoriamento Remoto e Geoprocessamento. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.
- COELHO, L.; BRITO, J. N. **Fotogrametria digital.** Rio de Janeiro: Editora da Universidade do Estado do Rio de Janeiro, 2007. 196 p.
- CUNHA, J. P. A. R da.; NETO, M. A. S. Assembly of a remotely piloted aircraft of low cost applied to agriculture. **Engenharia Agrícola.** Jaboticabal, v. 37, n. 6, p. 1268-1274, nov/dez

2017. Disponível em: <<http://www.scielo.br/pdf/eagri/v37n6/1809-4430-eagri-37-06-1268.pdf>>. Acesso em: 19 maio 2019

DAMATTA, F.M.; RONCHI, C.P.; MAESTRI, M.; BARROS, R.S. Ecophysiology of coffee growth and production. **Brazilian Journal of Plant Physiology**, v.19, n.4, p.485-510, 2007.

DAMIAN et al. O uso de Aeronaves Remotamente Pilotadas (RPAS) na agricultura. In: SANTI, A. L. (Org.). **Agricultura de precisão no Rio Grande do Sul**. Santa Maria: CESPOL 2016. p. 285-309. Disponível em: <https://www.ufsm.br/cursos/pos-graduacao/santa-maria/ppgap/wp-content/uploads/sites/526/2019/01/AP_RS.pdf>. Acesso em: 8 maio 2019.

EMBRAPA. **Estudos socioeconômicos e ambientais** - Produtividade média da cafeicultura brasileira em 2018. 2018. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/31412007/produtividade-media-da-cafeicultura-brasileira-em-2018-devera-ser-a-maior-ja-registrada-com-2947-sacas-por-hectare>> Acesso em: 10/05/2019.

ENGESAT. **RapidEye**. Disponível em: < <http://www.engesat.com.br/imagem-de-satelite/RapidEye/>>. Acesso em: 01/06/2019.

ENGESAT. **Sentinel 2 2**. Disponível em: < <http://www.engesat.com.br/Sentinel-2-2/>>. Acesso em: 01/06/2019.

ENVI. **Atmospheric Correction Module: QUAC and FLAASH User's Guide**. v. 4.7. ago. 2009. Disponível em: <>. Acesso em: 10 maio 2019.

FIGUEREDO, D. **Conceitos Básicos de Sensoriamento Remoto**. Companhia Nacional do Abastecimento. Brasil, 2005.

FERRAZ, G. S. et al. Variabilidade espacial e temporal do fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola**, Jaboticabal, v. 32, n.1, p. 140-150, jan/fev. 2012. Disponível em: < http://www.sbicafe.ufv.br/bitstream/handle/123456789/10740/Eng.%20Agric%20_v.%2032_n.%201_p.%20140%20-%20150_2012.pdf?sequence=1&isAllowed=y>. Acesso em: 10 maio 2019.

GITELSON, A.A., MERZLYAK, M.N., 1996. Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing of chlorophyll. **J. of Plant Phys.** 148(3-4), pp. 494-500.

GONÇALVES, G.R. **Elementos da fotogrametria analítica**. Coimbra: Departamento de Matemática da FCTUC, 2006.

HUNT JR, E. R.; EITEL, J.; DAUGHTRY, C.; LONG, D. Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. **Agronomy Journal**, [s.l.], v. 103, n. 4, p.1090-1099, maio 2011.

ITO, D.S.; MACHADO, A.C.Z.; SILVA, S.A.. Distribuição de espécies de nematoides do gênero *Meloidogyne* em regiões cafeeiras do Paraná. **Ciência Florestal**, Londrina, v. 1, n. 22, p.113-124, jan. 2012.

JOHANN, J. A. et al. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa agropecuária brasileira**, Brasília, v. 47, n. 9, p. 1295-1306, set. 2012.

JESSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 4 ed. Pearson, 2015. 544 p.

LIMA, L. C. de. et al. Crescimento e produtividade do cafeeiro irrigado, em função de diferentes fontes de nitrogênio. **Coffee Science**, Lavras, v. 11, n. 1, p. 97-107, jan./mar. 2016. Disponível em: < http://sbicafe.ufv.br/bitstream/handle/123456789/8177/Coffee%20Science_v11_n1_p97-107_2016.pdf?sequence=1&isAllowed=y>. Acesso em: 1 maio 2019.

LUC, M.; SIKORA, R.A.; BRIDGE, J. **Plant parasitic nematodes in subtropical and tropical agriculture**. 2.ed. Wallingford: CABI, 2005. p.529-580.

MCKINNON, T.; HOFF, P. **Comparando Índices de Vegetação Baseados em RGB com o NDVI para Imagens Drone Agrícolas**. Boulder, 2017. Disponível em: < <https://agribotix.com/blog/2017/04/30/comparing-rgb-based-vegetation-indices-with-ndvifor-agricultural-drone-imagery/>> Acesso em: 15 maio 2019.

MENEZES R. P; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília. 2012.

MESQUITA, Carlos Magno de et al. **Manual do café: colheita e preparo (Coffea arábica L.)**. Belo Horizonte: EMATER-MG, 2016. 52 p. il.

NOVO, Evlyn M. L. de Moraes. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Edgard Blucher Ltda., 2010. 387 p.

OLIVEIRA, Gildriano Soares de. **Produtividade de biomassa de cana-de-açúcar em função dos índices de vegetação utilizando técnicas de sensoriamento remoto**. Tese: Mestrado. Repositório UNESP, 2015.

PICOLI, M. C. A. et al. Índice de vegetação do sensor Modis na estimativa da produtividade agrícola da cana-de-açúcar. **Bragantia**, Campinas, v. 68, n. 3, p. 789-795, 2009.

PEREIRA, S. P. et al. Crescimento, produtividade e bienalidade do cafeeiro em função do espaçamento de cultivo. **Pesquisa Agropecuária Brasileira**, Brasília – DF, v. 46, n. 2, p. 152-160, fev. 2011. Disponível em: < <http://www.scielo.br/pdf/pab/v46n2/v46n02a06.pdf>>. Acesso em: 10 maio 2019.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento Remoto da Vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. v. 1, 176p.

SCCON (Santiago e Cintra Consultoria). Imagens Planet. Disponível em: <<https://www.scccon.com.br/produtos/imagens-planet/>>. Acesso em: 01/06/2019.

SILVA, B A. de O.; REIS, E. A. dos. A bienalidade da cafeicultura e o resultado econômico da estocagem. **Custos e agronegócio on line**, Recife – PE, v. 9, n. 3, p. 2-26m jul./set. 2013.

SILVA, C.A.; TEODORO, R.E.F.; MELO, B. Produtividade e rendimento do cafeeiro submetido a lâminas de irrigação. **Pesquisa agropecuária brasileira**, v.43, n.3, p.387-394, 2008.

SILVA, C.R.; MACHADO, S.L.D.; ARAUJO, A.A.; ABREU JUNIOR, C.A.M.; Analysis of the phenology dynamics of brazilian caatinga species with ndvi time series. **CERNE**, Lavras, v.24, n. 1, p.48-58, 2018.

TOMMASELLI, A. M. G. **Fotogrametria Básica**. 2009. Disponível em: . Acesso em: 4 nov. 2019.

RAMOELO, Abel et al. Potential to monitor plant stress using remote sensing tools. **Journal Arid Environments**, v.115, n. 1, p.134-144, 2015.

ROUSE JUNIOR, J. W.; HAAS, R. H.; DEERING, D. W.; SCHELL, J. A.; HARLAN, J. C. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Greenbelt, Maryland: NASA, 1974. 371 p.

RUDJORD, Ø.; TRIER, Ø. D. **Evaluation of FLAASH atmospheric correction**. Oslo: Norsk Regnesentral, 2012. 24p. Disponível em: <https://www.nr.no/directdownload/1338298623/Rudjord-Trier_FLAASH_2012.pdf>. Acesso em: 19 maio 2019.

VALE, A. R. do.; CALDERARO, R. A. P.; FAGUNDES, F. N. A CAFEICULTURA EM MINAS GERAIS: estudo comparativo entre as regiões Triângulo Mineiro/Alto Paranaíba e Sul/Sudoeste. **Geografia agrária**. Edição especial do XXI ENGA-2012, p. 1-23, jun. 2014.

ZISCHINSKY, T.; DORFNER, L.; ROTTENSTEINER, F. **Application of a new Model Helicopter System in Architectural Photogrammetry**. Amsterdam: IAPRS, 2000. Part B5/2. (v. XXXIII).