

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

PABLO HENRIQUE DE SOUZA ASSIS

**MAPEAMENTO DE PARÂMETROS AGRONÔMICOS DO CAFEIEIRO
A PARTIR DE IMAGENS TOMADAS POR AERONAVE
REMOTAMENTE PILOTADA**

MONTE CARMELO

2019-2

PABLO HENRIQUE DE SOUZA ASSIS

**MAPEAMENTO DE PARÂMETROS AGRONÔMICOS DO CAFEIEIRO
A PARTIR DE IMAGENS TOMADAS POR AERONAVE
REMOTAMENTE PILOTADA**

Projeto apresentado como requisito para a aprovação na disciplina de Trabalho de Conclusão de Curso II no curso de Engenharia de Agrimensura e Cartográfica na Universidade Federal de Uberlândia.

Orientador: Prof. Dr. George Deroco Martins.

MONTE CARMELO

2019-2

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me guiado e abençoado com saúde, fé, foco e força para superar todos os empecilhos, obstáculos e desafios.

Agradeço aos meus pais Francisco e Mara por sempre me motivarem à dedicação aos estudos e me ajudarem a chegar onde estou agora.

Agradeço a Aline pelo companheirismo em situações boas e nas horas difíceis.

Agradeço aos meus amigos Rafael, Keliton, Vinicius, José Vinícius e Samuel pela forte contribuição para a realização deste trabalho.

Aos docentes Prof.^a Dr.^a Naíssa Batista e Prof. Dr. Gabriel Guimarães pelos conselhos dados no decorrer da elaboração do trabalho.

Agradeço ao Prof. Dr. Pedro Paulo Barros por aceitar com gentileza o convite para contribuir neste importante trabalho para a minha formação profissional e pessoal.

Além destes, um agradecimento em especial ao Prof. Dr. George Deroco, docente responsável pela orientação do trabalho com total competência, paciência, apoio e dedicação.

Por fim, agradeço à Universidade Federal de Uberlândia pela estrutura e ambiente amigável oferecido.

“O sucesso é ir de fracasso em fracasso sem perder o entusiasmo.”

(Winston Churchill)

RESUMO

O cultivo dos grãos de café vem se mostrando cada vez mais como uma das culturas predominantes no mercado atual. Com isso, faz-se necessário compreender e monitorar as variabilidades existentes nas grandes lavouras pelo mundo. Para tanto, as técnicas de Sensoriamento Remoto direcionadas ao monitoramento das variabilidades espectrais de uma cultura torna possível mapear e estudar as variabilidades espaciais e os fatores limitantes da produção. Dentre diversas variáveis, este trabalho objetivou o mapeamento de parâmetros relacionados à produtividade, tais como o Teor de Clorofila e a Área Foliar de uma cultura cafeeira localizada nas proximidades do município de Monte Carmelo - MG. O mapeamento foi gerado a partir de modelos de regressão através da relação entre amostras obtidas *in situ* com o valor radiométrico de imagens tomadas por uma aeronave remotamente pilotada. Desse modo, foram realizados dois voos com altitudes 70 e 120 metros. Para a extração dos valores radiométricos foram adotadas duas técnicas, a primeira trabalhando com região de interesse (ROI) delimitada por polígonos. Já a segunda, trabalhando com ROI delimitada por pontos. Os resultados mostraram que para o voo de maior altitude a correlação entre as medidas de campo e a radiometria das imagens foi melhor. A precisão dos modelos estimadores com a técnica ROI delimitada por polígonos apresentou melhor correlação com os índices TGI ($r = 0,515$ e $RMSE = 16,43\%$) para a clorofila e NDVI ($r = 0,484$ e $RMSE = 15,85\%$) para área foliar. Já com o uso da ROI delimitada por pontos, os melhores resultados foram com os índices NDVI ($r = 0,870$ e $RMSE = 13,26\%$) para clorofila e TGI ($r = 0,756$ e $RMSE = 24,41\%$) para a área foliar. De modo geral, concluiu-se que embora a câmera Mapir possua suas limitações os modelos gerados conseguem estimar os dados com precisão significativa.

Palavras-chave: *Coffea arabica*. Parâmetros Agronômicos. Modelos de Regressão. Mapas.

LISTA DE FIGURAS

Figura 1	Perfis temporais do índice de área foliar para a cultura do trigo em: (A) duas datas distintas de plantio; (B) três diferentes anos agrícolas	14
Figura 2	Principais regiões do espectro eletromagnético	16
Figura 3	Características da reflectância espectral de vegetação verde e saudável para o intervalo de comprimento de onda (0,4 – 2,6 μm)	17
Figura 4	Níveis de aquisição de dados em sensoriamento remoto	19
Figura 5	Sobreposições do plano de voo	24
Figura 6	Localização da Área de Estudo. (A) Minas Gerais. (B) Limite municipal e área urbana de Monte Carmelo. (C) Área de Estudo	25
Figura 7	Drone Phantom 4 <i>Advanced</i> e sensor Mapir. (A) Drone Phantom. (B) Sensor Mapir com suporte de acoplamento	26
Figura 8	Alvos para calibração e demarcação de pontos de apoio. (A) Alvos <i>Mapir Target</i> . (B) Alvos foto-identificáveis para os pontos de apoio	26
Figura 9	Receptor GNSS <i>Topcon Hiper V</i>	27
Figura 10	Medidor de teor de clorofila <i>ClorofiLOG Falker</i>	27
Figura 11	Fluxograma dos procedimentos metodológicos	29
Figura 12	Representação do método de aquisição dos valores de clorofila	30
Figura 13	Representação do cálculo da área foliar proposta por Barros et al. (1973)	31
Figura 14	Esquematização da etapa de pré-processamento	33
Figura 15	Amostragem dos dados e vetorização dos ROI's na área de estudo	35
Figura 16	Correlação entre a clorofila, bandas espectrais e índices de vegetação (Altitude de voo = 120 m)	37
Figura 17	Correlação entre a clorofila, bandas espectrais e índices de vegetação (Altitude de voo = 70 m)	38
Figura 18	Gráficos de regressões entre a clorofila A e TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	39
Figura 19	Gráficos de regressões entre a clorofila B e TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	40
Figura 20	Gráficos de regressões entre a clorofila Total e TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	40
Figura 21	Mapa da concentração da clorofila A sobre a área de estudo	41
Figura 22	Mapa da concentração da clorofila B sobre a área de estudo	42
Figura 23	Mapa da concentração da clorofila Total sobre a área de estudo	42
Figura 24	Correlação entre a clorofila, bandas espectrais e índices de vegetação (Altitude de voo = 120 m)	44
Figura 25	Correlação entre a clorofila, bandas espectrais e índices de vegetação (Altitude de voo = 70 m)	44

Figura 26	Gráficos de regressões entre a clorofila A e NDVI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	45
Figura 27	Gráficos de regressões entre a clorofila B e NDVI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	46
Figura 28	Gráficos de regressões entre a clorofila Total e NDVI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	46
Figura 29	Mapa da concentração da clorofila A sobre a área de estudo	47
Figura 30	Mapa da concentração da clorofila B sobre a área de estudo	48
Figura 31	Mapa da concentração da clorofila Total sobre a área de estudo	48
Figura 32	Comparação da eficácia dos modelos estimadores de clorofila	49
Figura 33	Correlação da área foliar com as bandas espectrais e IV's para os voos de 70 e 120 metros de altitude	50
Figura 34	Modelos de regressão entre a AF e o NDVI. (A) Regressão Linear Simples. (B) Regressão Polinomial Quadrática	51
Figura 35	Mapa do comportamento da área foliar na região de estudo	52
Figura 36	Correlação da área foliar com os canais espectrais e índices de vegetação	53
Figura 37	Modelos de regressão entre a AF e o TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.	53
Figura 38	Mapa do comportamento da área foliar na região de estudo	54
Figura 39	Comparação da eficácia dos modelos estimadores de AF	55

LISTA DE TABELAS

Tabela 1	Parâmetros para o aerolevanteamento. (A) Parâmetros do primeiro voo. (B) Parâmetros do segundo voo	32
Tabela 2	Parâmetros estipulados para o levantamento dos pontos de apoio	33
Tabela 3	Validação dos modelos de regressão pelo RMSE	43
Tabela 4	Validação dos modelos de regressão pelo RMSE	49

LISTA DE ABREVIATURAS E SIGLAS

AF	Área Foliar
ARP	Aeronave Remotamente Pilotada
IAF	Índice de Área Foliar
IFOV	<i>Instantaneous Field of View</i>
IVP	Infravermelho próximo
NDVI	<i>Normalized Difference Vegetation Index</i>
PDI	Processamento Digital de Imagens
RGB	Vermelho (<i>Red</i>), Verde (<i>Green</i>), Azul (<i>Blue</i>)
REM	Radiação Eletromagnética
RMSE	Raiz do Erro Médio Quadrático
SPAD	<i>Soil Plant Analysis Development</i>
SR	Sensoriamento Remoto
TGI	<i>Triangular Greenness Index</i>
TRC	Teor Relativo de Clorofila

SUMÁRIO

1 INTRODUÇÃO	10
2 OBJETIVOS	11
3 JUSTIFICATIVA	11
4 FUNDAMENTAÇÃO TEÓRICA	12
4.1 Parâmetros Agronômicos	12
4.1.1 Teor de Clorofila	13
4.1.2 Área Foliar	14
4.2 Sensoriamento Remoto da vegetação	15
4.2.1 Sensores	18
4.2.2 Resolução das Imagens	19
4.3 Processamento Digital de Imagens	20
4.3.1 Índice de Vegetação	22
4.4 Planejamento de voo	23
4.5 Análises estatísticas: Correlação e Regressão	24
5 MATERIAL E MÉTODOS	25
5.1 Área de Estudo	25
5.2 Material	26
5.3 Métodos	29
5.3.1 Obtenção das amostras georreferenciadas do teor de clorofila e AF	30
5.3.2 Planejamento e execução do voo	32
5.3.3 Processamento Digital de Imagens	33
5.3.4 Experimento 1	35
5.3.5 Experimento 2	36
6 RESULTADOS E DISCUSSÃO	37
6.1 Experimento 1	37
6.1.1 Modelos de estimativa do teor de clorofila pelo método ROI's via polígonos	37
6.1.2 Modelo de estimativa do teor de clorofila pelo método ROI's via pontos	43
6.1.3 Comparação dos modelos: ROI's via polígonos <i>versus</i> ROI's via pontos	49
6.2 Experimento 2	50
6.2.1 Modelo de estimativa da AF pelo método ROI's via polígonos.....	50
6.2.2 Modelo de estimativa da AF pelo método ROI's via pontos.....	52
6.2.3 Comparação dos modelos: ROI's via polígonos <i>versus</i> ROI's via pontos	55
7 CONSIDERAÇÕES FINAIS	56
REFERÊNCIAS	57

1 INTRODUÇÃO

A agricultura assume grande papel na sociedade devido à sua forte influência em relação ao setor de serviços, sendo assim, considerada um dos pilares para a manutenção da economia mundial. No Brasil, ela tem uma trajetória longa e crescente de relação com o comércio internacional (IPEA, 2014). Dentre as diversas culturas produzidas no país, a produção cafeeira é uma das que mais se destacam. O país bateu seu recorde em cultivo de café para o ano de 2018, sendo atualmente o responsável por cerca de 25% da produção mundial desses grãos (CONAB, 2018).

Levando em consideração as grandes dimensões do território nacional que são utilizadas para agricultura, é importante que o país possua e utilize-se das melhores e mais avançadas tecnologias de estudo e monitoramento das culturas e atividades agropecuárias (FORMAGGIO; SANCHES, 2017). O sensoriamento remoto é uma tecnologia que tem potencial no monitoramento da agricultura, pois conforme cita Martins (2016), direcionando-se essa prática como ferramenta de planejamento, controle e análise de dados agrícolas, possibilita-se o monitoramento das variações espaciais e espectrais e dos fatores limitantes da produção, fato que auxilia no processo de tomada de decisão e no manejo otimizado das culturas no campo de produção.

Assim, tais informações podem ser obtidas através da mensuração de aspectos biofísicos de interesse, sendo que essas variáveis são a base para contribuições em diversas áreas da agricultura (FORMAGGIO; SANCHES, 2017). Dentre esses parâmetros, a clorofila é essencial para realização de fotossíntese, absorção de nutrientes e desenvolvimento das plantas. O teor de clorofila está correlacionado com a concentração de nitrogênio na planta, indicando um conteúdo substancial de nutrientes e por consequência acarretando em uma boa produtividade (LEONARDO et al., 2013).

A medição da área foliar também é outro importante indicador. Além de auxiliar em estudos relacionados com morfologia, anatomia e Ecofisiologia vegetal, esse parâmetro dá suporte na determinação do índice de área foliar (IAF), que pode estimar a produtividade de um ecossistema vegetal, seu crescimento e desenvolvimento das folhas (MORAES et al., 2013).

Atualmente, uma série de novos sensores multiespectrais instalados em plataformas espaciais, incluem bandas espectrais específicas e apropriadas para monitorar atividades agrícolas (MARTINS, 2016). Embora os sensores orbitais tenham uma área maior de recobrimento, o uso de sensores multiespectrais acoplados em aeronaves remotamente

pilotadas (ARPs), minimizam o custo das operações se tornando um meio rápido e preciso para avaliar o ciclo de desenvolvimento agrícola (FURLANETTO et al., 2017).

Sabe-se que através das técnicas de sensoriamento remoto é possível captar diferentes padrões espectrais do comportamento da vegetação, possibilitando diversos estudos em determinada região. Com base nessa premissa, utilizando-se de tais técnicas, a hipótese desse estudo baseia-se no seguinte questionamento: é possível estimar de forma eficiente, o teor de clorofila e índice de área foliar da vegetação correlacionando dados obtidos *in situ* com dados de câmeras multiespectrais de baixo custo acopladas em uma ARP?

2 OBJETIVOS

O objetivo geral deste trabalho é avaliar o potencial das imagens multiespectrais embarcadas em ARP's em estimar parâmetros agrônômicos em culturas cafeeiras. Para tanto, são apresentados os seguintes objetivos específicos:

- Avaliar a acurácia de modelos de estimativa do teor de clorofila e área foliar na cultura cafeeira;
- Mapeamento da concentração do teor de clorofila e da área foliar da área de estudo.

3 JUSTIFICATIVA

A agricultura é uma das práticas mais antigas de transformação do espaço geográfico para fins de sobrevivência. Esta técnica possibilitou o desenvolvimento das primeiras civilizações, sendo atualmente uma das atividades econômicas de maior potencial no país. Com o advento do mundo globalizado e competitivo, a redução de custos, aumento de produtividade e a otimização no manejo de culturas se tornaram o principal objetivo dos grandes produtores rurais.

Dentre as produções agrícolas existentes no país, a cafeicultura apresenta-se de forma relevante na balança comercial e cultural dos brasileiros. Dada tal importância, compreender e administrar as variabilidades espaciais existentes em determinada lavoura, pode proporcionar boa influência em relação à produtividade bem como tornar a atividade mais sustentável (MELO, 2015).

Desta forma, o sensoriamento remoto surge como técnica de grande competência no monitoramento de áreas agrícolas. De modo a compreender as variabilidades espaciais situadas em determinada região, gerar modelos de estimativa de produtividade ou estabelecer técnicas

de manejo localizado que melhor se adequem a determinada área, o mapeamento de parâmetros biofísicos da lavoura atua como ferramenta base para execução destes diversos estudos que a agricultura de precisão proporciona (FORMAGGIO; SANCHES, 2017).

Segundo Barros et al. (2007), o mapeamento da cultura cafeeira com base em imagens orbitais de alta resolução espacial, oferta um produto com boa precisão e área de recobrimento considerável. Existe atualmente, uma série de novos sensores multiespectrais instalados em plataformas espaciais que possuem bandas espectrais específicas e adequadas para monitoramento das atividades agrícolas. Sensores como *RapidEye* e *WorldView 3*, possuem canais espectrais que possibilitam a detecção de variações de clorofila nas folhas e fornecem informações sobre estrutura e condição sanitária da vegetação (MARTINS, 2016).

Contudo, a perspectiva do uso de sensores acoplados em ARP's para agricultura assume grande papel nos dias atuais. As ARP's apresentam alta performance e excelente nível de detalhamento, sendo consideradas de baixo custo e fácil manuseio. Assim, essas aeronaves podem ser equipadas com sensores térmicos, câmeras multiespectrais e câmeras RGB que auxiliam na detecção de falhas no plantio, registro de estresses hídricos, controle de pragas e problemas nutricionais (FORMAGGIO; SANCHES, 2017).

Com isso, associando-se essa estratégia de baixo custo com técnicas de amostragem georreferenciada, é possível avaliar o comportamento de determinada cultura em locais específicos, seja para análises físicas, químicas ou biológicas. Tal fato atua como grande contribuinte para a otimização da gestão das lavouras, explorando-se ao máximo as técnicas do manejo localizado (MOLIN; AMARAL; COLAÇO, 2015). As melhorias em tal gestão trazem redução de gastos e desperdícios, aumentam a produtividade e a economia, além de degradar menos o meio ambiente devido à política do uso de métodos não destrutivos para coleta dos dados utilizados neste trabalho.

Portanto, o trabalho propõe avaliar o potencial do vínculo entre aeronaves de baixo custo, sensores remotos de alta resolução e informações obtidas em campo, para fins do mapeamento de parâmetros agronômicos na cultura cafeeira por meio de técnicas de amostragem.

4 FUNDAMENTAÇÃO TEÓRICA

4.1 Parâmetros Agronômicos

Os parâmetros agronômicos são variáveis biofísicas que dizem respeito às propriedades

fisiológicas particulares da vegetação. Dentre tais parâmetros têm-se a biomassa, porcentagem de cobertura vegetal, área foliar e radiação fotossinteticamente ativa absorvida (BATISTA et al., 2013).

Estudar e entender a correlação entre fatores biofísicos da cultura e sua resposta espectral pode contribuir de maneira efetiva no uso das imagens de alta resolução espacial para o cadastro da cultura e também auxiliar os métodos atuais de previsão e monitoramento de safras (RAMIREZ et al., 2010).

O sensoriamento remoto apresenta-se, crescentemente, como uma tecnologia de potencial no monitoramento da agricultura para estimativa de parâmetros biofísicos que são utilizados em múltiplas finalidades. Em geral, as principais variáveis de sensoriamento remoto utilizáveis para a estimativa de parâmetros agronômicos, são índices espectrais de vegetação baseados em bandas localizadas no vermelho e no infravermelho próximo (FORMAGGIO; SANCHES, 2017).

4.1.1 Teor de Clorofila

As clorofilas são pigmentos verdes, comuns em todas as células fotossintéticas, ocorrendo nos cloroplastos das folhas e em outros tecidos vegetais. Estes pigmentos funcionam como agentes de conversão da radiação luminosa em energia, na forma de adenosina trifosfato (ATP) e fosfato de dinucleotídeo de adenina (NADPH), o que proporciona o crescimento e adaptabilidade dos vegetais em situações ambientais variadas (CORRÊA et al., 2018).

O teor de clorofila correlaciona-se diretamente com a concentração de nitrogênio na planta, e também, com a produtividade das culturas, dado que o nitrogênio é um dos principais elementos presente em uma série de compostos indispensáveis ao desenvolvimento da planta, como das moléculas de clorofila, bases nitrogenadas dos nucleotídeos, dos aminoácidos e proteínas, entre outros compostos de metabolismo secundário (TAIZ; ZEIGER, 2008).

Com o advento dos medidores portáteis que utilizam princípios não destrutivos baseados na absorbância e reflectância da luz pelas folhas, a determinação do teor relativo de clorofila (TRC) tornou-se fácil e rápido podendo ser realizado em campo, através de aparelhos denominados clorofilômetros (RICHARDSON et al., 2002). Dentre os aparelhos mais recentes, o ClorofiLOG utiliza fotodiodos emissores em três comprimentos de onda: dois sinais são emitidos e captados dentro da banda do vermelho, próximos aos picos de cada tipo de clorofila ($\lambda = 635$ e 660nm) e um outro no infravermelho próximo ($\lambda = 880\text{nm}$). Deste modo, um sensor inferior recebe a radiação transmitida através da estrutura foliar e a partir desses dados, o

aparelho fornece valores chamados de índice de clorofila falker (ICF) proporcionais à absorvância das clorofilas (FALKER, 2008).

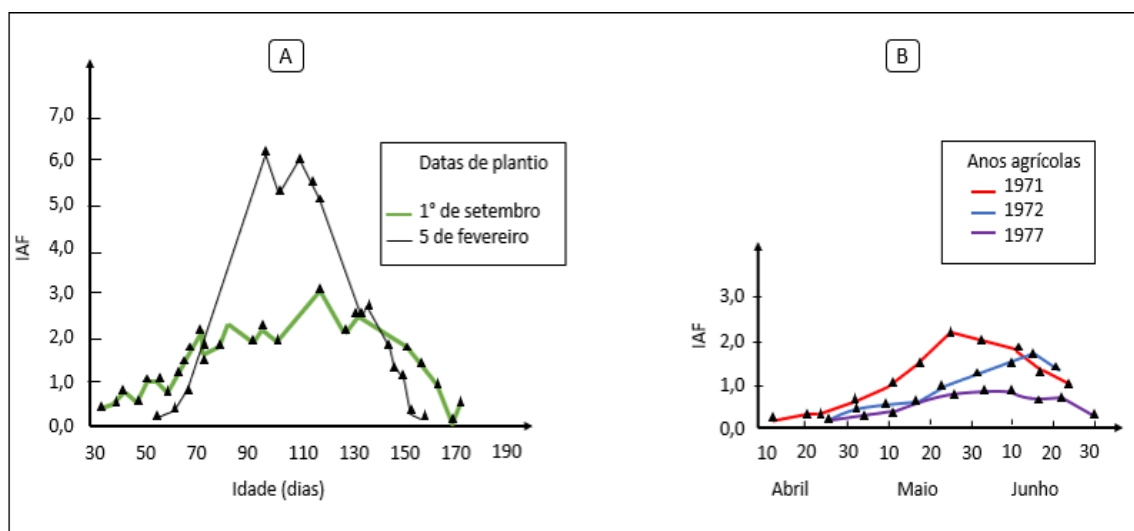
Para a medição do teor de clorofila, as folhas das plantas são posicionadas entre o emissor e receptor do equipamento, de modo que a radiação transmitida através da folha seja convertida em sinais eletrônicos (BOECHAT, 2012).

4.1.2 Área Foliar

A importância da área foliar (AF) de uma cultura, é amplamente conhecida por ser um parâmetro indicativo de produtividade, pois o processo fotossintético depende da interceptação da energia luminosa e a sua conversão em energia química (FAVARIN et al., 2002).

Segundo Formaggio e Sanches (2017), o comportamento do índice de área foliar durante o ciclo de uma cultura anual pode ser considerado de tendência parabólica (Figura 1), com valores iniciais baixos, posteriormente atingindo um pico e por fim, entrando em queda novamente.

Figura 1 – Perfis temporais do índice de área foliar para a cultura do trigo em: (A) duas datas distintas de plantio; (B) três diferentes anos agrícolas



Fonte: Adaptado de Formaggio e Sanches (2017).

Fatores como datas de plantio, densidades, espaçamentos, transpiração, pragas, precipitação pluviométrica (ou irrigação artificial), interferem de forma significativa no desenvolvimento das culturas, e essa influência geralmente é bem evidenciada pela AF. Assim sendo, este parâmetro tem sido uma das variáveis agrônômicas de maior interesse, além de ser um dos indicadores de dosséis mais utilizados em trabalhos relacionados com sensoriamento

remoto multiespectral de culturas agrícolas (FORMAGGIO; SANCHES, 2017).

A determinação de área foliar pode ser realizada por métodos diretos ou indiretos, destrutivos ou não destrutivos. Os métodos diretos são aqueles que realizam medições diretas nas folhas. Os métodos indiretos baseiam-se na correlação conhecida entre a variável medida e área foliar. Os métodos destrutivos exigem a remoção da folha ou demais estruturas, o que muitas vezes não é viável devido à limitação do número de plantas na parcela experimental. Já nos métodos não destrutivos, as medidas são tomadas na planta, sem necessidade de remoção de estruturas, preservando sua integridade (ADAMI et al., 2008).

Sabe-se que existem vários métodos de obtenção da AF e que estes possuem prós e contras. Com o avanço tecnológico, vários métodos tradicionais de medição e equipamentos têm sido substituídos por métodos computacionais usando a análise de imagens digitais que são associadas com medições diretas ou indiretas, de preferência não destrutivas (MARTINS, 2016). Nesta perspectiva, duas principais formas de se obter a AF vêm sendo utilizadas na atualidade. A primeira, conforme Boechat (2012), por meio de sensor *scanner* passivo, que tem como principal característica uma maior rapidez na obtenção das informações. Em segundo lugar tem-se a mensuração direta de dimensões foliares e área do dossel. Embora seja um procedimento lento, assegura maior precisão nas informações, fato que o torna um bom método para estimativa dessa variável (ADAMI et al., 2008).

De modo geral, a relação de valores de reflectância da vegetação e valores correspondentes de área foliar é um parâmetro de suma importância para diversos estudos e aplicações no sensoriamento remoto em agricultura (FORMAGGIO; SANCHES, 2017).


4.2 Sensoriamento Remoto da vegetação

De acordo com Formaggio e Sanchez (2017), o sensoriamento remoto para uso em agricultura vem sendo estudado desde a década de 1970, onde o país pioneiro foram os Estados Unidos a partir do lançamento do primeiro satélite da série *Landsat*. De modo amplo, pode-se definir Sensoriamento Remoto (SR) como sendo a utilização conjunta de sensores, equipamentos para processamento e transmissão de dados colocados a bordo de aeronaves, espaçonaves, entre outras plataformas, que objetivam estudar eventos, fenômenos e processos que ocorrem na superfície terrestre a partir do registro e análise das interações entre a radiação eletromagnética (REM) e as substâncias que a compõem em suas mais diversas manifestações (NOVO, 2010).

A energia registrada por sistemas de SR passa por interações fundamentais que devem

ser entendidas para interpretação adequada dos dados remotamente detectados. Para tanto, faz-se necessário entender os princípios da radiação eletromagnética (JENSEN, 2009). De acordo com Novo (2010), a REM é o meio pelo qual a informação é transferida do objeto ao sensor. A autora também define REM como uma forma dinâmica de energia que se manifesta a partir de sua interação com a matéria. Sabe-se que existem diferentes regiões do espectro eletromagnético (Figura 2) e que toda matéria reflete, absorve, transmite ou emite REM de forma específica, conforme suas próprias características (FORMAGGIO; SANCHES, 2017).

Figura 2 – Principais regiões do espectro eletromagnético



Fonte: Adaptado de Ferraro, Torres e Penteado (2012).


A REM transporta energia radiante e a mesma possui capacidade de alterar o estado da matéria com a qual interage. Essa energia, por exemplo, pode provocar mudanças na temperatura de um sensor e tais mudanças variam de acordo com a intensidade de energia transportada pela REM (NOVO, 2010). Com isso, a variação da quantidade de energia que incide sobre determinada superfície em um dado intervalo de tempo é denominada de fluxo radiante (JENSEN, 2009). No momento em que o fluxo radiante entra em contato com uma superfície, dado que a mesma possui determinada quantidade de área, a densidade de fluxo radiante que incide sobre essa superfície é denominada Irradiância (NOVO, 2010).

Conforme citam Ponzoni et al. (2012), a intensidade média do fluxo radiante que deixa a superfície por unidade de área, é denominada excitância. Quando se acrescenta a direção medida dessa energia, este parâmetro é denominado radiância. Outra variável de grande

interesse para o sensoriamento remoto agrícola é a reflectância da energia solar, definida como a capacidade de determinado objeto de refletir a REM que incide sobre ele, representada pela razão entre o fluxo de radiação que incide numa superfície e o fluxo de radiação que é refletido por ela (FORMAGGIO; SANCHES, 2017).

As frações espectrais da radiação incidente que são refletidas, transmitidas e absorvidas dependem das propriedades físico-químicas que são únicas de cada objeto e é essencial que se tenha um adequado entendimento sobre como atuam fatores que interferem nas respostas espectrais dos objetos sensorizados. Para tal, é interessante entender que a resposta espectral emitida pela vegetação (Figura 3), possui comportamentos que variam nas diferentes bandas do espectro eletromagnético (JENSEN, 2009). De todos os comprimentos do espectro eletromagnético, as regiões do visível e do infravermelho são as mais utilizadas para aplicações no meio agrícola (MOLIN; AMARAL; COLAÇO, 2015).

Figura 3 – Características da reflectância espectral de vegetação verde e saudável para o intervalo de comprimento de onda (0.4 – 2,6 μm)



Fonte: Adaptado de Jensen (2009).

O sensoriamento remoto multiespectral se mostrou eficaz e vem sendo utilizado de forma significativa para agricultura de precisão na área de monitoramento de culturas (FORMAGGIO; SANCHES, 2017). Assad et al. (2002) realizaram uma pesquisa para identificação de impurezas e misturas no pó de café através da análise do comportamento espectral de imagens digitais multiespectrais. Os resultados mostraram diferentes curvas de comportamento espectral indicando vários componentes que tornaram algumas amostras do pó

de café impuras ou adulteradas.

Boechat (2012) utilizou imagens multiespectrais e técnicas de SR para detecção de doenças fúngicas do feijoeiro. Com auxílio dessas imagens de alta resolução espectral, foi possível realizar a detecção das doenças em diferentes níveis de severidade trazendo resultados satisfatórios na agricultura de precisão. Em sua tese, Martins (2016) mostra a possibilidade e eficiência do monitoramento da cultura cafeeira infectada por nematoides e a identificação de diferentes estágios de infecção por meio de informações tomadas por imagens multiespectrais.

Em um estudo, Ramirez et al. (2010) estimaram parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução. Os resultados apresentaram-se satisfatórios, dado que o erro relativo médio foi de apenas 7,6% para as estimativas. O autor concluiu, portanto, que o uso de imagens de alta resolução no estudo de áreas cafeeiras mostra-se bastante promissor, uma vez que permite detectar características biofísicas relevantes para o acompanhamento e monitoramento daquela cultura.

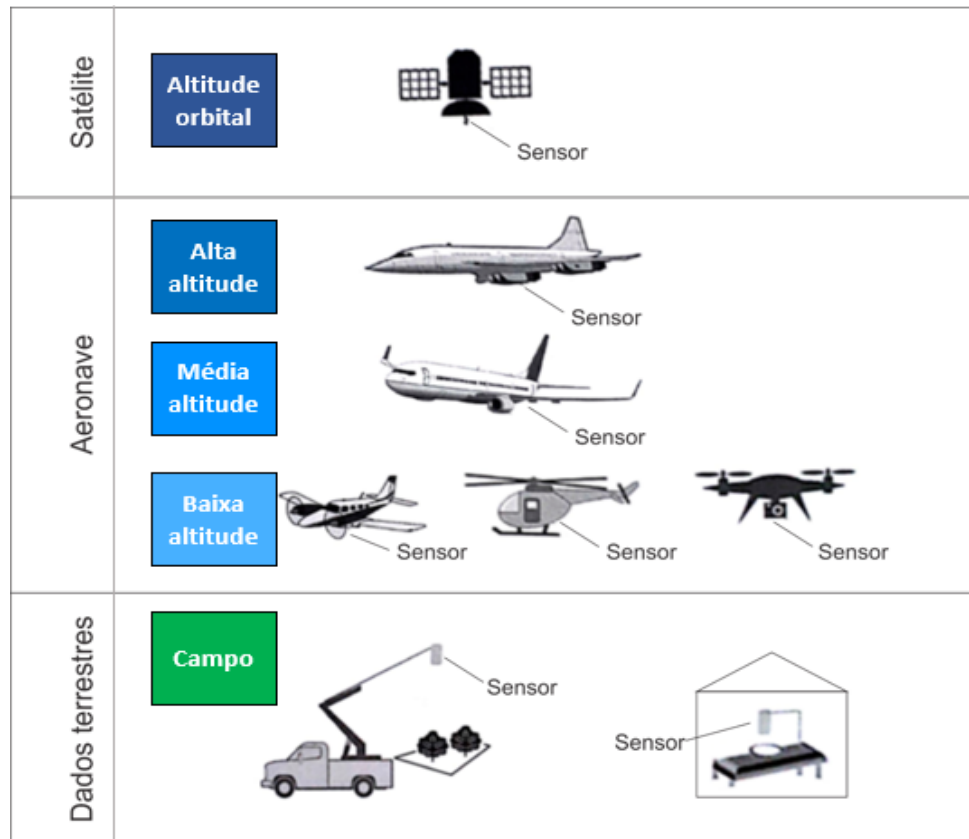
4.2.1 Sensores

Os sensores remotos são dispositivos capazes de detectar, em determinadas faixas do espectro eletromagnético, a energia eletromagnética proveniente de um objeto, transformá-la em um sinal elétrico e registrá-la, de modo que esse dado possa ser armazenado e transmitido, para posteriormente ser convertido em informações que descrevam as feições dos objetos presentes na superfície terrestre (MORAES, 2015).

Os sensores possuem algumas classificações, por exemplo, quanto à fonte de energia. Sensores passivos são aqueles que dependem de uma fonte de radiação externa para que possam gerar informação sobre os alvos de interesse. Já os sensores ativos, produzem sua própria radiação. Também são classificados em imageadores, ou seja, produzem uma imagem bidimensional da REM fornecendo como resultado final uma imagem da superfície observada. Os não-imageadores medem a intensidade de energia de um objeto, mas não necessariamente produzem uma imagem (NOVO, 2010).

Quando se fala em sistemas sensores, conforme citam Formaggio e Sanches (2017), existem diferentes níveis de coleta de informações de objetos sensoriados. Esses níveis são associados em função da distância entre o sensor e os objetos estudados conforme mostra a Figura 4.

Figura 4 – Níveis de aquisição de dados em sensoriamento remoto



Fonte: Formaggio e Sanches (2017).

4.2.2 Resolução das Imagens

Quando se trabalha com imagens de origem orbital ou aérea, é necessário certificar se a qualidade desses produtos satisfaz as demandas requeridas em determinado mapeamento. Para tanto, uma das soluções é ter conhecimento sobre o que é resolução espectral, radiométrica, espacial e temporal. Tratando-se de produtos obtidos por essas plataformas, conhecer tais informações é vital (MOLIN; AMARAL; COLAÇO, 2015).

A resolução espacial pode ser definida pelo tamanho do menor objeto no terreno que poderá ser identificado em determinada imagem (FORMAGGIO; SANCHES, 2017). Em sensores ópticos, a resolução espacial depende do *Instantaneous Field of View* (IFOV), que se refere ao campo de visada instantâneo. O mesmo pode ser definido como o ângulo de visibilidade do sensor que determina a área da superfície terrestre vista por ele. O tamanho da área é determinado pelo IFOV e pela distância do sensor à superfície imageada. Em suma, as imagens que permitem visualização de objetos ou feições de terreno grandes, possuem resolução espacial baixa. Já as imagens de alta resolução permitem detectar objetos com

dimensões pequenas (NOVO, 2010).

A variável resolução radiométrica trata da intensidade de radiação mínima que o sensor pode diferenciar (MOLIN; AMARAL; COLAÇO, 2015). Novo (2010, p.85) cita que “A resolução radiométrica de um sensor descreve sua habilidade de distinguir variações no nível de energia refletida, emitida ou retroespalhada que deixa a superfície de um alvo”. A autora também conclui que quanto maior a capacidade do sensor de discernir variações de intensidade do sinal, maior sua resolução. Já a resolução espectral refere-se ao número de bandas espectrais que o sensor comporta. Quanto maior o número de bandas, maior será a resolução espectral e vice-versa (FORMAGGIO; SANCHES, 2017). Por fim, a resolução temporal diz respeito ao tempo de revisita do sensor em uma mesma região. Essa resolução se aplica em plataformas orbitais pelo fato de ser dependente da frequência em que determinado satélite passa sobre a mesma região. Quanto maior o tempo de revisita, menor a resolução temporal e vice-versa (MOLIN; AMARAL; COLAÇO, 2015).

4.3 Processamento Digital de Imagens

Uma grande vantagem das imagens digitais em relação às imagens analógicas é a possibilidade do processamento digital, processo que visa manipular a imagem de modo a melhorar o realce ou extrair informações específicas (NOVO, 2010). O processamento digital de imagens (PDI) é multidisciplinar, envolvendo diversos aspectos e conceitos de ótica, eletrônica, matemática, fotografia e computação (JENSEN, 2009).

O procedimento inicial que envolve manipulação de imagens é conhecido como pré-processamento. Este engloba processos como a filtragem de ruídos e distorções causadas pelo sensor, fazendo parte de um conjunto de métodos que permitem a correção dos erros inerentes ao processo de aquisição de dados (NOVO, 2010). Em seguida, tem-se a fase de realce visual e classificação que possui o objetivo de reconhecer, verificar ou inferir a identidade dos objetos a partir das características e representações obtidas pelas etapas anteriores do processamento (QUEIROZ; GOMES, 2001).

A atmosfera pode afetar a imagem adicionando uma radiância extra em certa região ou atenuando a intensidade de energia que ilumina o alvo na superfície. Para uma interpretação confiável das imagens, é necessário remover os efeitos que a atmosfera introduz (MENEZES; ALMEIDA, 2012). Podem ocasionar nas imagens *pixels* aleatórios com valores saturados (claros) ou sem sinal (escuros). Estas informações incoerentes são chamadas de ruídos e podem ser corrigidos através das opções de algoritmos que os *softwares* de processamento de imagem

oferecem.

As distorções geométricas em imagens de SR são introduzidas no momento de aquisição das imagens devido ao movimento de rotação, inclinação e curvatura da Terra, variações na posição da plataforma de aquisição (velocidade, altura, direção), efeitos panorâmicos, entre outros (NOVO, 2010). Como estas distorções dependem de uma série de parâmetros de exatidão do posicionamento da plataforma, do qual um usuário não tem acesso, a correção fica a cargo dos próprios laboratórios de produção das imagens (MENEZES; ALMEIDA, 2012).

O realce de contraste busca o melhoramento na qualidade das imagens sob o ponto de vista subjetivo do olho humano. A manipulação do contraste dos objetos presentes em uma imagem digital possibilita um aumento de discriminação visual entre eles (QUEIROZ; GOMES, 2001). Ainda tratando-se de realce de imagens, a modificação de fatores como intensidade (brilho), matiz (cor) e a saturação (quantidade de cor presente), também são relevantes para melhor visualização e interpretação da imagem (NOVO, 2010).

A classificação digital de imagens automatiza o processo de extração de informações das imagens, eliminando a subjetividade da interpretação humana. O resultado desta classificação é dado por uma imagem de *pixels* classificado, representando em polígonos os padrões homogêneos das classes alvo, denominado mapa digital temático (MENEZES; ALMEIDA, 2012). A classificação pode ser supervisionada, definida como aquela em que o usuário fornece as amostras pertencentes às classes de interesse e o algoritmo localiza e agrupa os *pixels* com base em modelo estatístico pré-estabelecido (NOVO, 2010). A classificação não-supervisionada requer pouca ou nenhuma participação do analista durante o processo de classificação. Nesta, o usuário utiliza algoritmos para reconhecer as classes presentes na imagem (PONZONI; SHIMABUKURO; KUPLICH, 2015).

Em suma, o uso das técnicas de PDI que serão aplicadas depende dos objetivos da pesquisa e métodos que mais facilitem o trabalho que o analista propôs fazer (MENEZES; ALMEIDA, 2012).

4.3.1 Índice de Vegetação

Desde a década de 1960, os cientistas extraíram e modelaram diversas variáveis biofísicas da vegetação usando dados de sensoriamento remoto (JENSEN, 2009). Grande parte do trabalho foi direcionada para o desenvolvimento de índices de vegetação (IVs), que conforme explicam Formaggio e Sanches (2017), podem ser definidos como formulações matemáticas desenvolvidas a partir de dados espectrais obtidos via sensores remotos, em sua

maioria nas regiões do vermelho (R) e infravermelho próximo (IVP), com o objetivo de permitir a realização de avaliações e estimativas da cobertura vegetal e de parâmetros biofísicos tais como área foliar, fitomassa, atividade fotossintética e porcentagem de cobertura do solo. Os autores ressaltam que tais informações são essenciais para se conhecer a dinâmica temporal e as variabilidades espaciais de determinada lavoura.

De acordo com Jensen (2009), existem mais de vinte índices de vegetação em uso, sendo que muitos deles possuem informações equivalentes enquanto outros oferecem propriedades biofísicas únicas. Dentre os índices mais utilizados destaca-se o NDVI (*normalized difference vegetation index*) que do inglês significa índice de vegetação da diferença normalizada (FORMAGGIO; SANCHES, 2017). Proposto por Rouse et al. (1973), este índice utiliza imagens dos canais espectrais do R e IVP para ser calculado (Equação 1).

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

Onde:

- IVP = reflectância no infravermelho próximo;
- R = reflectância no vermelho.

O NDVI é bastante utilizado em razão da sua alta resposta a variações de vigor da vegetação. Para a vegetação, a maior absorção de energia ocorre na região do vermelho, apresentando baixos valores de reflectância e indicando alta atividade fotossintética. Já os comprimentos de onda do IVP são refletidos quando as folhas estão saudáveis. Logo, através da relação entre essas duas bandas, foi possível obter uma variação conhecida e comparável, isto é, normalizada, dando origem ao índice. Assim sendo, o NDVI teoricamente pode variar entre -1 e 1, onde valores mais próximos a 1 indicam alto vigor vegetativo, e valores mais próximos a -1 indicam vigor vegetativo baixo ou nulo (MENEZES; ALMEIDA, 2012).

Outro importante índice para trabalhos em agricultura trata-se do TGI (*Triangular Greenness Index*) ou índice de verde triangular. Criado por Hunt Jr et al. (2011), este IV estima a concentração de clorofila nas folhas com base na área de um triângulo, onde sinais de reflectância na região do vermelho, verde e azul delimitam seus vértices. McKinnon e Hoff (2017) realizaram estudos com o sensor CMOS (*Complementary Metal Oxide Semiconductor*), sendo este o mais comum encontrado nas câmeras digitais da atualidade. Através do estudo de comprimentos de onda típicos desse sensor, normalizado pelo sinal verde, o cálculo do TGI é

expresso conforme mostra a Equação 2.

$$TGI = G - 0.39 * R - 0.61 * B \quad (2)$$

Onde:


- G corresponde a reflectância medida no canal espectral do verde;
- R corresponde a reflectância medida no canal espectral do vermelho;
- B corresponde a reflectância medida no canal espectral do azul.

4.4 Planejamento de Voo

O planejamento de voo entra como etapa inicial para execução de um mapeamento aéreo bem-sucedido. As condições atmosféricas, período e horário (condições naturais), em conjunto com o modelo de aeronave e sensor (condições específicas), são variáveis de forte influência nos resultados provindos de um aerolevanteamento (JENSEN, 2009).

De acordo com Tommaselli (2009), o mapeamento via fotografias aéreas deve seguir certos requisitos que asseguram confiabilidade nas informações. O veículo aéreo utilizado deve seguir uma faixa de voo de modo que as faixas vizinhas tenham uma região que se sobreponham entre 25% a 30% de cobertura, denominada sobreposição lateral. Faz-se necessário também um recobrimento entre as fotos sucessivas, que assume em média o valor de 60% da região entre fotos. Este é chamado de sobreposição longitudinal e objetiva permitir a produção de estéreo par para análise e medição estereoscópica, a construção de mosaicos a partir da porção central de cada fotografia onde as distorções são menores, e a criação de pontos de apoio por métodos fotogramétricos, ou seja, por fototriangulação. Na Figura 5, podem-se observar as sobreposições laterais e longitudinais mínimas entre fotografias em um aerolevanteamento.

Figura 5 – Sobreposições do plano de voo



Fonte: Adaptado de Tommaselli (2009).

Para execução de um plano de voo com boa qualidade, o operador pode considerar também variáveis como dimensões da área a ser fotografada, fato que torna possível a determinação da altitude de voo ideal, quantidade de linhas de voo, quantidade de fotos e o intervalo de tempo aproximado que será gasto para execução do aerolevanteamento (GONÇALVES, 2010).

4.5 Análises estatísticas: Correlação e Regressão

O estudo do comportamento conjunto de uma ou mais variáveis vem sendo praticado ao longo de muitos anos. Tal fato faz-se necessário devido a necessidade de explicar, por exemplo, se duas variáveis estão relacionadas a um determinado problema ou fenômeno no qual ambas de alguma forma contribuem para a ocorrência dos mesmos.

Para tanto, a análise de correlação e a análise de regressão são métodos estatísticos amplamente utilizados para estudar o grau de relacionamento entre variáveis (LIRA, 2004). A correlação fornece um número que indica como duas variáveis variam conjuntamente. Trata-se de um indicador que atende à necessidade de se estabelecer a existência ou não de uma relação entre essas variáveis determinando, por exemplo, como uma se comporta em um cenário onde a outra está variando visando detectar a existência de alguma relação entre tal variabilidade (BUSSAB; MORETTIN, 2010). Já a regressão, conforme descreve Lira (2004), consiste na realização de uma análise estatística com o objetivo de verificar a existência de uma relação funcional entre uma variável dependente com uma ou mais variáveis independentes. Em outras palavras, esta análise gera uma equação que tenta explicar o comportamento dessas variáveis.

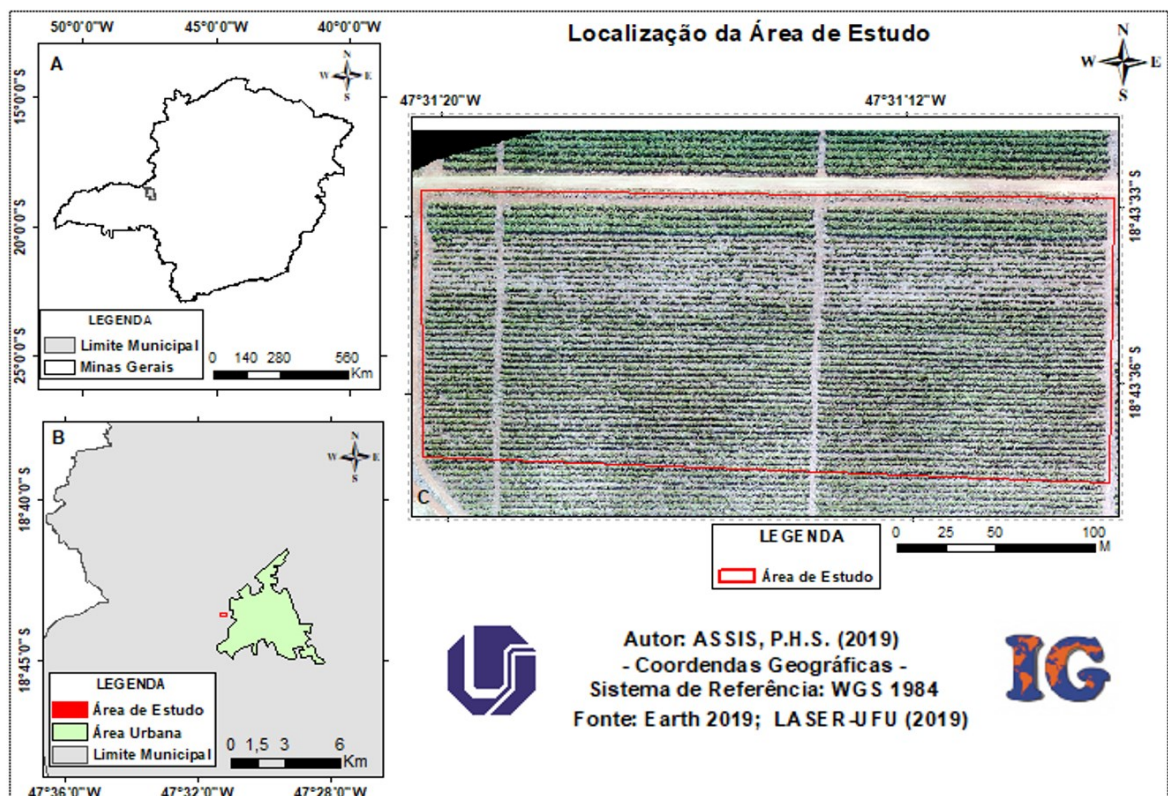
Para tentar estabelecer uma equação que representa o fenômeno em estudo, pode-se fazer um gráfico denominado diagrama de dispersão. Este é utilizado para verificar como se comportam os valores da variável dependente (Y) em função da variável independente (X). O comportamento de Y em relação a X pode se apresentar de diversas maneiras: linear, quadrático, cúbico, exponencial, logarítmico, entre outros. Para se estabelecer o modelo que melhor explica o fenômeno, deve-se analisar qual tipo de curva melhor se ajusta aos dados observados (BUSSAB; MORETTIN, 2010).

5 MATERIAL E MÉTODOS

5.1 Área de Estudo

A área onde ocorreu o estudo (Figura 6), encontra-se próxima à área urbana do município de Monte Carmelo-MG, nas coordenadas geográficas a latitude de $18^{\circ}43'35'' S$ e longitude $47^{\circ}31'14'' W$, com extensão aproximada de 9 hectares. O município está situado na Mesorregião do Triângulo Mineiro e Alto Paranaíba.

Figura 6 – Localização da Área de Estudo. (A) Minas Gerais. (B) Limite municipal e área urbana de Monte Carmelo. (C) Área de Estudo




5.2 Material

O trabalho foi realizado por estágios diferentes. O primeiro momento foi voltado à obtenção de dados de campo. Em uma segunda etapa, os dados obtidos passaram por análises estatísticas para dar origem ao produto final. Para execução do primeiro estágio foram utilizados os seguintes materiais:

- Drone Phantom 4 *Advanced*, com autonomia média de voo de 30 minutos, peso de 1368 gramas, equipado com câmera RGB de 20 megapixels e GPS integrado (Figura 7A);
- Sensor Mapir *Survey 3*, com peso de 60 gramas, GPS integrado e operando nos canais do vermelho, verde e infravermelho próximo do espectro eletromagnético (Figura 7B);


Figura 7 – Drone Phantom 4 *Advanced* e sensor Mapir. (A) Drone Phantom.
(B) Sensor Mapir com suporte de acoplamento



Fonte: O autor.

- Alvos de calibração radiométrica *Mapir Target* (Figura 8 A);
- Alvos foto-identificáveis de cartolina branca para demarcar pontos de apoio (Figura 8 B);

Figura 8 – Alvos para calibração e demarcação de pontos de apoio. (A) Alvos *Mapir Target*. (B) Alvos foto-identificáveis para os pontos de apoio



Fonte: O autor.

- Receptor GNSS *Topcon Hiper V*, com memória interna e removível via *SD card* de 8GB, utilizado para o georreferenciamento das amostras e alvos (Figura 9);

Figura 9 – Receptor GNSS *Topcon Hiper V*



Fonte: O autor.

- ClorofiLOG Falker, medidor eletrônico de teor de clorofila (Figura 10).

Figura 10 – Medidor de teor de clorofila ClorofiLOG Falcker



Fonte: O autor.

- Régua milimétrica Acrimet com extensão de 30 cm para medida de dimensões foliares.

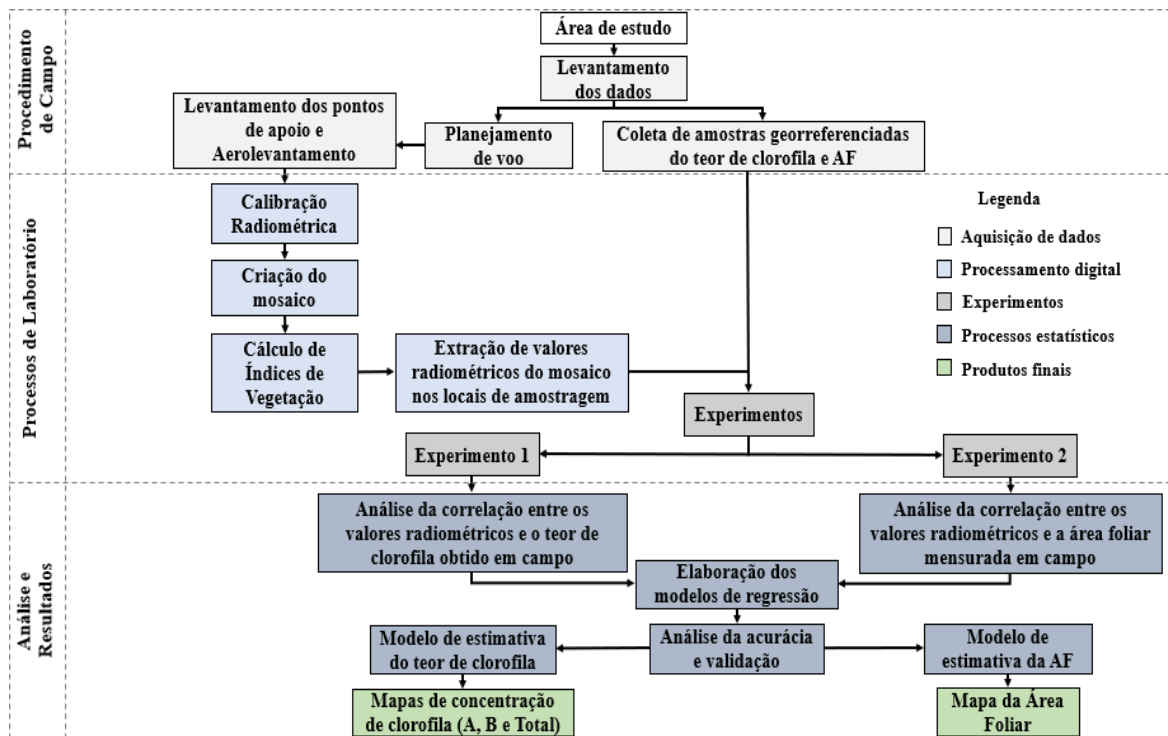
Em seguida, para realização do segundo estágio, foram necessários os seguintes *hardwares* e *softwares* de processamento:

- Notebook Dell Inspiron, Intel Core i7, 8GB RAM e sistema operacional de 64 bits para processos computacionais;
- *Smartphone* Samsung modelo Galaxy A8 para armazenamento e execução do plano de voo;
- *Software DroneDeploy* para elaboração do plano de voo;
- *Software Mapir Camera Control* para calibração radiométrica das imagens;
- *Software Pix4Dmapper* para processamentos fotogramétricos;
- *Software ENVI 5.1* para processamento digital de imagens e avaliação da acurácia do mapeamento;
- *Software Excel* para tabulação dos dados obtidos em campo;
- *Software MiniTab 18* para criação dos modelos de estimativa do teor de clorofila e área foliar e análise da acurácia através do erro médio quadrático (RMSE);
- *Software ArcGIS* para confecção dos mapas temáticos.

5.3 Métodos

Os procedimentos executados neste trabalho são descritos pela Figura 11. Desse modo, a divisão metodológica representada pelo fluxograma é dada por: procedimento de campo, processos de laboratório e análise e resultados. A primeira etapa teve por objetivo o planejamento e aquisição dos dados que foram utilizados para o estudo, onde foi feita a coleta de amostras georreferenciadas do teor de clorofila e dimensões foliares, levantamento dos pontos de controle com receptor GNSS e o aerolevanteamento da área de estudo em questão. Na segunda etapa, os dados passaram por processamento digital para calibração radiométrica das imagens, criação do mosaico, cálculo de IV's e extração de valores radiométricos nos locais de amostragem. Por fim, foram realizados dois estudos. O primeiro consistiu em analisar a correlação entre os valores radiométricos extraídos e o teor de clorofila obtido em campo, com intuito de estimar a concentração do teor de clorofila sob a área de estudo. O segundo, consistiu em analisar a correlação entre os valores radiométricos e a área foliar calculada em campo, com intuito de estimar a variação da AF na área de estudo.

Figura 11 – Fluxograma dos procedimentos metodológicos




Fonte: O autor.

5.3.1 Obtenção de amostras georreferenciadas do teor de clorofila e AF

A aquisição dos valores do teor de clorofila e área foliar foi tomada a partir de 75 pontos amostrais aleatórios pertencentes à área de estudo. Para tanto, os valores dos parâmetros mensurados em cada ponto de coleta foram tabulados no *software* Excel. As medidas obtidas em campo foram simultaneamente georreferenciadas via receptor GNSS no modo RTK (*Real Time Kinematic*).

Os valores do teor de clorofila foram obtidos com um medidor eletrônico do modelo ClorofiLOG *Falker*. Este equipamento é baseado nos princípios de absorção e reflectância das folhas, captando essa radiação através do receptor e convertendo em sinais eletrônicos que determinam o estado nutricional da folha. As medidas do teor de clorofila foram extraídas nas regiões do terço médio e terço superior de cada planta (Figura 12). Com isso, foi decidida à execução de quatro leituras por planta com a finalidade de se obter um valor médio do teor de clorofila para cada planta através do cálculo da média aritmética.

Figura 12 – Representação do método de aquisição dos valores de clorofila



Fonte: O autor.

Os princípios de aquisição das dimensões foliares para o estudo foi equivalente aos do teor de clorofila, ou seja, as leituras também foram realizadas no terço médio e superior de cada

planta. As variáveis obtidas foram o maior comprimento e a largura do meio de cada folha, em centímetros, tomadas por uma régua milimétrica de acrílico. O cálculo da AF foi empregado seguindo a Equação 3, proposta por Barros et al. (1973):


$$AF = 0,667 * C * L \quad (3)$$

Onde:

- C = comprimento da folha (cm);
- L = largura do meio da folha (cm);
- 0,667 = fator de correção de área.

A equação proposta pelo autor se baseia nas dimensões da área de um retângulo imaginário circunscrito em torno da folha de café conforme mostra a Figura 13.

Figura 13 – Representação do cálculo da área foliar proposta por Barros et al. (1973)



Fonte: Adaptado de Silva et al. 2011.

5.3.2 Planejamento e execução do voo

A execução dos voos ocorreu no dia 20 de agosto de 2019 às 11:30. Para tal realização, foi utilizada uma ARP fornecida pelo Laboratório de Sensoriamento Remoto e Fotogrametria da Universidade Federal de Uberlândia (LASER-UFU). Optou-se pela realização de dois voos distintos, um à 70 e o outro à 120 metros de altitude para analisar a influência dessa variável nos resultados estatísticos dos modelos. Para definição dos parâmetros do plano de voo, foi utilizado o *software DroneDeploy*, ferramenta que apresenta detalhadamente as informações sobre o levantamento (Tabela 1).

Tabela 1 - Parâmetros para o aerolevanteamento. (A) Parâmetros do primeiro voo. (B) Parâmetros do segundo voo

A		B	
Elementos	Valores	Elementos	Valores
GSD	2 cm	GSD	3,6 cm
Altura de voo	70 m	Altura de voo	120 m
Área imageada	9 ha	Área imageada	9 ha
Número de faixas	5	Número de faixas	4
Número de fotos	119	Número de fotos	45
Tempo total do voo	7 min e 26 seg	Tempo total do voo	5 min e 10 seg
Baterias	1	Baterias	1
Sobreposição longitudinal	75%	Sobreposição longitudinal	75%
Sobreposição lateral	65%	Sobreposição lateral	65%

Fonte: O autor.

Além dos parâmetros apresentados pelo *software*, deve-se considerar que a escolha do dia do aerolevanteamento dependeu diretamente das condições favoráveis do ambiente, isto é, condições climáticas tais como dia ensolarado, sem nuvens e com baixa velocidade do vento.

Após concluído o planejamento de voo, foi feito o levantamento e demarcação dos pontos de controle na área a ser imageada. Esses pontos possibilitaram que o mosaico gerado pelas imagens fosse georreferenciado, fato que aumentou o nível de precisão das informações.

Para o rastreamento dos pontos de controle foi utilizado o receptor GNSS Topcon *Hiper V* disponibilizado pelo Laboratório de Topografia e Geodésia (LTGEO) da universidade. Para realização desse levantamento, alguns parâmetros foram definidos conforme mostra a Tabela 2.

Tabela 2 – Parâmetros estipulados para levantamento dos pontos de apoio

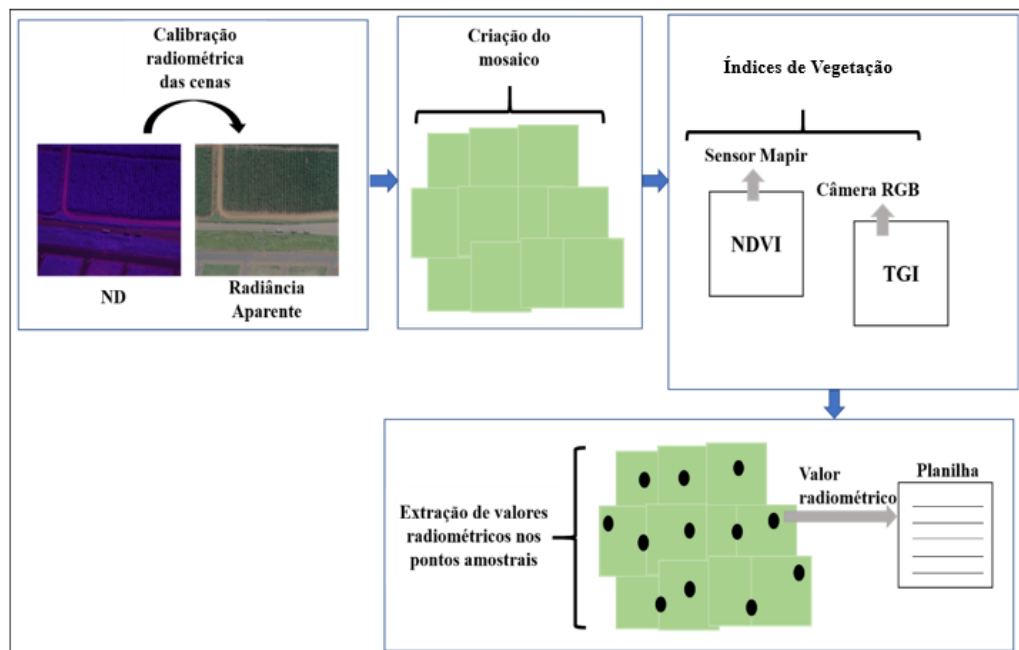
Elementos	Valores utilizados
Posicionamento	Relativo Estático Rápido
Máscara de elevação	10°
Tempo de rastreamento	10 min / ponto
Quantidade de pontos	10

Fonte: O autor.

5.3.3 Processamento Digital de Imagens

Após realizado todo processo de levantamento dos dados, as imagens obtidas em campo passaram pela etapa de pré-processamento digital. Os processos realizados nesta etapa podem ser observados conforme mostra a Figura 14.

Figura 14 – Esquematisação da etapa de pré-processamento



Fonte: O autor.

A princípio, foram utilizados o *software Mapir Camera Control* e o alvo de calibração do sensor *Mapir Survey 3* (Figura 8A) para a calibração radiométrica das imagens. Desse modo, foi necessário o uso de uma cena em que o alvo fosse identificável para que o *software* reconhecesse os diferentes padrões espectrais da imagem, isto é, as cores verdadeiras (RGB), o

preto e o branco. Assim, o *software* gerou um modelo de calibração e o aplicou em todas as cenas. Com isso, as imagens que antes eram representadas por *pixels* de número digital (ND), são transformadas em imagens com *pixels* contendo a radiância aparente possibilitando a caracterização espectral de objetos.

Em seguida, as imagens foram inseridas no *software Pix4Dmapper* que processou e uniu as feições comuns de cada cena, dando origem aos mosaicos da área de estudo, ou seja, um mosaico referente às cenas da câmera do drone e o outro referente às cenas do sensor *Mapir Survey 3*. Ambos foram exportados para o *software* ENVI onde foram calculados os índices de vegetação NDVI e TGI através da ferramenta *BandMath*. Estes, por apresentarem alta relação com o vigor da vegetação de determinada área, serviram de base para aplicação dos modelos de estimativa do teor de clorofila e área foliar que foram calculados.

Para concluir esta etapa, foi extraído valores radiométricos do mosaico referente aos pontos de amostragem. Neste processo, foi utilizado dois métodos de extração a fim de se comparar a influência dos mesmos em relação aos resultados estatísticos dos modelos. O primeiro método consistiu em extrair as informações através da ferramenta *ROI tool* do *software* ENVI. Para tanto, foi criada uma *shapefile* que continha polígonos vetorizados sobre as amostras georreferenciadas. Esses polígonos são chamados de ROI's (*Region of Interesting*) e contém os valores radiométricos dos *pixels* que estão dentro da região de interesse, isto é, na área de recobrimento de cada polígono. Com isso, o *software* calcula e apresenta a média desses valores para cada polígono através da ferramenta *ROI Statistics*.

O segundo método fundamentou-se na utilização dos mesmos recursos do *software* ENVI, contudo, a *shapefile* de polígonos foi transformada para pontos onde nessa situação era extraído apenas o valor de um único *pixel* por ponto amostral não havendo a necessidade de ser calcular uma média. A Figura 15 apresenta a amostragem dos dados na área de estudo e a vetorização dos ROI's.

Figura 15 – Amostragem dos dados e vetorização dos ROI's na área de estudo



Fonte: O autor.

5.3.4 Experimento 1

O objetivo do primeiro experimento foi à elaboração de modelos estimadores da clorofila através da análise da regressão entre as amostras do teor de clorofila obtidas *in situ* com os valores de radiometria das bandas espectrais e índices de vegetação derivados do sensor *Mapir Survey 3* e da câmera do drone. Para tanto, foi feita a análise da correlação entre as amostras georreferenciadas do teor de clorofila e os valores radiométricos medidos nos mosaicos tanto para o voo à 70 metros quanto o de 120 metros de altura. Deste modo, para a composição dos modelos de estimativa, foi possível filtrar quais bandas teriam melhor resposta com o parâmetro a ser estimado, ou seja, bandas e índices que apresentassem maior correlação com a clorofila. Com intuito de se obter uma correlação significativa, foi considerado um P-valor menor que 0,05 a partir da correlação de *Pearson*.

Deve-se ressaltar que o experimento foi separado em duas partes. A primeira teve por objetivo estimar a clorofila através do método de extração radiométrica por ROI's via polígonos. Já a segunda, teve por objetivo estimar a clorofila através do método de extração por ROI's via pontos, a fim de se comparar a influência desse fator na precisão final dos modelos. Ambos os métodos foram apresentados no tópico 5.3.3 deste trabalho.

Com isso, os modelos de estimativa foram gerados a partir da regressão entre 65 amostras da concentração da clorofila medida em campo e dos valores radiométricos das bandas

de melhor correlação. Dentre as equações geradas, optou-se sempre por aquelas que melhor se ajustavam aos dados, isto é, aquelas com maior coeficiente de determinação (R^2). Contudo, foi necessário verificar a acurácia dos modelos criados. Para isso, os modelos foram aplicados sobre a radiometria de 15 pontos de validação (*checkpoints*). Desse modo, obtiveram-se valores da concentração de clorofila estimada tornando possível o cálculo do RMSE (Raiz do Erro Quadrático Médio) sendo este um método bastante utilizado para verificação da acurácia de modelos estimadores (Equações 4 e 5).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(X_o - X_e)^2}{n}} \quad (4)$$

$$RMSE(\%) = \sqrt{\sum_{i=1}^n \frac{(X_o - X_e)^2}{n}} * \frac{100 * n}{\sum_{i=1}^n X_e} \quad (5)$$

Onde:

RMSE é a raiz do erro médio quadrático;

RMSE (%) é a raiz do erro médio quadrático em porcentagem;

X_o representa os valores de clorofila observados *in situ*;

X_e representa os valores de clorofila estimados;

n é o número de amostras.

Por fim, os modelos de estimativa foram aplicados nas bandas de interesse, gerando-se os mapas com a variação do teor de clorofila para aquela área.

5.3.5 Experimento 2

O objetivo do segundo experimento foi à elaboração de modelos estimadores da área foliar através da análise da regressão entre as amostras de AF obtidas *in situ* com os valores de radiometria das bandas espectrais e índices de vegetação derivados do sensor *Mapir Survey 3* e da câmera do drone. Os procedimentos executados para à elaboração dos modelos de estimativa da AF seguiram exatamente a mesma metodologia apresentada no primeiro experimento. Vale salientar que novamente foram consideradas apenas as bandas e índices que apresentaram maior correlação com vigor da vegetação.

Assim sendo, após a realização da análise da acurácia e validação proposta pelas Equações 4 e 5, o modelo de estimativa da área foliar foi aplicado nas bandas de interesse, gerando-se os mapas com a variação da área foliar do local de estudo.

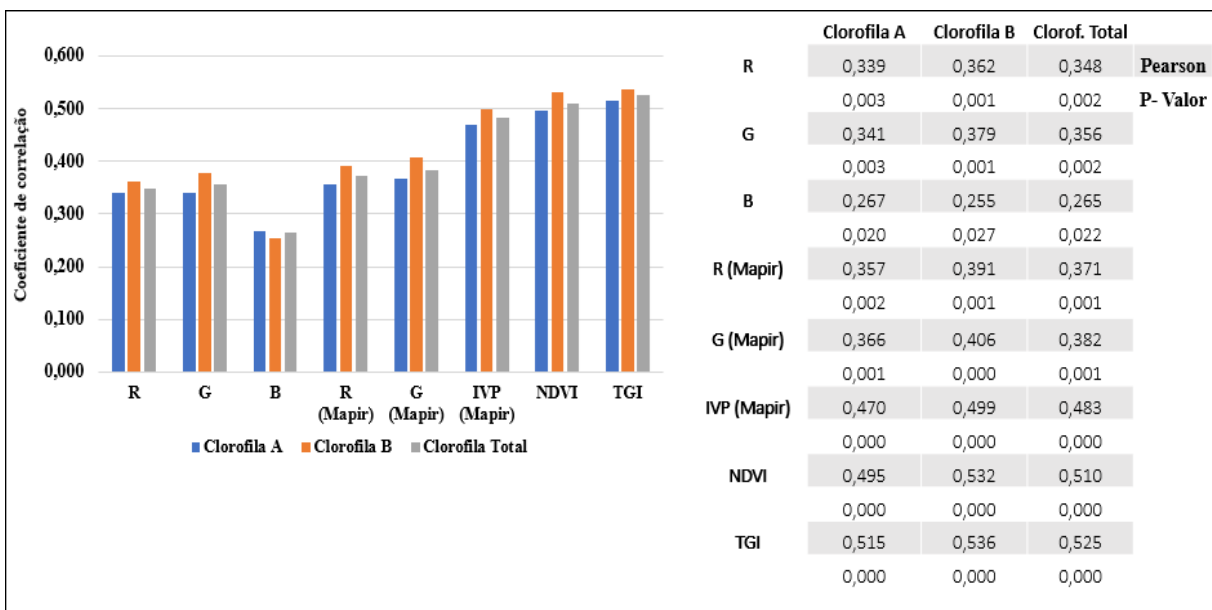
6 RESULTADOS E DISCUSSÕES

6.1 Experimento 1

6.1.1 Modelos de estimativa do teor de clorofila pelo método ROI's via polígonos

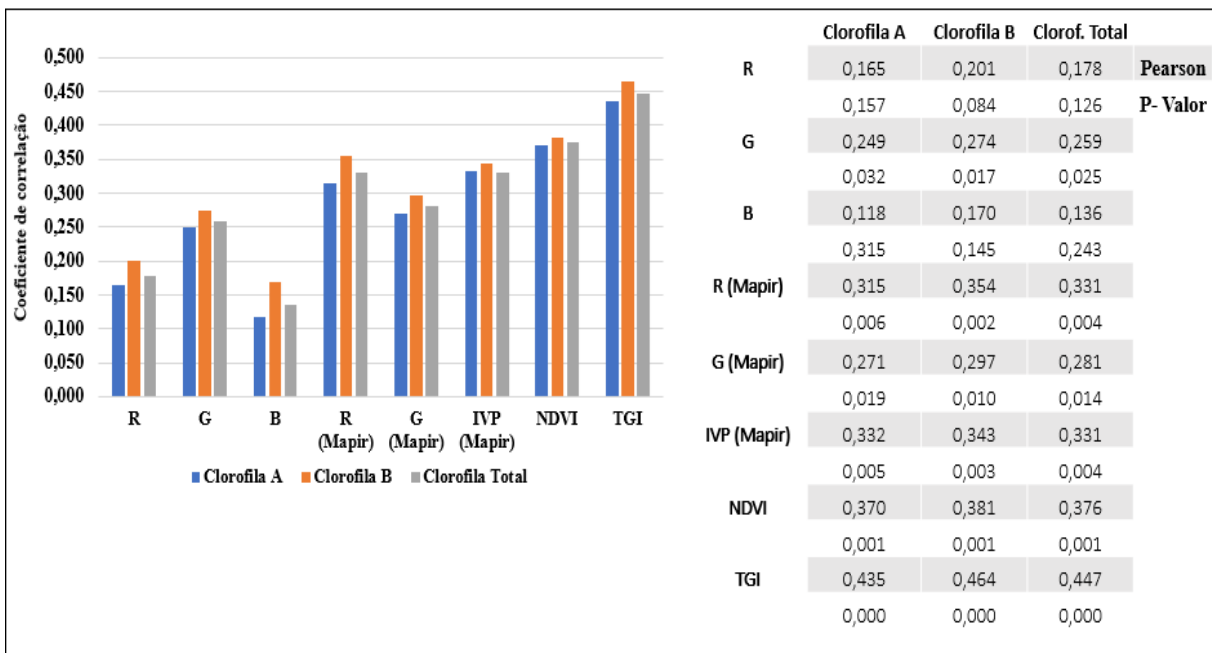
Para a elaboração dos modelos de regressão foi analisado inicialmente a correlação entre todas as bandas das câmeras Mapir e RGB (câmera do drone) bem como dos índices TGI e NDVI em relação à clorofila. As Figuras 16 e 17 apresentam a correlação das variáveis clorofila A, B e Total em relação as bandas e índices anteriormente citados.

Figura 16 – Correlação entre a clorofila, bandas espectrais e índices de vegetação
(Altitude de voo = 120 m)



Fonte: O autor.

Figura 17 – Correlação entre a clorofila, bandas espectrais e índices de vegetação
(Altitude de voo = 70 m)



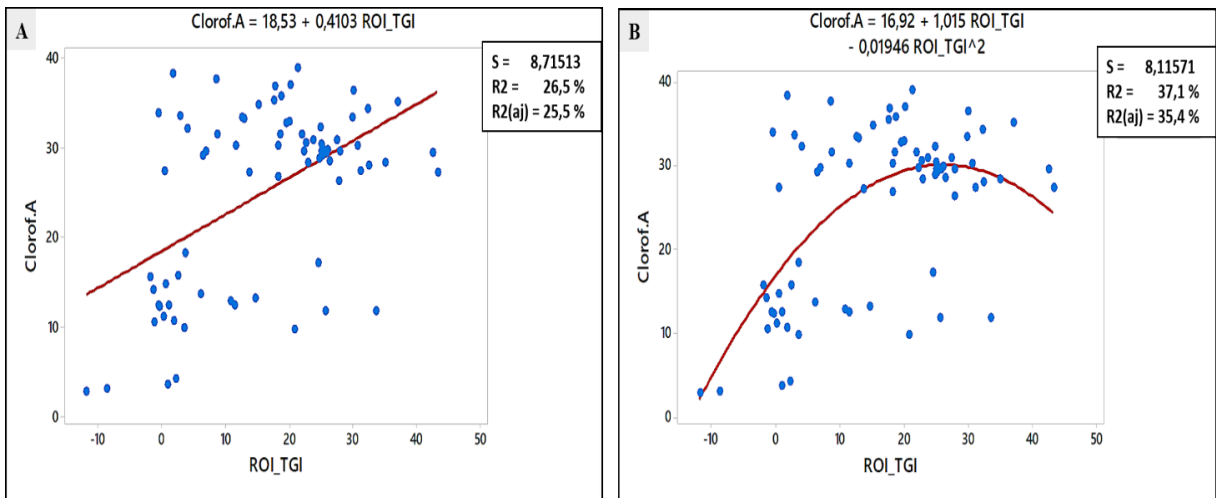
Fonte: O autor.

Considerando as informações da Figura 16 e o fato de que na metodologia proposta por este trabalho fora estipulado que para p-valores $< 0,05$ as correlações seriam consideradas significativas, os dados mostram que as correlações para todas as bandas e índices observados nesta situação foram relevantes. As correlações mais fortes ocorreram na banda do IVP e nos índices NDVI e TGI onde o p-valor = 0 evidencia a força dos resultados. Todavia, nota-se que as informações da Figura 17 apresentaram valores de correlação inferiores quando comparadas com a Figura 16. As bandas R e B da câmera do drone neste caso não obtiveram correlação significativa, fato comprovado pelo p-valor superior à 0,05 para ambas. Embora as demais bandas do voo à 70 metros tenham atingido correlação significativa, os valores se mostraram melhores no voo à 120 metros. Com isso, podemos partir do pressuposto que a variável altitude de voo teve influência nos resultados estatísticos para este trabalho.

Portanto, os dados da Figura 16 apresentaram melhores resultados para elaboração dos modelos de regressão. Como todos os preditores possuem um p-valor significativamente baixo, o índice TGI que teve o maior valor absoluto do coeficiente de correlação de *Pearson* foi o escolhido para descrever o teor de clorofila.

Com isso, foram gerados os modelos de regressão linear e quadrática do teor de clorofila A, B e Total com o índice TGI (Figuras 18, 19 e 20).

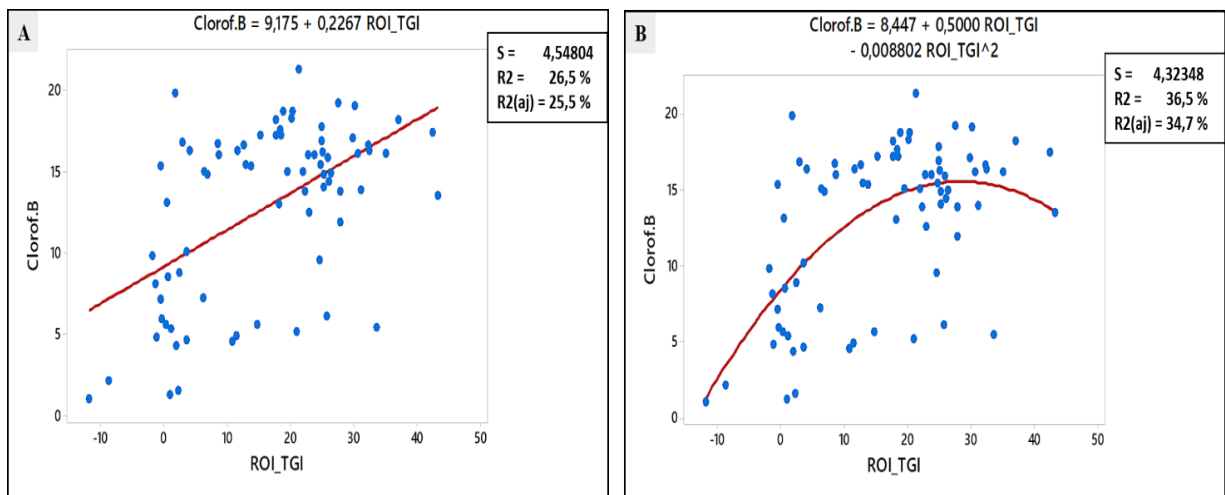
Figura 18 – Gráficos de regressões entre a clorofila A e TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.



Fonte: O autor.

Observando as informações geradas na Figura 18 nota-se que a regressão do tipo polinomial quadrática descreve melhor o comportamento dos dados. O coeficiente de determinação (R^2) dessa regressão consegue explicar 37,1% dos valores observados. Quando comparado com a regressão linear simples, este por sua vez explica 26,5% dos valores observados, ou seja, o modelo é 10,6% menos explicativo que o primeiro. Posto isto, a representação do modelo que melhor descreve o comportamento da clorofila A em relação ao TGI foi expressa pela Figura 18 B.


Figura 19 – Gráficos de regressões entre a clorofila B e TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.



Fonte: O autor.

Analisando agora a Figura 19 é possível concluir que para a clorofila B, a regressão polinomial quadrática também conseguiu explicar melhor o modelo quando comparada com a linear simples que é 10% menos explicativa. Com isso, a representação do modelo que melhor descreve o comportamento da clorofila B em relação ao TGI é expressa pela Figura 19 B.

Figura 20 – Gráficos de regressões lineares entre a clorofila Total e TGI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.




Fonte: O autor.

Por fim, foi feita a regressão entre a clorofila total, isto é, soma das clorofilas A e B em relação ao índice TGI. Optou-se também pela regressão polinomial quadrática dado que a mesma consegue explicar os valores observados 9,6% melhor que a regressão linear simples. Portanto, a representação do modelo que melhor descreve o comportamento da clorofila total em relação ao TGI é expressa pela Figura 20 B.

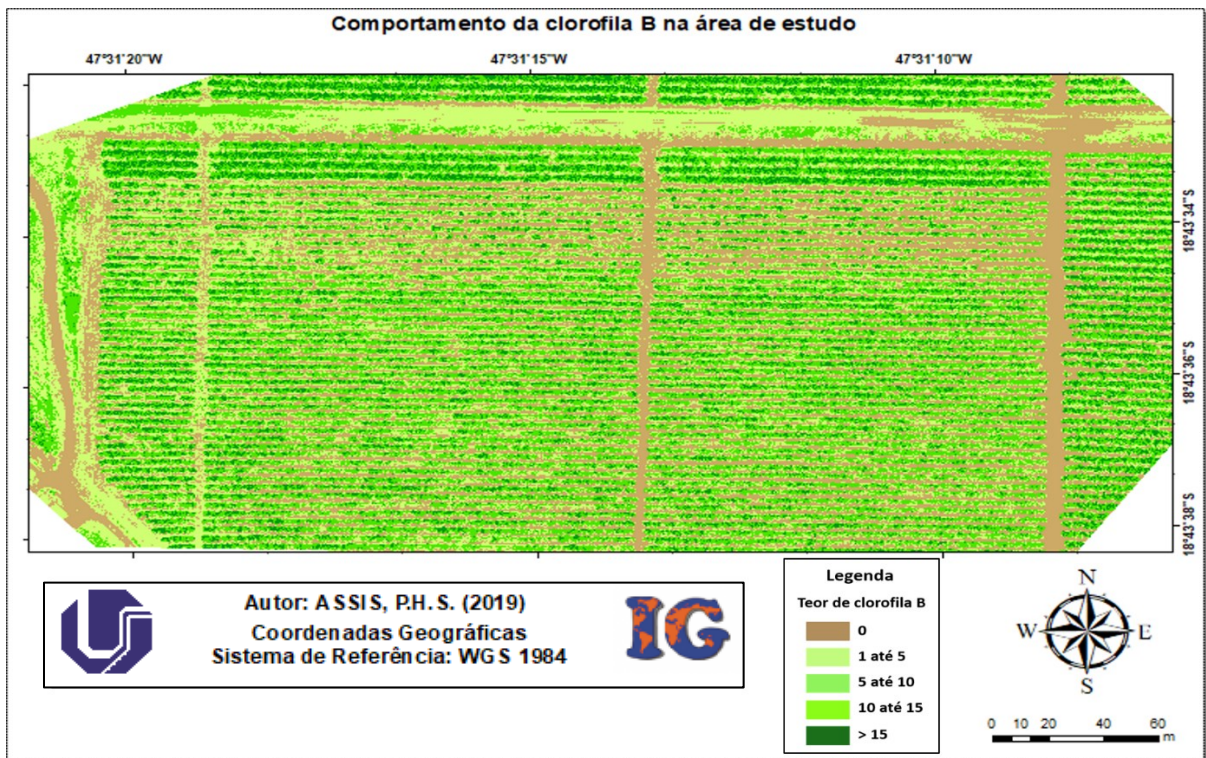
Após a elaboração dos modelos de regressão, as expressões foram aplicadas sobre o índice de interesse gerando-se os mapas da concentração do teor de clorofila A, B e Total da área de estudo (Figuras 21, 22 e 23).

Figura 21 – Mapa da concentração da clorofila A sobre a área de estudo



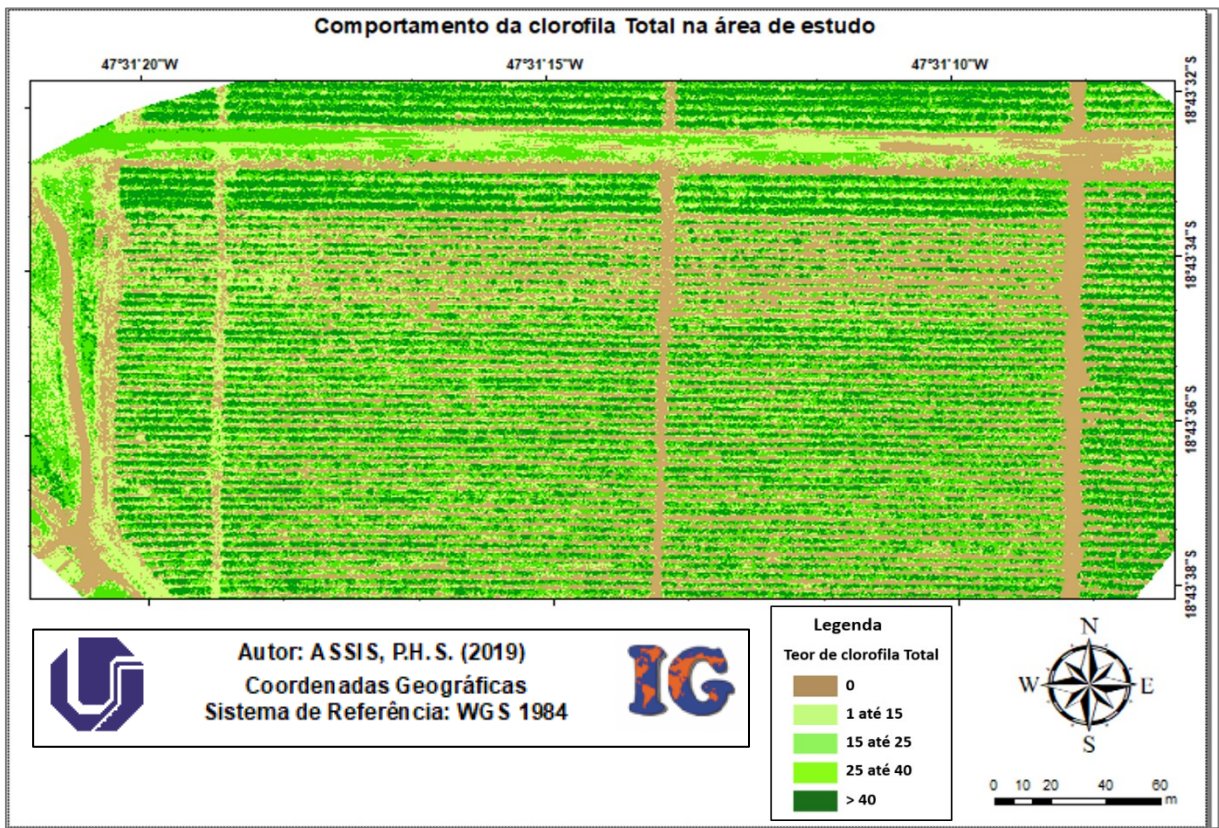
Fonte: O autor.

Figura 22 – Mapa da concentração da clorofila B sobre a área de estudo



Fonte: O autor.

Figura 23 – Mapa da concentração da clorofila Total sobre a área de estudo



Fonte: O autor.

O mapa dado pela Figura 21 aponta que os valores mais significativos de clorofila A foram encontrados nas regiões norte e leste da lavoura. Foi detectado também a presença de clorofila nas ruas e carreadores, o que é justificável pela existência de vegetação rasteira e folhas caídas da cultura naquela região. Percebe-se também a deficiência de clorofila em uma faixa próxima à região central do cultivo. Já a concentração de clorofila B (Figura 22) apresentou melhor distribuição pela área de estudo, principalmente na classe que varia de 15 à 25 unidades de clorofila. Para a clorofila total (Figura 23) houve presença significativa de altos valores dessa variável em todas as localidades da região de estudo. Contudo, é observável também déficits de clorofila total em uma faixa próxima à região central da lavoura.

Para validar os modelos estimadores, das 75 amostras obtidas *in situ* as 15 últimas foram tomadas como pontos de verificação. Com isso, estimou-se o teor de clorofila para esses pontos comparando os resultados com a verdade de campo. Isso possibilitou o cálculo do RMSE conforme mostra a Tabela 3.

Tabela 3 – Validação dos modelos de regressão pelo RMSE

	Clorofila A	Clorofila B	Clorofila Total
RMSE	4,73	2,42	6,92
RMSE (%)	17,01	16,95	16,43


Fonte: O autor.

Percebe-se que a clorofila B possui o menor erro (RMSE = 2,42) em unidades de clorofila. Contudo, quando analisamos em termos de porcentagem, o modelo mais preciso é o que estima a clorofila total (% RMSE = 16,43), ou seja, o modelo está estimando os dados com 83,57 % de precisão. Em suma, a clorofila A, B e total conseguem ser estimadas com precisão superior à 80 %.

6.1.2 Modelos de estimativa do teor de clorofila pelo método ROI's via pontos


Para a elaboração dos modelos de estimativa da clorofila por este método, a princípio foi necessário analisar a correlação de todas as bandas das câmeras Mapir e RGB (câmera do drone) e dos índices NDVI e TGI em relação à clorofila (Figuras 24 e 25).

Figura 24 – Correlação entre a clorofila, bandas espectrais e índices de vegetação (Altitude de voo = 120 m)



Fonte: O autor.

Figura 25 – Correlação entre a clorofila, bandas espectrais e índices de vegetação
(Altitude de voo = 70 m)

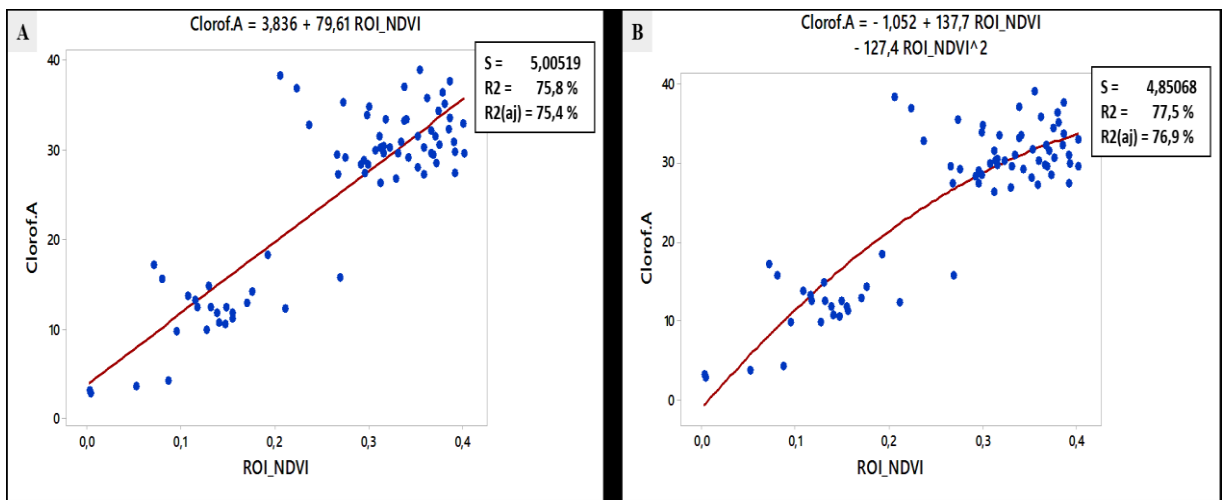


Fonte: O autor.

As informações das Figuras 24 e 25 revelam que existe correlação significativa para todas as bandas e índices apresentados. O p-valor próximo à zero ocorrendo em todos os casos se mostra como evidencia explicativa para os bons resultados de correlação. Embora as correlações se apontem otimistas para ambas altitudes de voo, os índices NDVI e TGI se sobressaíram em relação às demais bandas. O NDVI foi o índice que melhor se correlacionou com a clorofila para esta situação. Com isso, optou-se por este índice na altitude de voo à 120 metros onde o valor absoluto do coeficiente de correlação de *Pearson* foi maior. Percebe-se novamente que a variável altitude teve influência nos resultados, dado que os valores de correlação foram melhores para a altitude de voo maior.

Em seguida, foram gerados os modelos de regressão linear e quadrática do teor de clorofila A, B e Total com o índice NDVI (Figuras 26, 27 e 28).

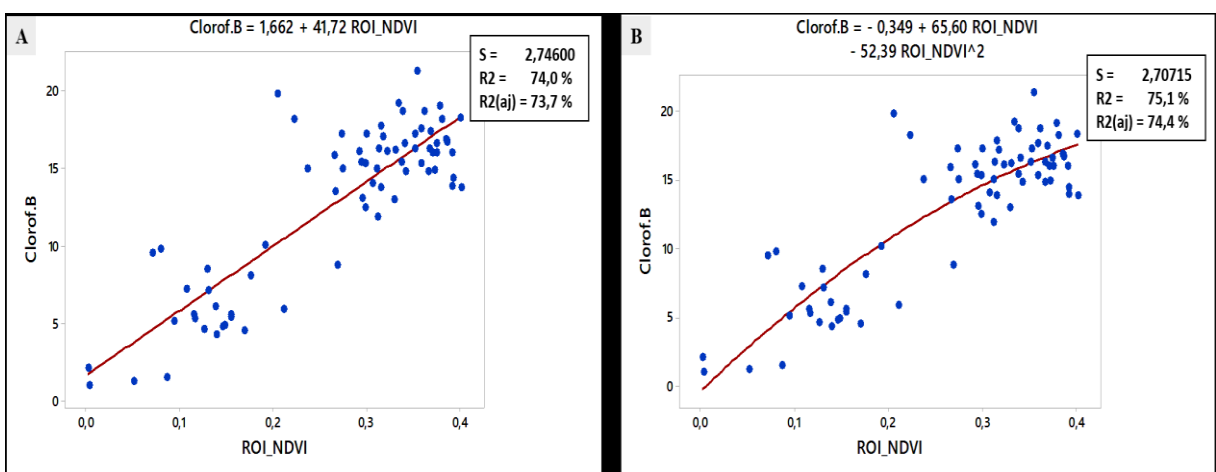
Figura 26 - Gráficos de regressões entre a clorofila A e NDVI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.



Fonte: O autor.

Os gráficos mostram que para a clorofila A, a regressão do tipo polinomial quadrática consegue explicar 77,5 % dos valores observados. Tal regressão possui o coeficiente de determinação 1,7% melhor que a regressão linear. Posto isso, foi decido que regressão polinomial quadrática melhor descreve o comportamento da clorofila A que é expressa pela Figura 26 B.

Figura 27 - Gráficos de regressões entre a clorofila B e NDVI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.

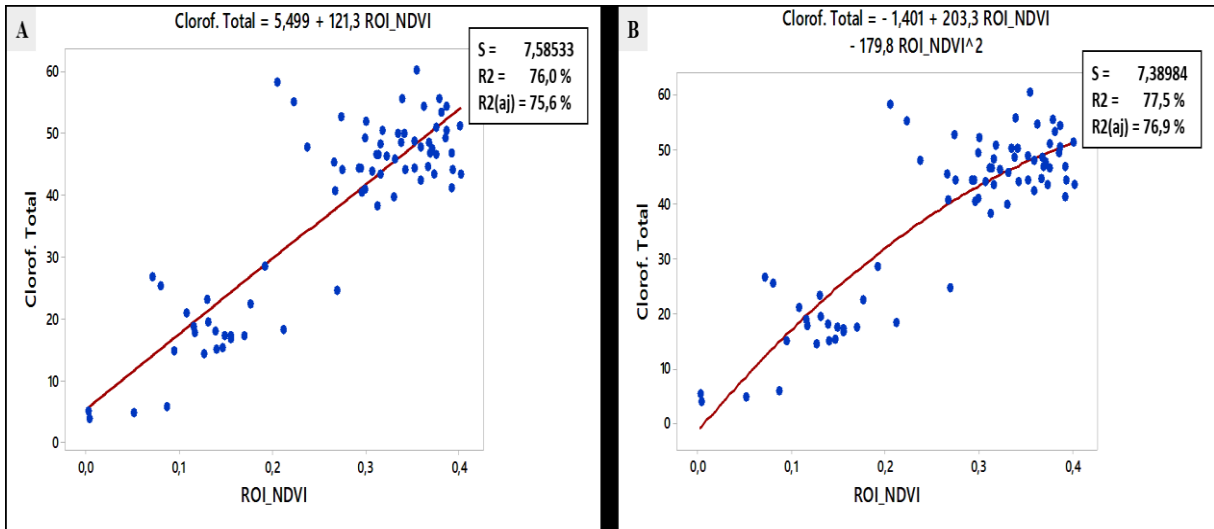


Fonte: O autor.

Para a clorofila B, os resultados mostram que a regressão polinomial quadrática é 1,1 % melhor que a linear. O modelo consegue explicar 75,1% dos valores observados e melhor

descreve o comportamento da clorofila B (Figura 27 B).

Figura 28 - Gráficos de regressões entre a clorofila total e NDVI. (A) Regressão linear simples. (B) Regressão polinomial quadrática.

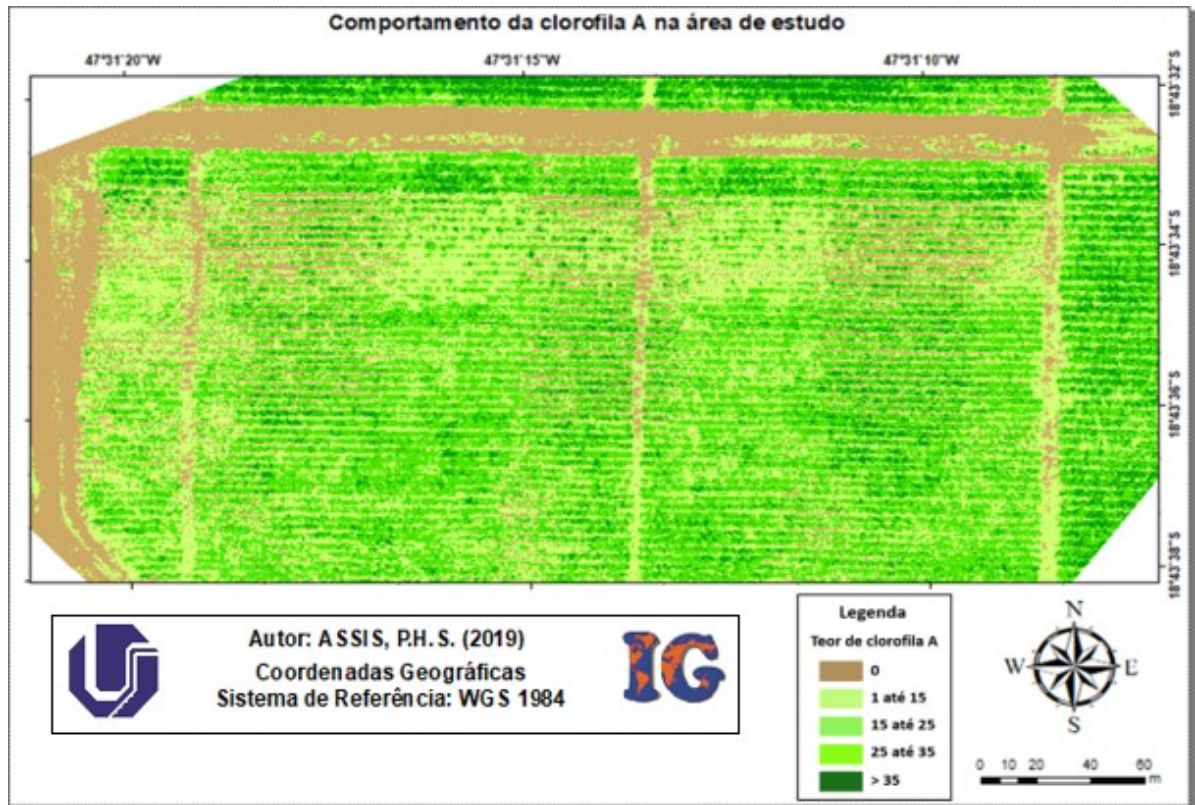


Fonte: O autor.

Por fim, foi feita a regressão entre a clorofila total em relação ao NDVI. Optou-se também pela regressão polinomial quadrática sendo que a mesma consegue explicar os valores observados 1,5% melhor que a regressão linear simples. Portanto, a representação do modelo que melhor descreve o comportamento da clorofila total em relação ao NDVI é expressa pela Figura 28 B.

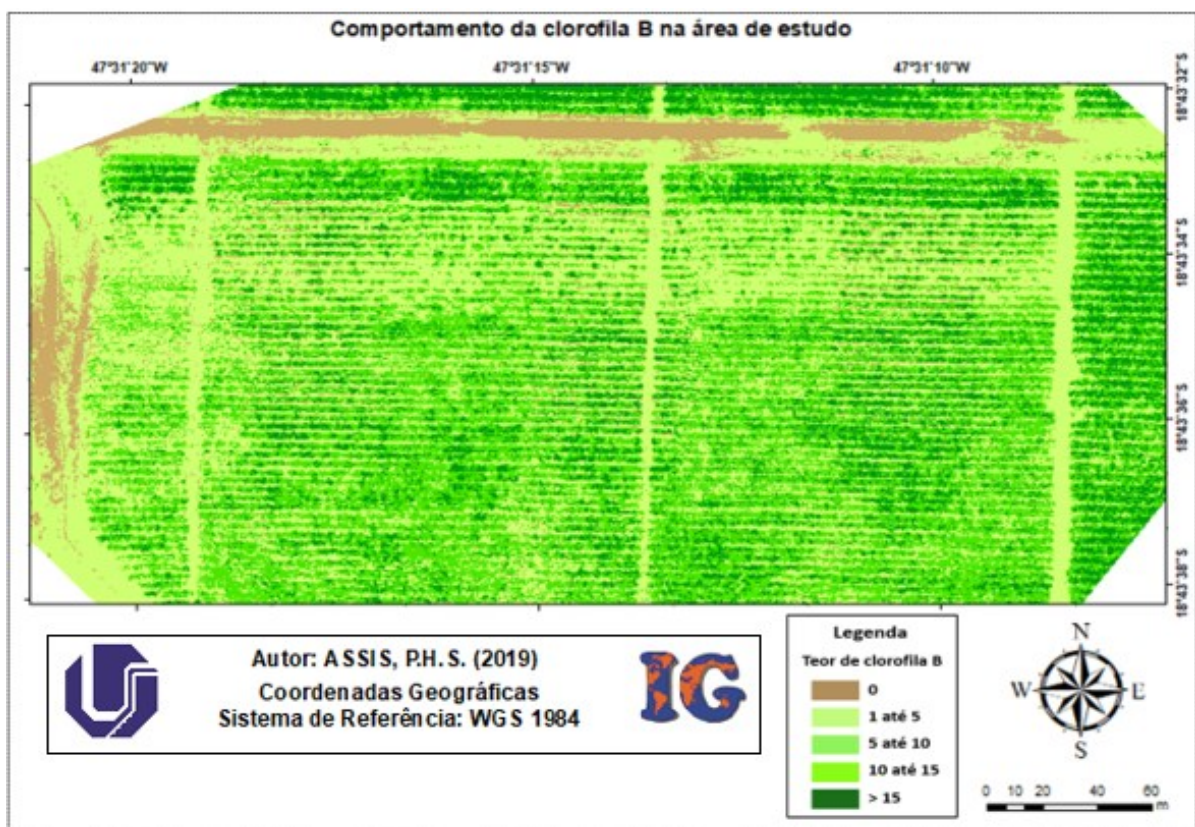
Após a elaboração dos modelos de regressão, as equações foram aplicadas sobre o índice de interesse gerando-se os mapas da variação do teor de clorofila A, B e Total da área de estudo (Figuras 29, 30 e 31).

Figura 29 – Mapa da concentração da clorofila A sobre a área de estudo




Fonte: O autor.

Figura 30 – Mapa da concentração de clorofila B sobre a área de estudo



Fonte: O autor.

Figura 31 – Mapa da concentração da clorofila total sobre a área de estudo



Fonte: O autor.

Através de uma análise geral observou-se que a concentração do teor de clorofila a e b (Figuras 29 e 30) apresentou valores maiores para a região norte da lavoura. Foi detectado também a presença de clorofila nas ruas e carregadores, o que é justificável pela existência de vegetação rasteira e folhas caídas da cultura naquela região. Para a clorofila total (Figura 31) a distribuição se mostrou mais homogênea, isto é, houve presença significativa de altos valores de clorofila total em todas as localidades da região de estudo. Contudo, é observável também déficits de clorofila total em parte da região oeste e em uma faixa próxima à região central da lavoura.

Novamente, para a validação dos modelos estimadores, das 75 amostras de campo as 15 últimas foram tomadas como pontos de verificação. Com isso, estimou-se o teor de clorofila para esses pontos comparando os resultados com a verdade de campo pelo cálculo do RMSE (Tabela 4).

Tabela 4 – Validação dos modelos de regressão pelo RMSE

	Clorofila A	Clorofila B	Clorofila Total
RMSE	4,39	2,00	6,19
RMSE (%)	14,84	13,26	13,84


Fonte: O autor.

Os resultados da tabela mostram que a clorofila B teve o menor erro em termos de unidade de clorofila (RMSE = 2,00) bem como em porcentagem (%RMSE = 13,26). De modo geral, todos os modelos atingiram um nível de precisão alto e conseguem estimar os dados com mais de 85 % de eficácia.

6.1.3 Comparação dos modelos: ROI's via polígonos *versus* ROI's via pontos

Afim de se comparar o potencial dos modelos estimadores de clorofila para ambos os métodos utilizados, temos a seguinte imagem:

Figura 32 – Comparação da eficácia dos modelos estimadores de clorofila



Fonte: O autor.

A Figura 32 aponta que o método de extração dos valores radiométricos trabalhando com regiões de interesse vetorizadas por feições pontuais trouxeram melhores resultados para os modelos estimadores da clorofila, isto é, o RMSE e o RMSE (%) foram inferiores quando comparados com o método de extração trabalhando com regiões de interesse vetorizadas por

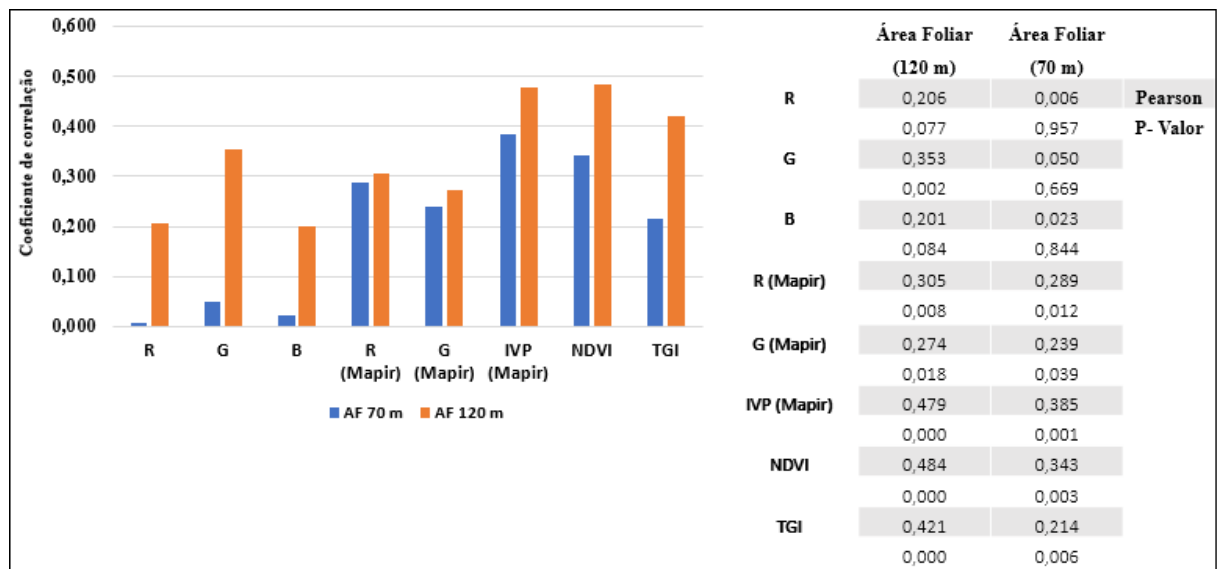
polígonos. Observando a média do RMSE (%) para ambos os métodos de extração, percebe-se que a diferença na precisão dos modelos estimadores não foi tão alta. Em média, o modelo estimador de clorofila gerado utilizando o método de extração por feições pontuais estima os dados com uma precisão 2,78 % melhor do que o outro modelo. Com isso, pode-se concluir que embora o método de extração trabalhando com ROI's via polígonos tenha apresentado um modelo com precisão inferior, ele também possui bom potencial em estimar a clorofila na área de estudo.

6.2 Experimento 2

6.2.1 Modelo de estimativa da área foliar pelo método ROI's via polígonos

Para a elaboração do modelo estimador da área foliar por este método, foi feita inicialmente a análise da correlação deste parâmetro com todas as bandas espectrais da câmera do drone e do sensor Mapir bem como dos índices de vegetação. A Figura 33 exibe as correlações das variáveis para as altitudes de voo igual a 70 e 120 metros.

Figura 33 – Correlação da área foliar com as bandas espectrais e IV's para os voos de 70 e 120 metros de altitude




Fonte: O autor.

Ao observar a Figura 33 percebe-se que no geral, a correlação entre a área foliar e as bandas obtiveram melhores resultados para o voo à 120 metros de altitude, reafirmando novamente a influência desse fator nos resultados. Para o voo à 70 metros, as bandas R, G e B da câmera do drone não obtiveram correlação significativa. O p-valor alto para essas bandas se

torna uma evidência explicativa do baixo valor de correlação observado. Dentre as bandas e índices apresentados, o IVP, NDVI e TGI apontaram melhores valores de correlação com a área foliar. Como o NDVI teve o maior valor absoluto do coeficiente de correlação ($Pearson = 0,484$), chegou-se à conclusão de que o mesmo melhor representaria o comportamento da área foliar na região de interesse.

Com isso, foram gerados os modelos de regressão linear e quadrática da AF com o índice NDVI (Figura 34).

Figura 34 – Modelos de regressão entre a AF e o NDVI. (A) Regressão Linear Simples. (B) Regressão Polinomial Quadrática

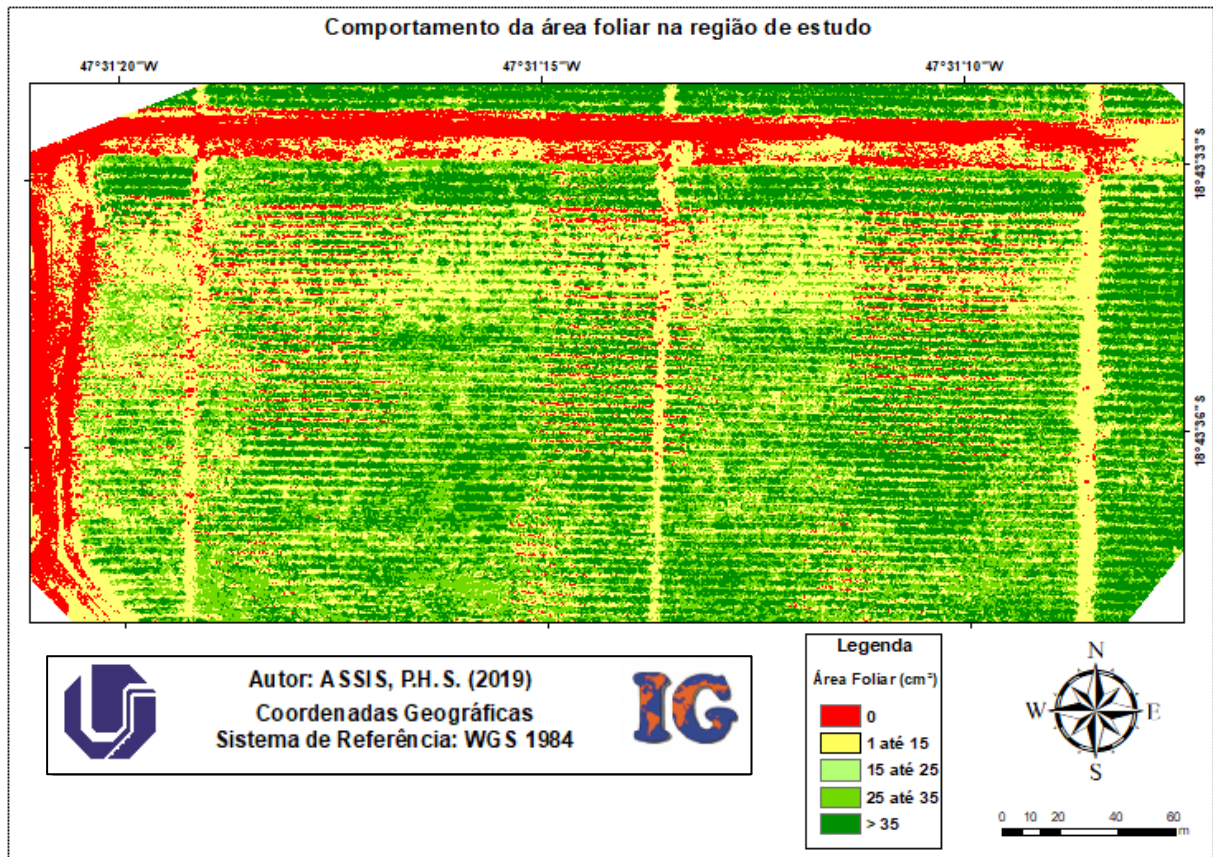


Fonte: O autor.

Os gráficos da Figura 34 evidenciam que a curva gerada pela regressão polinomial quadrática consegue explicar 23,3 % da ocorrência dos dados observados. Quando comparamos os coeficientes de determinação de ambos os modelos se percebe que a regressão linear simples produz resultados com 2,7% de inferioridade em relação ao outro modelo. Portanto, foi decidido que a equação da regressão quadrática melhor descreve o comportamento da área foliar na região de estudo.

Após a elaboração dos modelos de regressão, a equação foi aplicada sobre a banda de interesse gerando-se o mapa da variação da área foliar na área de estudo (Figura 35).

Figura 35 – Mapa do comportamento da área foliar na região de estudo



Fonte: O autor.


O modelo estimador escolhido para mapear o comportamento da AF na região de estudo apresenta o erro médio quadrático $RMSE = 5,15$. Este erro foi calculado em porcentagem, chegando-se a $RMSE (\%) = 15,857$, ou seja, o modelo estima os dados com 84% de precisão.

Analisando o mapa percebe-se que os valores mais altos de área foliar encontram-se nas regiões norte e leste da lavoura. Existe também a presença de solo exposto (caracterizado pela cor vermelha) bem como faixas próximas à região central que apresentaram baixos valores de área foliar.

6.2.2 Modelo de estimativa da área foliar pelo método ROI's via pontos

Para a elaboração dos modelos de regressão por este método, também foi necessário primeiramente analisar a correlação entre a AF com as bandas espectrais da câmera do drone, do sensor Mapir e os índices de vegetação TGI e NDVI. A Figura 36 apresenta a correlação desses parâmetros para os dois voos que foram realizados com altitudes distintas.

Figura 36 – Correlação da área foliar com as bandas espectrais e índices de vegetação

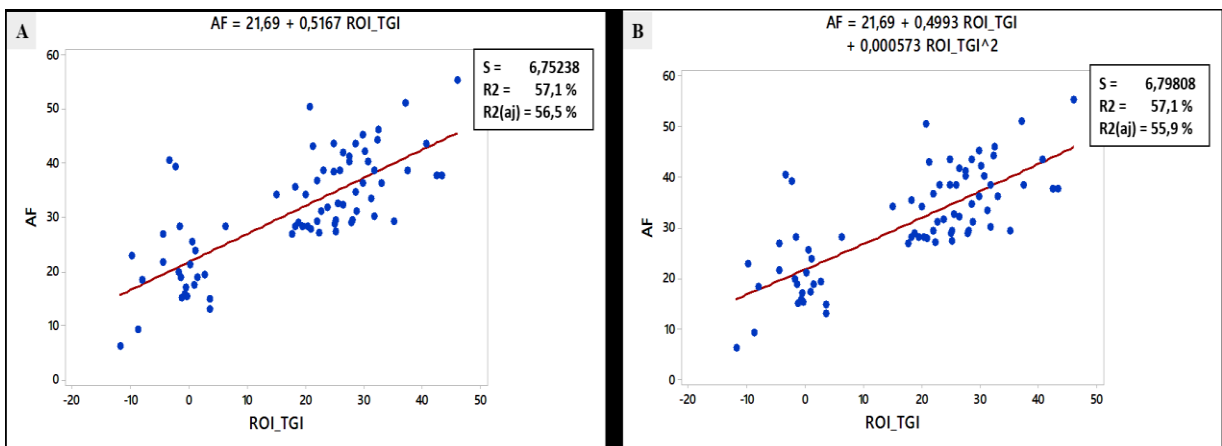


Fonte: O autor.

Os dados mostram que as correlações para o voo à 120 metros de altitude foram melhores. Para o voo à 70 metros, a banda B da câmera do drone não obteve correlação significativa o que é evidenciado pelo p-valor alto. Os índices NDVI e TGI se sobressaíram em relação às demais bandas. O p-valor = 0 para esta situação evidencia a boa correlação obtida pelos índices. Como o TGI apresentou o maior valor absoluto do coeficiente de correlação (*Pearson* = 0,756), ele foi o escolhido para representação do comportamento da AF na região de estudo. Para tanto, foram gerados os modelos de regressão linear e quadrática entre a área foliar e o índice em questão (Figura 37).

Figura 37 – Modelos de regressão entre a AF e o TGI. (A) Regressão linear simples.

(B) Regressão polinomial quadrática.




Fonte: O autor.

A Figura 37 mostra que para ambas as regressões o coeficiente de determinação (R^2) se manteve o mesmo. Toda via, o desvio padrão das medidas é menor na regressão linear simples e também possui o coeficiente de determinação ajustado maior. Portanto, a regressão linear foi a escolhida como modelo que melhor descreve o comportamento da AF.

Aplicando a equação sob o índice TGI temos o mapa da variação da área foliar na região de estudo (Figura 38).

Figura 38 – Mapa do comportamento da área foliar na região de estudo



Fonte: O autor.


Para a validação do modelo estimador novamente foi calculado o RMSE onde se encontrou o valor $RMSE = 8,27$ e $RMSE (\%) = 24,41$. O resultado indica que o modelo é capaz de estimar os dados com mais de 75% de precisão.

O mapa apresenta valores maiores de área foliar para a região norte da lavoura. Percebe-se também que na região central a presença de área foliar é mais baixa. O produto conseguiu caracterizar também a presença de solo exposto (região representada pela cor vermelha), tanto para as ruas e carreadores daquela plantação.

6.2.3 Comparação dos modelos gerados por ROI's via polígonos versus ROI's via pontos

Afim de se comparar o potencial dos modelos estimadores da área foliar para ambos os métodos utilizados, temos a seguinte imagem:

Figura 39 – Comparação da eficácia dos modelos estimadores de AF



Fonte: O autor.

Os dados comprovam que o erro dos modelos estimadores foi menor para o método de extração usando ROI's via polígonos. Em termos de porcentagem, o modelo gerado por este método estima os dados com precisão 8,56% melhor do que o outro.

7 CONSIDERAÇÕES FINAIS

A câmera *Mapir Survey 3* acoplada à plataforma Drone Phantom 4 *Advanced* tem potencial no mapeamento dos parâmetros agronômicos estudados neste trabalho. Contudo, vale salientar que a câmera possui certas limitações que contribuem para a redução na precisão dos dados.

Das regressões geradas, o modelo estimador da clorofila que utilizou o método de extração radiométrica de ROI's via pontos apresentou melhor acurácia, com valor médio do RMSE (%) = 13,98. Já o modelo estimador da área foliar que utilizou o método de extração radiométrica de ROI's via pontos foi o menos acurado, com valor médio do RMSE (%) = 24,41. Desse modo, o mapeamento do teor de clorofila teve precisão média de 86,02 % ao passo que a área foliar teve precisão média de 84,15 %.

Outro fator importante foi considerar que a precisão das informações obtidas com os modelos não dependeu exclusivamente dos sensores. Na verdade, o grande influenciador dos resultados consistiu na boa amostragem dos dados. Este trabalho fundamentou-se na obtenção de dados de campo com a melhor caracterização possível das informações. Desta forma, todos os levantamentos de campo foram executados em um único dia. Para tanto, a plataforma ARP aplicada ao sensoriamento remoto mostrou seu potencial quanto à resolução temporal, alto desempenho e não dependência da influência de condições climáticas tais como a presença de nuvens.

Por fim, o trabalho mostrou que os resultados da estatística geral dos dados foram melhores para o voo à 120 metros de altitude. Sensores embarcados em ARP's possuem alta resolução espacial o que é benéfico para alguns estudos. Todavia, a área de pesquisa que envolve o desenvolvimento de modelos estimadores necessita de boa resolução espectral e como essas imagens são obtidas a uma altitude muito baixa, o nível de informação é muito grande e os algoritmos não conseguem processar de forma eficiente esses dados.

REFERÊNCIAS

- ADAMI, M.; HASTENREITER, F.A.; FLUMIGNAN, D.L.; FARIA, R.T.de. Estimativa de área de folíolos de soja usando imagens digitais e dimensões foliares. **Bragantia**, v.67, p.1053-1058, 2008.
- ASSAD, E.D.; SANO, E.E.; CUNHA, S.A.R.da.; CORREA, T.B.S.; RODRIGUES, H.R. **Identificação de impurezas e misturas em pó de café por meio de comportamento espectral e análise de imagens digitais**. Embrapa- Centro de Pesquisa Agropecuária dos Cerrados. Brasília, v.37, n.2, p. 211-216, 2002. Disponível em: < <https://seer.sct.embrapa.br/index.php/pab/about/submissions>>. Acesso em: 14 mar. 2019.
- BARROS, R. S.; MAESTRI, M.; VIEIRA, M.; BRAGAFILHO, L. J. **Determinação de área de folhas do café (*Coffea arabica* L. cv. 'Bourbon Amarelo')**. Revista Ceres, Viçosa, v.20, n.107, p.44-52, 1973.
- BARROS, M. A.; MOREIRA, M. A.; RUDORFF, B. F. T.; FARIA, V. G. C. de. Mapeamento de áreas cafeeiras em imagens de sensores orbitais: estudo de caso em Aguanil, Boa Esperança, Campo Belo e Cristais-MG como suporte a estudos regionais. In: Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, **Anais...** v. 13, p. 21-26, 2007.
- BATISTA, E.R.; BETTIOL, W.; GHINI, R.; BRAGA, M.R.; SILVA, E.A. **Aumento da concentração atmosférica de CO₂ altera a fotossíntese e acúmulo de biomassa em duas cultivares de *Coffea arabica***. XIV Congresso Brasileiro de Fisiologia Vegetal, 2013, Poços de Caldas. Anais, 2013. p. 408-408.
- BOECHAT, L.T. **Técnica de sensoriamento remoto na detecção do mofo branco e da mancha-angular no feijoeiro**. 128 f. Tese (Doutorado) – Curso de Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, 2012.
- BUSSAB, W. O.; MORETTIN, P. A. **Estatística Básica**. 6ª Ed. São Paulo: Editora Saraiva, 2010. 535p.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. *Remote sensing leaf water stress in coffee (*Coffea arabica*) using secondary effects of water absorption and random forests*. **Physics and Chemistry of the Earth**. 2017. p.317-324.
- CONAB - Companhia Nacional de Abastecimento. **Produção de café deve ser a maior da história com quase 60 milhões de sacas**. Disponível em: < <https://www.conab.gov.br/ultimas-noticias/2512-producao-de-cafe-deve-ser-a-maior-da-historia-com-quase-60-milhoes-de-sacas>> Acesso em: 29 mar. 2019.
- FALKER, Automação agrícola. **Manual do medidor eletrônico de teor de clorofila (ClorofiLOG/CFL 1030)**. Porto Alegre, 2008. 33p. Disponível em: <http://www.falker.com.br/produto_download.php?id=4>. Acesso: 28 nov. 2019.
- FAVARIN, J. L. et al. Equações para a estimativa do índice de área foliar do cafeeiro. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 37, n. 6, p. 769-773, 2002.

FERRARO, N. G.; TORRES, C. M. A.; PENTEADO, P. C. M. **Física**. 1ª Ed. São Paulo: Moderna, 2012. 507p.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em agricultura**. São Paulo: Oficina de textos, 2017. 288p.

FURLANETTO, R.H.; NANNI, M.R.; CRUSIOL, L.G.T.; SILVA, G.F.C.; OLIVEIRA JUNIOR, A. de. Potencial de utilização de sensores multiespectral e hiperespectral no estudo de diferentes alvos agrícolas. In: Jornada Acadêmica da Embrapa Soja, XII, 2017, Londrina, **Anais...** Londrina: Embrapa Soja, 2017. p. 146-154.

GALVÃO, J. R.; OLIVEIRA NETO, C. F.; OKUMURA, R. S. Pigmentos fotossintéticos em plantas de sorgo submetidas a diferentes doses de nitrogênio e potássio. In: 28º Congresso Brasileiro de Zootecnia, 2018, Goiânia. **Anais...** Goiânia: Sociedade Brasileira de Zootecnia, 2018. p. 110-115.

HUNT, 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.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA (IPEA). **Agricultura: evolução e importância para a balança comercial brasileira - 2014**. Disponível em: http://www.en.ipea.gov.br/agencia/images/stories/PDFs/TDs/td_1944.pdf

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. São José dos campos: Parêntese, 2009. 598p.

LANGHI, P.; TOMMASELLI, A. M. G.; Correção radiométrica de imagens aéreas digitais por meio de ajuste polinomial. In: Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, II, 2008, Recife, **Anais...** Recife: UFPE, 2008.

LEONARDO, F.A.P.; PEREIRA, W.E.; SILVA, S.M.; COSTA, J.P. **Teor de clorofila e índice spad no abacaxizeiro** cv. Vitória em função da adubação nitrogenada. *Revista Brasileira de Fruticultura*, v.35, n.2, p. 377-383, 2013.

LIRA, S.A. **Análise de correlação: Abordagem teórica e de construção dos coeficientes com aplicações**. 196 f. Dissertação (Mestrado) – Curso de Ciências Exatas, Universidade Federal do Paraná, Paraná, 2004.

LIU, W. T. H. **Aplicações de Sensoriamento Remoto**. Campo Grande: UNIDERP, 2007. 908p.

MARTINS, G. D.; GALO, M. de L. B. T.; VIEIRA, B. S. Caracterização hiperespectral in situ do cafeeiro infectado por nematoides. In: Simpósio Brasileiro de Sensoriamento Remoto, XVII, 2015, João Pessoa, **Anais...** João Pessoa: INPE, 2015. p.1829-1836.

MARTINS, G. D. **Inferência dos níveis de infecção por nematoides na cultura cafeeira a partir de dados de sensoriamento remoto adquiridos em multiescala.** 121 f. Tese (Doutorado) - Curso de Ciências Cartográficas, Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2016.

MCKINNON, T.; HOFF, P. *Comparing RGB-based vegetation indices with NDVI for agricultural drone imagery.* Boulder, 2017. Disponível em: <<https://agribotix.com/blog/2017/04/30/comparing-rgb-based-vegetation-indices-with-ndvi-for-agricultural-drone-imagery/>> Acesso em: 20, mar. 2019.

MELO, B. M. R. **Técnicas de agricultura de precisão para avaliação da variabilidade de solo e do cafeeiro em pequenas propriedades do sul de Minas Gerais.** 103 p. Dissertação (Mestrado) – Curso de Ciências Agrônômicas, Universidade Federal de Lavras, Lavras, 2015.

MENEZES, P.R.; ALMEIDA, T.; **Introdução ao processamento de imagens de sensoriamento remoto.** Universidade Federal de Brasília (UNB), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ). Brasília, DF., 2012. 276 p.

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. F. **Agricultura de Precisão.** 1. ed. São Paulo: Oficina de Textos., 2015. 231 p.

MORAES, E.C. Fundamentos de Sensoriamento Remoto. 2015. **Apostila.** Instituto Nacional de Pesquisas Espaciais (INPE/MCTI). Disponível em: <http://www.dsr.inpe.br/vcsr/files/capitulo_1.pdf>. Acesso em: 2 abr. 2019.

MORAES, L. de.; SANTOS, R. K.; WISSER, T. Z.; KRUPPEK, R. A. **Avaliação da área foliar a partir de medidas lineares simples de cinco espécies vegetais sob diferentes condições de luminosidade.** Revista Brasileira de Biociências v. 11, n. 4, p. 381-387, 2013.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação.** 4 Ed. Atualizada e Ampliada – Viçosa: UFV, 2012. 422p.

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

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPPLICH, T. M. **Sensoriamento Remoto da Vegetação.** 2. Ed. Atualizada e Ampliada – São Paulo: Oficina de textos, 2012.

QUEIROZ, J. E. R.de.; GOMES, H. M. **Introdução ao Processamento Digital de Imagens.** Revista de Informática Teórica Aplicada v.8, n.1, p. 2-31, 2001.

RAMIREZ, G.M.; JÚNIOR ZULLO, J. **Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial.** Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura. Jaboticabal, v.30, n.3,

p. 468-479, 2010.

RICHARDSON, A.D.; DUIGAN, S.P.; BERLYN, G.P. *An evaluation of noninvasive methods to estimate foliar chlorophyll content. New Phytologist, Lancaster*, v.153, n.1, p.185-194, 2002.

RODRIGUES JÚNIOR, F. A.; VIEIRA, L. B.; QUEIROZ, D. M. de; SANTOS, N. T. **Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar.** Revista Brasileira de Engenharia Agrícola e Ambiental. v.15, n.8, p.778-787, 2011.

ROSA, R. **Introdução ao sensoriamento remoto.** 7 ed. Uberlândia: EDUFU, 2009. 264p.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. *Monitoring vegetation systems in the great plains with ERTS.* In: **Third ERTS Symposium, Proceedings**, NASA SP-351, NASA, Washington, DC, v. 1, p. 309-317, 1973.

SILVA, W. Z. da; BRINATE, S. V. B; TOMAZ, M. A; AMARAL, J. F. T. do; RODRIGUES, W. N; MARTINS, L. D. **Métodos de Estimativa de Área Foliar em Cafeeiro.** Centro Científico Conhecer, Goiânia, v.7, n.13, p.746-755, 2011.

SILVA, F. M. da; ALVES, M de C. **Cafeicultura de Precisão.** Lavras: UFLA, 2013. 227p.

SWIADER, J.M.; MOORE, A. *SPAD - chlorophyll response to nitrogen fertilization and evaluation of nitrogen status in dryland and irrigated pumpkins. Journal of Plant Nutrition*, v. 25, p.1089-1100, 2002.

TAIZ, L.; ZEIGER, E. **Fisiologia Vegetal.** 3 ed. Porto Alegre: Artmed, 2004. 719p. Disponível em: <<https://www.ebah.com.br/content/ABAAAfqVkAG/taiz-zeiger-fisiologia-vegetal-3ed>>. Acesso em: 31 mar. 2019.

TOMMASELLI, A. M. G. **Fotogrametria Básica.** 2009. Disponível em: <http://www.faed.udesc.br/arquivos/id_submenu/891/introducao_a_fotogrametria.pdf> Acesso em: 14 mar. 2019.

ZOTARELLI, L.; CARDOSO, E.G.; PICCINI, J.L.; URQUIAGA, S.; BODDEY, R.M.; TORRES, E.; ALVES, B.J.R. **Calibração do medidor de clorofila Minolta SPAD-502 para uso na cultura do milho.** Rio de Janeiro: Embrapa Agrobiologia, 4p. (Comunicado técnico,55). 2003.