



**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE DOUTORADO EM AGRONOMIA**

**INFERÊNCIA DO TEOR DE NITROGÊNIO FOLIAR EM LARANJEIRA-
VALÊNCIA COM IMAGENS MULTIESPECTRAIS DE ALTA RESOLUÇÃO
ESPACIAL**

LUCAS PRADO OSCO

**INFERÊNCIA DO TEOR DE NITROGÊNIO FOLIAR EM LARANJEIRA-
VALÊNCIA COM IMAGENS MULTIESPECTRAIS DE ALTA RESOLUÇÃO
ESPACIAL**

LUCAS PRADO OSCO

Tese apresentada a Pró-Reitoria de Pesquisa e Pós-Graduação, Universidade do Oeste Paulista, como parte dos requisitos para a obtenção do título de Doutor no Programa de Pós-Graduação em Agronomia, Área de Concentração: Produção Vegetal.

Orientador: Dr. José Eduardo Creste
Coorientadora: Dr.^a Ana Paula Marques Ramos

630
O81i

Oscó, Lucas Prado.

Inferência do teor de nitrogênio foliar em laranjeira-valência com imagens multiespectrais de alta resolução espacial / Lucas Prado Oscó. – Presidente Prudente, 2019.

112f.: il.

Tese (Doutorado em Agronomia) - Universidade do Oeste Paulista - UNOESTE, Presidente Prudente, São Paulo, 2019.

Bibliografia.

Orientador: Dr. José Eduardo Creste

Coorientadora: Dr.^a Ana Paula Marques Ramos

1. Aeronaves Remotamente Pilotadas. 2. Agricultura de Precisão. 3. Classificação de Imagens. 4. Índices Espectrais de Vegetação.

CERTIFICADO DE APROVAÇÃO

TÍTULO: "INFERÊNCIA DO TEOR DE NITROGÊNIO FOLIAR EM LARANJEIRA VALÊNCIA COM IMAGENS MULTIESPECTRAIS DE ALTA RESOLUÇÃO ESPACIAL"

AUTOR(A): LUCAS PRADO OSCO

ORIENTADOR(A): JOSÉ EDUARDO CRESTE

Aprovado(a) como parte das exigências para obtenção do título de DOUTOR em AGRONOMIA

Área de Concentração PRODUÇÃO VEGETAL, pela Comissão Examinadora:

Carlos Henrique dos Santos

UNOESTE – Universidade do Oeste Paulista / Presidente Prudente (SP)

Fernanda Sayuri Yoshino Watanabe

UNESP - Universidade Estadual Paulista Júlio de Mesquita Filho / Presidente Prudente (SP)

José Eduardo Creste

UNOESTE – Universidade do Oeste Paulista / Presidente Prudente (SP)

Tatiana Sussel Gonçalves Mendes

UNESP - Universidade Estadual Paulista Júlio de Mesquita Filho / São José dos Campos (SP)

William Hiroshi Suekane Takata

UNOESTE – Universidade do Oeste Paulista / Presidente Prudente (SP)

Data da realização: 11 de abril de 2019.

AGRADECIMENTOS

Ao apoio acadêmico e técnico;

Prof.^a Dr.^a Ana Paula Marques Ramos, mentora desta Tese, e Prof. Dr. José Eduardo Creste, que proporcionou a execução da pesquisa realizada.

Prof. Dr. José Marcato Júnior e Dr.^a Érika Akemi Saito Moriya, que conduziram o levantamento de dados em campo e o seu processamento.

Prof. Dr. Nilton Nobuhiro Imai e Prof. Dr. Edson Takashi Matsubara que cederam o equipamento necessário para a obtenção dos dados.

Prof. Dr. Carlos Henrique dos Santos, técnicos e discentes do Laboratório de Análise do Tecido Foliar, que realizaram a análise química dos dados.

Discentes; Vagner S. Machado, Mayara M. Faita, Felipe D. G. Gomes, Renata C. Mafra, Marco A. Fernandes e Geison R. Filho, que participaram do levantamento dos dados em campo e do seu processamento.

Funcionários da Fazenda Brasília, que nos acompanharam durante todo o levantamento de dados em campo, dando suporte sempre quando necessário.

Universidade do Oeste Paulista (UNOESTE); Universidade Federal do Mato Grosso do Sul (UFMS); Universidade Estadual Paulista “Júlio Mesquita Filho” (UNESP); Fazenda Brasília e; Instituto de Terras do Estado de São Paulo (ITESP).

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – (Brasil) CAPES – Código de Financiamento 001.

Obrigado.

RESUMO

Inferência do teor de nitrogênio foliar em laranjeira valência com imagens multiespectrais de alta resolução espacial

O nitrogênio possui papel fundamental na atividade fotossintética das plantas, e a sua análise é essencial para o manejo de culturas agrícolas. Uma maneira de se obter informações rápidas e menos dispendiosas do nutriente é por meio do processamento de imagens multiespectrais. As aplicações com imagens adquiridas por sensores a bordo de Aeronaves Remotamente Pilotadas (ARP) aumentaram na Agricultura de Precisão. Todavia, em citrus, em específico laranjeiras, pouco se conhece sobre o potencial das imagens multiespectrais adquiridas com ARPs na inferência do teor de nitrogênio foliar. Diante desse contexto, o objetivo desta pesquisa foi avaliar o potencial de imagens multiespectrais de alta resolução espacial para inferir o teor de nitrogênio foliar em laranjeiras-valência. Como método, aplicamos duas abordagens para inferir o teor de nitrogênio foliar: (1) classificação de imagens e; (2) índices espectrais. Para isso, conduzimos um experimento em um pomar de laranjeiras-valência (porta-enxerto Citrumelo Swingle) e coletamos folhas de diferentes talhões da plantação. Realizamos um voo com uma ARP eBee SenseFly, equipado com a câmera Parrot Sequoia, que registra bandas nas faixas do verde, vermelho, borda-do-vermelho e do infravermelho-próximo, com *Ground Sample Distance* (GSD) de 12 cm. Na primeira abordagem determinamos que o algoritmo de classificação *Spectral Angle Mapper* (SAM) possui o melhor desempenho ao classificar o nitrogênio foliar, com acurácia global de 85,7% e coeficiente *kappa* de 0,75. Na segunda abordagem determinamos que o índice espectral *Chlorophyll Vegetation Index* (CVI) é a alternativa de melhor acurácia (R^2 de 0,81 e Raiz do Erro Quadrático Médio - REQM) de 0,942 g.kg⁻¹) entre os índices testados para inferir o teor de nitrogênio foliar em laranjeiras-valência. Concluímos que é possível estabelecer relações precisas entre o teor de nitrogênio foliar quantificado em laboratório e a resposta espectral da planta registrada na imagem. Assim, imagens multiespectrais de alta resolução espacial são eficientes para discriminar os teores de nitrogênio foliar em laranjeiras-valência. A abordagem investigada mostrou resultados superiores aos métodos previamente avaliados na literatura.

Palavras-chave: Aeronaves Remotamente Pilotadas; Agricultura de Precisão; Classificação de Imagens; Índices Espectrais de Vegetação.

ABSTRACT

Inference of leaf nitrogen content in orange trees with high spatial resolution multispectral images

Nitrogen plays a fundamental role in the photosynthetic activity of plants, and its analysis is essential for the management of agricultural crops. One way of obtaining fast and inexpensive information on this nutrient is through multispectral image processing. Applications with images acquired by sensors on board of Remotely Piloted Aircrafts (RPA) have increased in Precision Agriculture. However, in citrus plants, in specific orange trees, little is known about the potential of multispectral images acquired with ARPs in the inference of leaf nitrogen content. Considering this context, the objective of this research was to evaluate the potential of multispectral images with high spatial resolution to infer the leaf nitrogen content in valencia-orange. As a method, we apply two approaches to infer the content of leaf nitrogen: (1) classification of images and; (2) spectral indices. In order to do this, we conducted an experiment in a valencia-orange orchard (Citrumelo Swingle rootstock) and collected leaves from different fields of the plantation. We conducted a flight with an eBee SenseFly ARP, equipped with the Parrot Sequoia camera, which records bands in the green, red, red-edge and near-infrared regions with a Ground Sample Distance (GSD) of 12 cm. In the first approach, we determined that the Spectral Angle Mapper (SAM) (r) classification algorithm had the best performance when classifying leaf nitrogen, with an overall accuracy of 85.7% and a *kappa* coefficient of 0.75. In the second approach, we determined that the spectral index Chlorophyll Vegetation Index (CVI) is the most accurate alternative (R^2 of 0.81 and Root Mean-Squared Error - RMSE) of 0.942 g.kg^{-1}) among the indices tested to infer the leaf nitrogen content in valencia-orange. We conclude that it is possible to establish precise relationships between the foliar nitrogen content measured in the laboratory with the spectral response of the plant recorded in the image. Thus, multispectral images of high spatial resolution are efficient to discriminate levels of leaf nitrogen in valencia-orange. The approach investigated showed superior results in methods previously evaluated in literature.

Keywords: Remotely Piloted Aircraft; Precision Agriculture; Image Classification; Vegetation Spectral Indices.

LISTA DE SIGLAS

ARP	Aeronave Remotamente Pilotada
ARVI2	Atmospherically Resistant Vegetation Index 2
AUC	Area Under the Curve
CCCI	Canopy Chlorophyll Content Index
CEM	Constrained Energy Minimization
CG	Chlorophyll Green
Clgreen	Chlorophyll Index Green
Clrededge	Chlorophyll Index RedEdge
Ctr2	Simple Ratio 695/760 Carter2
CTVI	Corrected Transformed Vegetation Index
CVI	Chlorophyll Vegetation Index
DECEA	Departamento de Controle do Espaço Aéreo
FOV	Field of View
GDVI	Green Difference Vegetation Index
GI	Simple Ratio 554/677 Greenness Index
GNDVI	Normalized Difference NIR/Green NDVI
GNSS	Global Navigation Satellite System
GRNDVI	Green-Red NDVI
GSAVI	Green Soil Adjusted Vegetation Index
GSD	Ground Sample Disntace
HCRF	Hemispherical Conical Reflectance Factor
IBGE	Instituto Brasileiro de Geografia e Estatística
IPVI	Infrared Percentage Vegetation Index
LAI	Leaf Area Index
LSSVM	Least Squares Support Vector Machine
LSU	Linear Spectral Unmixing
MCARI1	Modified Chlorophyll Absorption in Reflectance Index 1
MD	Minimum Distance
MDE	Modelo Digital de Superfície
MSAVI	Modified Soil Adjusted Vegetation Index
MSC	Multiplicative Scatter Correction
MSR	Modified Simple Ratio

MTMF	Mixture Tuned Matched Filtering
MTVI	Modified Triangular Vegetation Index
ND	Número Digital
ND682/553	Normalized Difference 682/553
NDVI	Normalized Difference Vegetation Index
Norm G	Normalized Green
Norm NIR	Normalized Near Infrared
Norm R	Normalized Red
OSAVI	Optimized Soil Adjusted Vegetation Index
OSP	Orthogonal Subspace Projection
PLS	Partial Least Squares
PPP	Posicionamento por Ponto Preciso
PVA4	Argissolos Vermelho-Amarelo Abrupto
RDVI	Renormalized Difference Vegetation Index
REQM	Raiz do Erro Quadrático Médio
RNN	Redes Neurais Artificiais
ROC	Receiver Operating Characteristic
RTK	Real Time Kinematic
SAM	Spectral Angle Mapper
SAVI	Soil-Adjusted Vegetation Index
SID	Spectral Information Divergence
SMLR	Stepwise Multiple Linear Regression
SNV	Standard Normal Variable
SR	Simple Ratio
SR672/550	Simple Ratio 672/550 Datt5
SR750/550	Simple Ratio 750/550 Gitelson and Merzlyak 1
SR800/550	Simple Ratio 800/550
SVM	Support Vector Machine
TraVI	Transformed Vegetation Index
TriVI	Triangular Vegetation Index
VIN	Vegetation Index Number
WDRVI	Wide Dynamic Range Vegetation Index

LISTA DE FIGURAS

FIGURA 1 –	Fluxo de trabalho dos processamentos realizados neste estudo..	26
FIGURA 2 –	Área de interesse e pontos amostrados durante a campanha de campo	27
FIGURA 3 –	Histograma de distribuição de refletância das curvas espectrais .	34
FIGURA 4 –	Assinatura espectral do nitrogênio foliar e as curvas espectrais simuladas	36
FIGURA 5 –	Demonstração da eficiência dos diferentes algoritmos de classificação	38
FIGURA 6 –	Curva ROC e AUC construída para cada um dos classificadores testados.....	40
FIGURA 7 –	Classificação de imagens da câmera Parrot Sequoia utilizando o SAM.....	41
FIGURA 8 –	Principais características observadas na imagem classificada com SAM.....	42
FIGURA 9 –	Fluxo de trabalho contendo as etapas empregadas neste estudo	49
FIGURA 10 –	Área de estudo e pontos utilizados na avaliação dos índices espectrais	50
FIGURA 11 –	Vista em campo das laranjeiras (a, b) e a vista aérea (c).....	51
FIGURA 12 –	Representação das refletâncias médias em função do teor de nitrogênio foliar em laranjas-valência	55
FIGURA 13 –	Distribuição dos pontos de amostragem espectral em função do teor de nitrogênio foliar	57
FIGURA 14 –	Dispersão para a validação-cruzada dos índices espectrais.....	60
FIGURA 15 –	Matriz de correlação entre os índices espectrais testados neste estudo.....	62
FIGURA 16 –	Dispersão para a validação das combinações de índices	63
FIGURA 17 –	Inferência do teor de nitrogênio foliar em citrus a partir do índice CVI	65

LISTA DE TABELAS

TABELA 1 –	Descrição dos algoritmos de classificação testados neste estudo.....	32
TABELA 2 –	Comparação entre a refletância das curvas reais e simuladas....	34
TABELA 3 –	Comparativo entre a assinatura espectral e a curva espectral simulada.....	37
TABELA 4 –	Performance dos classificadores de acordo com a referência terrestre.....	39
TABELA 5 –	Matriz de confusão e erros de omissão e comissão da classificação SAM.....	41
TABELA 6 –	Descrição dos índices espectrais de vegetação utilizados neste estudo	53
TABELA 7 –	Análise de regressão entre os índices espectrais e o teor de nitrogênio	58
TABELA 8 –	Validação-cruzada entre os índices espectrais analisados neste estudo	59
TABELA 9 –	Análise de regressão das melhores combinações de índices espectrais.....	63
TABELA 10 –	Validação-cruzada entre as combinações de índices espectrais.	63

SUMÁRIO

1	INTRODUÇÃO GERAL	12
1.1	Sensoriamento Remoto na Agricultura de Precisão	15
1.2	Inferência do Nitrogênio em Plantas por Sensoriamento Remoto	17
1.3	Aplicações de Sensoriamento Remoto em Plantas Cítricas	19
2	CAPÍTULO I	22
2.1	Introdução	23
2.2	Materiais e Métodos	25
2.2.1	Levantamento dos dados em campo.....	26
2.2.2	Processamento das curvas espectrais e análise química do tecido foliar	28
2.2.3	Processamento das imagens multiespectrais.....	30
2.3	Resultados e Discussão	32
2.3.1	Classificação de imagens por algoritmos de análise espectral.....	36
2.4	Conclusões	43
3	CAPÍTULO II	45
3.1	Introdução	46
3.2	Materiais e Métodos	48
3.2.1	Levantamento dos dados em campo.....	49
3.2.2	Processamento das imagens e amostragem espectral nos pontos.....	51
3.2.3	Cálculo e validação dos índices espectrais	52
3.3	Resultados e Discussão	55
3.3.1	Validação-cruzada dos índices espectrais individuais e combinados.....	57
3.4	Conclusões	66
4	CONCLUSÃO GERAL	67
	REFERÊNCIAS	69
	ANEXO A – Relatório do Posicionamento por Ponto Preciso	80
	ANEXO B – Comprovante de Autorização do Voo	82
	ANEXO C – Relatório de Qualidade do Processamento de Imagem	83
	ANEXO D – Resultados da Análise de Tecido Vegetal	107

1 INTRODUÇÃO GERAL

A laranja representa uma parcela importante da economia agrícola do país. No cenário mundial, o Brasil se sobressai como o principal produtor de suco, participando em 76% do comércio internacional (USDA, 2017). A produção ocorre principalmente no estado de São Paulo e no Triângulo Mineiro, onde estão espalhadas 12 mil fazendas, com cerca de 191,69 milhões de árvores das principais variedades e ocupando área total de 450 mil hectares (NEVES; TROMBIN, 2017). Para alcançar uma produção eficaz, garantindo a liderança de mercado, é exigido dos produtores o manejo adequado de seus pomares. Neste caso, o monitoramento do nitrogênio é fundamental, uma vez que o nutriente auxilia no desenvolvimento foliar e na atividade fotossintética da planta, influenciando a produtividade das plantas (STELLACCI *et al.*, 2016).

Na ausência do nitrogênio, a planta apresenta sintomas que revelam sua deficiência, principalmente na folhagem (HOLZAPFEL *et al.*, 2009). Esse nutriente é comumente aplicado em campos agrícolas, e os produtores acabam por colocá-lo em excesso por não conhecer a quantidade necessária (WANG *et al.*, 2017). Tal prática pode causar impactos à própria plantação, causando a sua intoxicação, e ao meio ambiente por meio dos processos de lixiviação e volatilização da parcela não absorvida (CILIA *et al.*, 2014). Para contornar isso, os produtores rurais se pautam em métodos de análise foliar para determinar o teor do nutriente na planta, e manejar a fertilização.

Como método tradicional, é realizado a coleta e a análise laboratorial de folhas com a finalidade de representar a área manejada. O ideal é que essas análises sejam feitas com uma certa frequência ao decorrer do ano. Contudo, isso demanda custos e tempo que, em certos casos, são inviáveis aos produtores (HUERTA *et al.*, 2013). Como alternativa para aumentar a frequência de monitoramento, métodos não destrutivos, envolvendo o uso de dados espectrais coletados por sensores remotos, surgem como uma proposta (CONNELL *et al.*, 2014).

A detecção de variações do nitrogênio em culturas agrícolas a partir de dados espectrais, além de consistir em um método não destrutivo, possibilita avaliar a deficiência e o excesso do nutriente na planta, reduzindo aplicações desnecessárias (CILIA *et al.*, 2014). Vários estudos comprovam a versatilidade de se

monitorar o nitrogênio em culturas agrícolas a partir de dados hiperespectrais ou multiespectrais (HE *et al.*, 2016; KNYAZIKHIN *et al.*, 2012; PERRY *et al.*, 2012; THOMASON *et al.*, 2011). Esses dados, coletados a partir de sensores remotos, permitem estabelecer relação entre os pigmentos e o nitrogênio foliar, possibilitando inferir a quantidade do nutriente (SCHLEMMER *et al.*, 2013; SULTANA *et al.*, 2014).

Sensores hiperespectrais se destacam por possuírem bandas com alta resolução espectral, ou seja, que descrevem detalhadamente as parcelas do espectro eletromagnético (HE *et al.*, 2016). Sensores multiespectrais por sua vez, são utilizados com maior frequência, pois são economicamente viáveis e mais acessíveis do que os hiperespectrais (MULLA, 2016). Assim, cresce a necessidade de se avaliar o potencial dos dados multiespectrais, calibrados com dados de campo (MAIMAITIJIANG *et al.*, 2017), na área da Agricultura de Precisão.

Os sensores podem ser embarcados em diferentes plataformas, sejam estas terrestres, aéreas e orbitais. Entretanto, e recentemente, as ARPs (Aeronaves Remotamente Pilotadas) vêm se destacando para as atividades de monitoramento de culturas agrícolas. Essas aeronaves otimizaram o processo de aquisição de imagens com alta resolução espacial (RAMOELO *et al.*, 2012; XU *et al.*, 2018), sendo, ainda, de baixo custo operacional.

Em nível foliar, a análise de dados hiperespectrais mostrou resultados satisfatórios para as culturas da beterraba (JAY *et al.*, 2017), do arroz (MAHAJAN *et al.*, 2017; MOHARANA; AHMED, 2010), da pera (WANG *et al.*, 2017), do algodão (MUHARAM *et al.*, 2015; ZHAO *et al.*, 2010), da cana-de-açúcar (MIPHOKASAP; WANNASIRI, 2018) e do trigo (HE *et al.*, 2016; LI *et al.*, 2018; THOMASON *et al.*, 2011). No caso de sensores multiespectrais, ao nível de dossel, diferentes pesquisas avaliaram o nitrogênio foliar em milho (CILIA *et al.*, 2014), trigo (ZHENG *et al.*, 2018); algodão (RAPER; VARCO, 2015), soja (SONG; WANG, 2016), arroz (HUANG *et al.*, 2017), citrus (XUEFENG *et al.*, 2016), dentre outras. Isso demonstra o alcance do Sensoriamento Remoto na estimativa do nitrogênio foliar em culturas.

Em plantas cítricas, a avaliação de dados espectrais tem proporcionado resultados promissores, como a implementação de índices espectrais na detecção de estresse hídrico e da produtividade de laranjeiras (STAGAKIS *et al.*, 2012). Outros índices espectrais, em conjunto com algoritmos de aprendizagem em máquina, foram utilizados para a identificação de laranjeiras que apresentavam *greening* (RUIZ *et al.*, 2013). Ainda em relação ao *greening*, outro estudo analisou as

diferenças espectrais dessa doença em laranjeiras por meio de algoritmos não-paramétricos, como o SVM (*Support Vector Machine*), e de outros menos complexos, como o *Minimum Distance* e o *Mahalanobis Distance*, demonstrando a adequabilidade dos mesmos (LI *et al.*, 2012).

Na última década, a quantidade de pesquisas relacionadas a inferência do nitrogênio foliar em culturas agrícolas cresceu. Porém, poucas pesquisas avaliaram o nitrogênio em laranjeiras por meio de dados espectrais adquiridos por sensores. A primeira aproximação consiste-se em uma análise hiperespectral da absorvância, na região do visível e do infravermelho (415-2485 nm) (MIN; LEE, 2005). Nesse estudo, os autores investigaram a potencialidade de duas técnicas quimiométricas: SMLR (*Stepwise Multiple Linear Regression*) e PLS (*Partial Least Squares*). Concluíram que a PLS é a mais indicada na inferência do nitrogênio, com um coeficiente de regressão (R^2) de 0,828 e Raiz do Erro Quadrático Médio (REQM) de 0,122%. Ademais, apontam que os comprimentos de onda 448, 669, 719, 1377, 1773 e 2231 nm são considerados mais adequados para identificar o teor do nutriente em laranjeiras-valência.

Na análise de imagens multiespectrais, obtidas com sensor embarcado em ARP, um estudo (XUEFENG *et al.*, 2016) avaliou o nitrogênio foliar em laranjeiras-de-sangue. Os autores utilizaram dois métodos de pré-processamento, sendo o MSC (*Multiplicative Scatter Correction*) e o SNV (*Standard Normal Variable*); e dois métodos de modelagem, correspondendo ao PLS e ao LSSVM (*Least Squares Support Vector Machine*). Concluíram que o PLS, com base em MSC, foi o melhor método de previsão do nitrogênio foliar, com R^2 de 0,647 e REQM de 0,130. No entanto, apontam que as partículas em suspensão e as diferenças na geometria de iluminação causaram problemas na análise realizada. Ao final, esses mesmos autores sugerem que novos estudos avaliem formas de reduzir esses problemas, assim como melhorar a acurácia de dados adquiridos em maior resolução espacial, em ARP, em plantas cítricas.

Diante do contexto apresentado, ainda se sabe pouco sobre o potencial das imagens multiespectrais de alta resolução espacial, adquiridas por sensores em ARPs, para a avaliação do teor de nitrogênio foliar em plantas cítricas, sobretudo, em laranjeiras-valência, que representam uma vasta parcela do gênero citrus produzido. Assim, o objetivo deste estudo foi avaliar o potencial de imagens multiespectrais de alta resolução espacial para inferir o teor de nitrogênio foliar em

laranjeiras-valência. Para alcançar esse objetivo, propomos: I) avaliar o desempenho de algoritmos de classificação de imagens treinados a partir de curvas espectrais para determinar o teor de nitrogênio foliar em laranjeiras-valência e; II) determinar o potencial de índices espectrais de vegetação em estimar o teor de nitrogênio foliar em laranjeiras-valência.

1.1 Sensoriamento Remoto na Agricultura de Precisão

As culturas agrícolas ao redor do mundo se encontram sobre a ameaça de pragas, espécies invasivas, aumento da salinidade do solo e da água, queimadas, manejo inadequado, além de outros fatores que são responsáveis por sua degradação (MULLA, 2013). A adoção de técnicas comumente utilizadas por profissionais da área agrônômica, são voltadas para a identificação e recuperação das condições sadias ou adequadas das culturas afetadas por esses problemas (ZHAI *et al.*, 2013). Um pré-requisito para a sustentabilidade das culturas é o monitoramento, incluindo a análise das propriedades composicionais, estruturais e funcionais da planta (CONNELL *et al.*, 2014). Recentemente, o desenvolvimento de geotecnologias tem aprimorado práticas de monitoramento da vegetação em diversas escalas de abordagem (JENSEN, 2014).

Os pesquisadores têm obtido avanços significativos no monitoramento das condições da vegetação, com o objetivo de desenvolver sensores e algoritmos de processamento digital de imagens, possibilitando extrair informações biofísicas com o Sensoriamento Remoto (JENSEN, 2014). As técnicas de Agricultura de Precisão, direcionadas para a observação e a análise da vegetação, encontraram no Sensoriamento Remoto uma possibilidade emergente na análise e no suporte do monitoramento de culturas (MELESSE *et al.*, 2007). Essa integração é importante, pois permite: a) o estudo da fenologia de determinada vegetação; b) o monitoramento das condições nutricionais da planta; c) avaliações de produtividade; entre outros (HOLZAPFEL *et al.*, 2009).

As geotecnologias possibilitam ao seu usuário analisar dados remotos e produzir mapas contendo a variabilidade espacial dos fatores da produção agrícola, auxiliando o gerenciamento de áreas cultivadas e otimizando a eficiência do manejo dessas áreas (JAY *et al.*, 2017). Dados espectrais, de Sensoriamento Remoto, podem ser transformados em índices espectrais de vegetação ou em imagens

classificadas, dos quais possibilitam ao produtor rural identificar as condições nutricionais da sua cultura (JENSEN, 2014). No entanto, é importante mencionar que o comportamento espectral dos alvos e a escala de trabalho estão sujeitos a variações provocadas pela arquitetura do dossel e pela geometria de visada do sensor e de iluminação da área, além de outros fatores, diferenciando de cultura para cultura (WANG *et al.*, 2017).

Cálculos envolvendo bandas multiespectrais e hiperespectrais permitem determinar características da vegetação e, na maioria dos casos, avaliar o seu estado fitossanitário (SULTANA *et al.*, 2014). A análise de dados espectrais é empregada na estimativa de área foliar, biomassa, radiação fotossinteticamente ativa, assim como das condições nutricionais e fisiológicas de uma planta (MULLA, 2013). O fluxo de radiação, ao interagir com a vegetação, apresenta alterações que variam em relação a capacidade das folhas em absorver, transmitir ou refletir a energia recebida. Essa relação com a vegetação varia conforme o seu tipo, a densidade e as suas condições fisiológicas, além do comprimento de onda recebido (CONNEL *et al.*, 2014).

No comportamento espectral da vegetação, valores maiores de radiação refletidos pelas folhas na região do infravermelho-próximo indicam uma planta mais sadia (RAMOELO *et al.*, 2012). Contudo, mesmo que os dados espectrais ofereçam aplicações variadas para os estudos da vegetação, a obtenção de correlações mais precisas entre a resposta espectral registrada nas imagens e os sistemas biofísicos é, ainda, um desafio para as pesquisas sobre o tema (JENSEN, 2014).

Conforme apontado, a resposta espectral pode ser influenciada por uma série de fatores, como as características do sensor, as condições climáticas locais, e as características da própria planta (LI *et al.*, 2012). Além disso, as imagens de Sensoriamento Remoto são afetadas pelo comportamento da atmosfera ou mesmo por seu processo de aquisição. Por essa razão, as imagens devem ser calibradas utilizando dados coletados em campo (denominados referência terrestre), para que possam caracterizar o alvo estudado com maior confiabilidade (JENSEN, 2014).

Como práticas mais recentes da integração de dados de Sensoriamento Remoto com a Agricultura de Precisão tem-se o uso de câmeras e sensores, multi ou hiperespectrais, na aplicação de diferentes abordagens. Dentre essas abordagens se destacam a avaliação de estresse hídrico em plantas (MATESE *et al.*, 2018), a avaliação da quantidade de clorofila (ATZBERGER *et al.*, 2010), a

identificação de doenças e infestações (RUIZ *et al.*, 2013) e também a avaliação do teor de nitrogênio foliar (CILIA *et al.*, 2014; MIN; LEE, 2005; XUEFENG *et al.*, 2016).

A deficiência de nitrogênio foliar é preocupante, e tem sido monitorada constantemente por meio de técnicas agronômicas mais tradicionais, que envolvem a coleta de um número de folhas representativas da plantação (MIN; LEE, 2006). Por meio de técnicas desenvolvidas com sensores, é possível inferir o teor de nitrogênio foliar a partir de métodos denominados “não-destrutivos” (HUERTA *et al.*, 2013), que apresentam como vantagens a agilidade e o custo relativamente baixo na análise do nutriente (MUHARAM *et al.*, 2015). Assim, várias técnicas têm sido implementadas por meio do processamento digital de imagens, adquiridas com sensores a bordo de plataformas aéreas ou orbitais (RAMOELO *et al.*, 2012), e por dados hiperespectrais adquiridas com espectroradiômetros, em campo ou em condições controladas (ZHAI *et al.*, 2013).

1.2 Inferência do Nitrogênio em Plantas por Sensoriamento Remoto

O nitrogênio é comumente aplicado em solos agricultados, uma vez que promove um melhoramento significativo da cultura e das taxas de produtividade (LEMAIRE *et al.*, 2008). Apesar de serem conhecidas as dosagens adequadas para a aplicação de fertilizantes em várias culturas e pomares, os proprietários acabam por administrar, continuamente, dosagens maiores do que recomendadas (SCHRODER *et al.*, 2000). Essa prática deve ser evitada para reduzir os impactos ambientais. Ainda que o nitrogênio promova o desenvolvimento da planta, a parcela não absorvida pode ser lixiviada no solo, ou volatizada para a atmosfera (JONES *et al.*, 2007; MELLISSE *et al.*, 2007). Outro problema causado pelo excesso do nutriente é a toxicidade para a própria planta, levando a reduzir a sua produtividade (CILIA *et al.*, 2014).

A deficiência do nitrogênio provoca um amarelamento uniforme na folha alterando, assim, a clorofila e o comportamento espectral da planta (JAY *et al.*, 2017). O nitrogênio, também, participa da construção da auxina, auxiliando no crescimento foliar e influenciando a biomassa acumulada na planta, outro fator determinante da presença do nutriente (CONNELL *et al.*, 2014). Devido ao papel desempenhado pelo nitrogênio, pesquisadores têm buscado práticas que melhorem o seu aproveitamento, e que agilizem na recomendação de adubação, assim como

reduzindo a quantidade aplicada (KALACSKA *et al.*, 2015). Essas práticas, por sua vez, devem levar em consideração a fenologia da planta, e inferir o nitrogênio nos diferentes estágios do seu ciclo fenológico (MULLA, 2013; JENSEN, 2014).

A detecção do teor de nitrogênio em culturas agrícolas a partir de dados espectrais tem-se mostrado uma maneira segura e não destrutiva de se avaliar a deficiência do nutriente em plantas, reduzindo a necessidade de se administrar aplicações em excesso e otimizando a análise em diferentes épocas do ano (CILIA *et al.*, 2014) Conforme apontado, o nitrogênio é determinado a partir de experimentos realizados em campo (coleta) e laboratoriais (análise química), o que demanda tempo e custos. Assim, a estimativa do nitrogênio por dados espectrais tem-se mostrado um método promissor na detecção indireta das características fisiológicas da vegetação (MISTELE; SCHMIDHALTER, 2008). Porém, a detecção do nutriente em plantações deve ser avaliada para cada cultura (HOULES *et al.*, 2007) e, especialmente, quando se propõe a realização deste processo por imagens de Sensoriamento Remoto.

A relação entre os pigmentos foliares e o teor de nitrogênio incorporado na estrutura molecular da folha permitem o uso de dados espectrais para determinar as condições das plantas com base em imagens, sejam estas multi ou hiperespectrais (SCHLEMMER *et al.*, 2013; SULTANA *et al.*, 2014). Os sensores hiperespectrais se destacam por possuírem alta resolução espectral, descrevendo detalhadamente as parcelas do espectro eletromagnético (JAY *et al.*, 2017). Sensores multiespectrais, por sua vez, são utilizados com maior frequência, uma vez que são economicamente mais viáveis e acessíveis (CILIA *et al.*, 2014; PERRY *et al.*, 2012). Por essa razão há uma necessidade em se avaliar os dados de sensores multiespectrais em estimativas das condições fitossanitárias de culturas agrícolas, atrelando-os a dados empiricamente comprovados (LI *et al.*, 2012).

Recentemente, o uso de sensores para a identificação do nitrogênio em culturas recebeu diferentes abordagens. Uma dessas abordagens é a comparação de índices espectrais de vegetação para determinar o teor do nutriente em folhas de trigo (CAMMARANO *et al.*, 2014). Isso permitiu concluir que os valores do nutriente, em nível foliar, foram melhores relacionados com os dados espectrais que utilizavam a borda-do-vermelho e o infravermelho-próximo em seu cálculo. Os índices também têm sido avaliados em outras culturas, como o milho (CHEN *et al.*, 2014). Nesse caso, além de comprovar o potencial de índices ao estimar o nitrogênio, também foi

possível determinar a relação do nutriente com o padrão reflexivo dessas plantas, tendo por finalidade propor novos índices para a sua estimativa.

Uma geotecnologia recentemente utilizada para o monitoramento e a avaliação de culturas agrícolas são as Aeronaves Remotamente Pilotadas (ARPs). As ARPs permitem embarcar sensores ou câmeras que realizam o imageamento de áreas à uma baixa altitude, com alto nível de detalhe espacial. Pouco é conhecido a respeito do potencial desta geotecnologia para a estimativa do teor de nitrogênio em plantas (XUEFENG *et al.*, 2016). As câmeras a bordo dos ARPs, além de adquirirem imagens de alta resolução espacial, são livres de certos efeitos atmosféricos, como o espalhamento de luz, que contribui com a luz dispersa captada pelo sensor (JENSEN, 2014). Essas vantagens permitem resultados interessantes para o monitoramento de áreas agrícolas, e isso é reforçado pela quantidade e variedade das aplicações até então empregadas (BASSO *et al.*, 2016; MIPHOKASAP e WANNASIRI, 2018).

Em suma, os dados multiespectrais e hiperespectrais para a avaliação e monitoramento agrícola, embora com certas limitações, são uma alternativa de alta potencialidade ao diagnóstico de culturas (NOVOTNÁ *et al.*, 2013). O uso desses dados permite obter informações rapidamente, de maneira constante, e oferecem, ainda, relativamente baixo custo na execução, tendo em vista os gastos e tempos despendidos com outros métodos (TEAL *et al.*, 2006; SULTANA *et al.*, 2014). Para tanto, entende-se que essas pesquisas se encontram em evolução (JENSEN, 2014), e é reconhecido que a interação do Sensoriamento Remoto com outras áreas do conhecimento pode contribuir para o avanço de novos estudos (JAY *et al.*, 2017).

1.3 Aplicações de Sensoriamento Remoto em Plantas Cítricas

O uso de dados de Sensoriamento Remoto em plantas cítricas, mais especificamente em laranjeiras, cresceu a partir das últimas décadas, uma vez que os avanços na tecnologia de sensores proporcionaram a aquisição de bandas multi e hiperespectrais com mais facilidade (DZIKITI *et al.*, 2011). O desenvolvimento desses sensores possibilitou o emprego de diferentes abordagens na Agricultura de Precisão, relacionadas aos problemas comumente encontrados em plantas cítricas. Quanto a isso, destacam-se as aplicações na detecção do estresse hídrico (JOHNSON *et al.*, 2013), do *greening* (RUIZ *et al.*, 2013), da deficiência nutricional

(MENESATTI *et al.*, 2010), da salinidade (ROMERO-TRIGUEROS *et al.*, 2016) e também na identificação de invasão por plantas daninhas (YE *et al.*, 2007).

Além da detecção de problemas, outras pesquisas mais direcionadas para a caracterização das laranjeiras, também foram desenvolvidas nos últimos anos. Como exemplos deve-se destacar os estudos voltados ao monitoramento do teor de nitrogênio foliar (XUEFENG *et al.*, 2016), à quantidade de água presente e utilizada pela planta (DZIKITI *et al.*, 2011), à quantidade de açúcar (LUO *et al.*, 2011), e do conteúdo de sólidos solúveis (LIU *et al.*, 2010). A diversidade dessas análises tem demonstrado o potencial dos sensores na avaliação dessas plantas, sejam ao nível terrestre, com espectralímetros de campo, ou mesmo ao nível aéreo, embarcados em ARPs.

Um estudo utilizou dados de sensores para interpretar as características fisiológicas de plantas cítricas ao decorrer do seu ciclo fenológico (STUCKENS *et al.*, 2011). Imagens aéreas também foram utilizadas para se extrair a copa de árvores em pomares, o que tem permitido identificar uma fração de sua cobertura, o número de árvores, assim como os padrões de plantio empregues (RECIO *et al.*, 2013). Esse último estudo buscou extrair as copas por meio de processos morfológicos envolvendo imagens binárias. Entretanto, outras análises têm envolvido o uso de classificações orientadas ao objeto, com auxílio de algoritmos de aprendizagem de máquina, para extrair as laranjeiras a partir de índices espectrais de vegetação, como por exemplo o NDVI (*Normalized Difference Vegetation Index*) (LÓPEZ *et al.*, 2011).

O uso de algoritmos de classificação para se avaliar plantas cítricas tem sido pouco aplicado em estudos envolvendo imagens multi e hiperespectrais. Essa aproximação foi utilizada para detectar infestações por *greening* em laranjeiras por meio de algoritmos de aprendizagem em máquina (RUIZ *et al.*, 2013). Nesse caso, o SVM com *kernel* obteve o melhor resultado entre quatro algoritmos testados. Ainda com relação ao *greening*, outro estudo demonstrou que o SVM permitiu separar as árvores infectadas das plantas saudáveis, e que algoritmos de análise espectral, como SAM (*Spectral Angle Mapper*), SID (*Spectral Information Divergence*), *Mahalanobis Distance*; *Minimal Distance*, *Parallelepiped*, entre outros, conseguiram diferenciar os níveis de infestação (LI *et al.*, 2012).

Índices espectrais, por sua vez, também foram aplicados na avaliação de pomares de plantas cítricas. Um exemplo disso é o uso de índices espectrais de

avaliação estrutural e fisiológica para investigar o conteúdo de água e os efeitos do seu estresse na qualidade de frutas cítricas (STAGAKIS *et al.*, 2012). Além disso, o índice NDVI foi relacionado com trocas gasosas realizadas entre diferentes espécies de laranjeiras, enquanto as bandas espectrais do vermelho e infravermelho-próximo, utilizadas no índice, foram relacionadas com a quantidade de clorofila e a pressão potencial nessas plantas (ROMERO-TRIGUEROS *et al.*, 2016).

Ainda assim, outras técnicas têm sido implementadas no Sensoriamento Remoto de plantas cítricas, como é o caso das técnicas quimiométricas. O emprego dessas técnicas tem sido utilizado na avaliação do teor de nitrogênio foliar, permitindo destacar os comprimentos de onda que melhor se relacionam com o nutriente (MIN; LEE, 2005). Um outro estudo avaliou a performance de uma técnica quimiométrica em comparação com o SVM para detectar o nitrogênio foliar, e determinou que a técnica quimiométrica foi superior (XUEFENG *et al.*, 2016). Além disso, outras técnicas de pré-processamento foram avaliadas para inferir o conteúdo de açúcar em laranjeiras, como a primeira e a segunda derivadas dos dados espectrais (LUO *et al.*, 2011). Não obstante, diferentes aplicações ainda devem ser empregadas na análise de plantas cítricas, com o intuito de otimizar os resultados atingidos até o momento.

2. CAPÍTULO I: Classificação de Imagens Multiespectrais de Alta Resolução Espacial para Inferir o Teor de Nitrogênio Foliar em Laranja-Valência

Resumo

O nitrogênio é um dos principais nutrientes para a produção de plantas cítricas. Porém, quando em excesso, provoca impactos à planta e ao meio ambiente. Para determinar a quantidade de nitrogênio necessário, produtores tem recorrido à análise química do tecido foliar. Contudo, uma alternativa mais rápida é análise de dados espectrais, que tem sido implementada em várias culturas. Em laranjeiras, a capacidade de sensores multiespectrais em determinar o teor de nitrogênio foliar ainda é pouco explorada. Esta pesquisa propôs uma metodologia que determina o nitrogênio foliar em laranjeiras a partir da classificação da resposta espectral do nitrogênio foliar em imagens de alta resolução espacial. Para isso, realizamos a medida espectral de laranjeiras com um espectroradiômetro de campo e adquiramos as imagens multiespectrais com uma câmera embarcada em uma Aeronave Remotamente Pilotada (ARP). Definimos três limiares para o teor de nitrogênio foliar em laranjeiras (baixo, médio e alto), e caracterizamos a assinatura espectral com base nesses limiares. Realizamos a simulação de bandas utilizando os intervalos espectrais das imagens adquiradas com a câmera Parrot Sequoia. Testamos sete algoritmos para classificar o teor de nitrogênio foliar nas laranjeiras, utilizando as assinaturas espectrais simuladas como dados de treinamento dos classificadores. Observamos que as bandas da borda-do-vermelho e infravermelho-próximo são mais apropriadas para diferenciar as classes de nitrogênio, e que a banda verde apresentou menor discrepância em diferenciar os teores mais elevados de nitrogênio. O *Spectral Angle Mapper* (SAM) apresentou a maior acurácia (global de 87,6% e coeficiente κ de 0,75) para classificar o teor de nitrogênio foliar em laranjeiras quando comparado com os demais algoritmos. Concluímos que a metodologia proposta, envolvendo a simulação de bandas e o uso de algoritmos baseados no ângulo espectral das curvas, é robusta para a inferência de diferentes classes de nitrogênio foliar em laranjeiras.

Palavras-chave: Aeronave Remotamente Pilotada; Simulação de Bandas Espectrais; Análise Espectral.

Abstract

Nitrogen is one of the main nutrients for the production of citrus plants. However, when in excess, it causes impacts to the plant and the environment. To determine the amount of nitrogen needed, farmers have resorted to chemical analysis of the leaf tissue. However, a faster alternative is their spectral data analysis, which has been implemented in several cultures. In orange trees, the ability of multispectral sensors to determine leaf nitrogen content is still poorly explored. This research proposed a methodology that determines leaf nitrogen content in valencia-orange trees from a spectral response classification of leaf nitrogen in high spatial resolution imagery. To do this, we performed the spectral measurement of orange trees with a field spectroradiometer and acquired the multispectral images with a camera

embedded in a Remotely Piloted Aircraft (RPA). We defined three thresholds for the leaf nitrogen content in orange trees (deficient, médio and excessive), and characterize the spectral signature based on the thresholds. We then perform a band simulation using the spectral ranges of the images acquired with the Parrot Sequoia camera. We tested seven algorithms to classify the leaf nitrogen content using the simulated spectral signatures as training data. We observed that the red-border and near-infrared bands are more appropriate to differentiate the nitrogen classes and that the green band presented less discrepancy in differentiating the higher nitrogen contents. The Spectral Angle Mapper (SAM) resulted in the highest accuracy (overall of 87.6% and kappa coefficient of 0.75) to classify the leaf nitrogen content in orange trees when compared to the other algorithms. We conclude that the proposed methodology, involving the simulation of bands and the usage of algorithms based on the spectral angle of the curves, is robust for the inference of different classes of leaf nitrogen content in valencia-orange trees.

Keywords: Remotely Piloted Aircraft; Simulation of Spectral Bands; Spectral Analysis.

2.1 Introdução

Um dos principais nutrientes para a produção de plantas é o nitrogênio, pois participa da construção da molécula de clorofila e auxilia enzimas relacionadas ao crescimento foliar, influenciando a atividade fotossintética (STELLACCI *et al.*, 2016; GABRIEL *et al.*, 2017). Entretanto, a parcela não absorvida pela planta é um problema, pois pode ser lixiviada ou volatizada, desencadeando impactos ao ambiente (CILIA *et al.*, 2014; HUERTA *et al.*, 2013; AHAMED *et al.*, 2011). Diante disso, os produtores precisam de métodos e técnicas aprimoradas, e voltadas para o monitoramento do nutriente em suas propriedades.

O monitoramento de culturas agrícolas é realizado a partir de métodos tradicionais que consistem na coleta e análise química do tecido foliar. Todavia, esses métodos desencorajam um monitoramento contínuo, pois demandam tempo e custos aos produtores (WANG *et al.*, 2017; HUANG *et al.*, 2014). Desse modo, métodos não-destrutivos de análise foliar surgem como uma alternativa promissora na inferência do nitrogênio foliar em plantações (CONNELL *et al.*, 2014). Os métodos não-destrutivos utilizam dados adquiridos por sensores multi ou hiperespectrais, e consistem-se em uma maneira rápida e não destrutiva de se mensurar o teor de nitrogênio foliar em diferentes culturas (HE *et al.*, 2016; KNYAZIKHIN *et al.*, 2012; PERRY *et al.*, 2012; THOMASON *et al.*, 2011; BASSO *et al.*, 2016; LI *et al.*, 2018).

A abordagem de se inferir o teor de nitrogênio foliar por meio da análise de curvas hiperespectrais tem demonstrado resultados satisfatórios em culturas como da beterraba (JAY *et al.*, 2017); do algodão (MUHARAM *et al.*, 2015); da pera (WANG *et al.*, 2017b), do arroz (MAHAJAN *et al.*, 2017), da cana-de-açúcar (MIPHOKASAP; WANNASIRI, 2018), do milho (GAUTAM; PANIGRASHI, 2007) e do trigo (WANG *et al.*, 2017a). No caso de sensores multiespectrais, a avaliação do nitrogênio foliar apresentou resultados importantes para a soja (SONG; WANG, 2016), o algodão (RAPER; VARCO, 2015) o trigo (ZHENG *et al.*, 2018) o milho (CILIA *et al.*, 2014), o arroz (HUANG *et al.*, 2017), o repolho (MIN; LEE, 2006) e a laranjeira (XUEFENG *et al.*, 2016). Isso demonstra o potencial que diferentes sensores possuem para inferir esse nutriente em culturas agrícolas.

Recentemente, diferentes pesquisas têm empregado ARPs (Aeronaves Remotamente Pilotadas) na avaliação do nitrogênio em plantações, uma vez que as aeronaves permitem embarcar sensores que realizam o imageamento de áreas à uma baixa altitude (XUEFENG *et al.*, 2016). Essas aeronaves possuem vantagens em relação à outras plataformas, como pouca interferência atmosférica e o baixo custo, e isso é reforçado pela variedade de aplicações empregadas até então (BASSO *et al.*, 2016; MIPHOKASAP; WANNASIRI, 2018). Por meio de imagens obtidas com auxílio desses equipamentos, diversas técnicas envolvendo a classificação de pixels têm sido empregadas no monitoramento de culturas agrícolas (LÓPEZ *et al.*, 2011; ZOU *et al.*, 2018; HAMEED *et al.*, 2018).

Diferentes algoritmos de classificação foram testados em plantas cítricas para detectar problemas distintos, como por exemplo na avaliação do estresse hídrico (STAGAKIS *et al.*, 2012), da produtividade (YE *et al.*, 2006) e de diferentes estágios de *greening* (RUIZ *et al.*, 2013; LI *et al.*, 2012). A doença *greening* apresenta sintomas visualmente identificáveis, e essas pesquisas apontaram o algoritmo *Support Vector Machine* como a melhor opção para separar as plantas infectadas das demais (RUIZ *et al.*, 2013). Ainda assim, algoritmos menos robustos, como *Minimum Distance* e *Mahalanobis Distance*, conseguiram resultados satisfatórios ao detectar os diferentes estágios de *greening* em citrus (LI *et al.*, 2012).

No caso de plantas cítricas, em específico laranjeiras, a performance dos métodos de classificação de imagem para inferir o nitrogênio é pouco conhecida. Apenas as técnicas quimiométricas foram empregadas neste tipo de análise, sendo

uma delas em nível hiperespectral (MIN; LEE, 2005) e outra em nível multiespectral, com imagens obtidas com uma câmera embarcada em ARP (XUEFENG *et al.*, 2016). Nesses estudos, a comparação de técnicas resultou no PLS como o método mais adequado para discriminar o teor de nitrogênio foliar, apresentando um R^2 de 0,828 e uma REMQ de 0,122% para as curvas hiperespectrais (MIN; LEE, 2005) e de 0,6469 e REMQ de 0,1296% para as imagens (XUEFENG *et al.*, 2016). Os autores apontam que, na inferência do nitrogênio foliar por meio de imagens multiespectrais, problemas relacionados à geometria de iluminação e às partículas em suspensão reduziram a acurácia dos métodos investigados, e apontam para a necessidade de estudos que melhorem essa acurácia (XUEFENG *et al.*, 2016).

Na avaliação do nitrogênio foliar em citrus, os métodos de classificação foram pouco explorados. Por esses estudos serem escassos, até o momento, existe uma lacuna sobre os métodos que envolvam o uso de curvas espectrais e algoritmos de classificação para se inferir o teor de nitrogênio foliar em laranjeiras. A classificação de imagens a partir de curvas espectrais pode ser uma alternativa interessante para determinar o nitrogênio, permitindo um monitoramento agrícola de maneira rápida e precisa dos pomares.

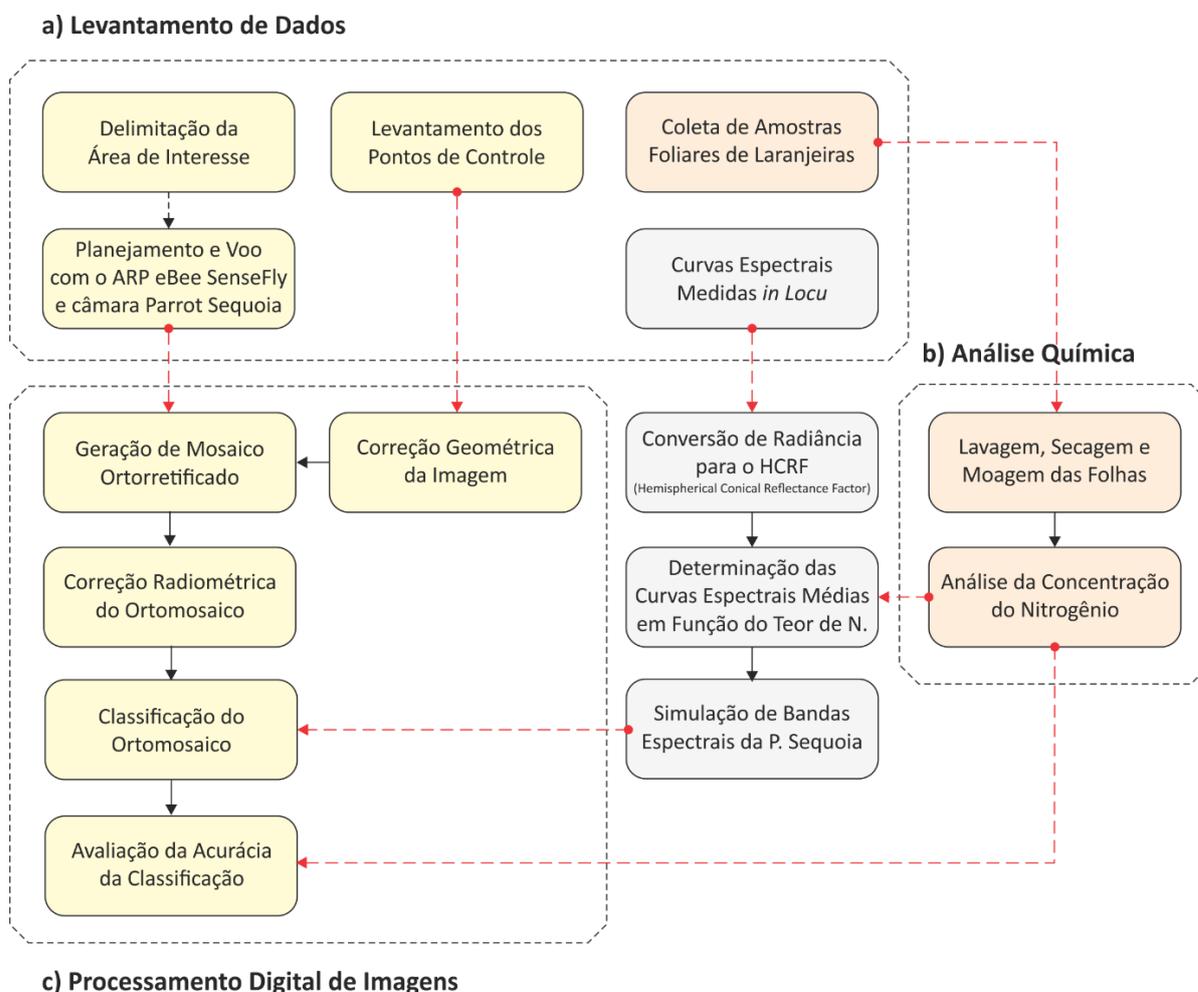
Os estudos discutidos, apesar de indicarem a possibilidade de se inferir o nitrogênio foliar em laranjeiras, apontam para a necessidade de se desenvolver ou aplicar novas técnicas que minimizem os problemas encontrados, e que aumentem a acurácia da inferência do teor de nitrogênio foliar de laranjeiras. Assim, com base na lacuna apresentada, esse trabalho propôs uma metodologia de inferência do teor de nitrogênio foliar em laranjeiras-valência a partir de sua resposta espectral registrada em imagens de alta resolução espacial. O objetivo foi proposto a partir dos seguintes objetivos específicos: I) descrever a resposta espectral do nitrogênio em laranjeiras, e; II) testar se o teor de nitrogênio quantificado em laboratório se relaciona com a refletância de superfície registrada pelas imagens.

2.2 Materiais e Métodos

Conduzimos um estudo de caso em um pomar comercial de laranjeiras-valência e analisamos imagens multiespectrais de alta resolução espacial, obtidas com uma câmera Parrot Sequoia, embarcada em uma ARP eBee SenseFly. O método foi organizado em três fases: a) coleta dos dados em campo; b) análise

química do tecido foliar e; c) processamento digital das imagens e análise dos dados. As etapas específicas de cada fase estão organizadas em um fluxo de trabalho (Figura 1) e detalhadas a seguir.

Figura 1 – Fluxo de trabalho dos processamentos realizados neste estudo.



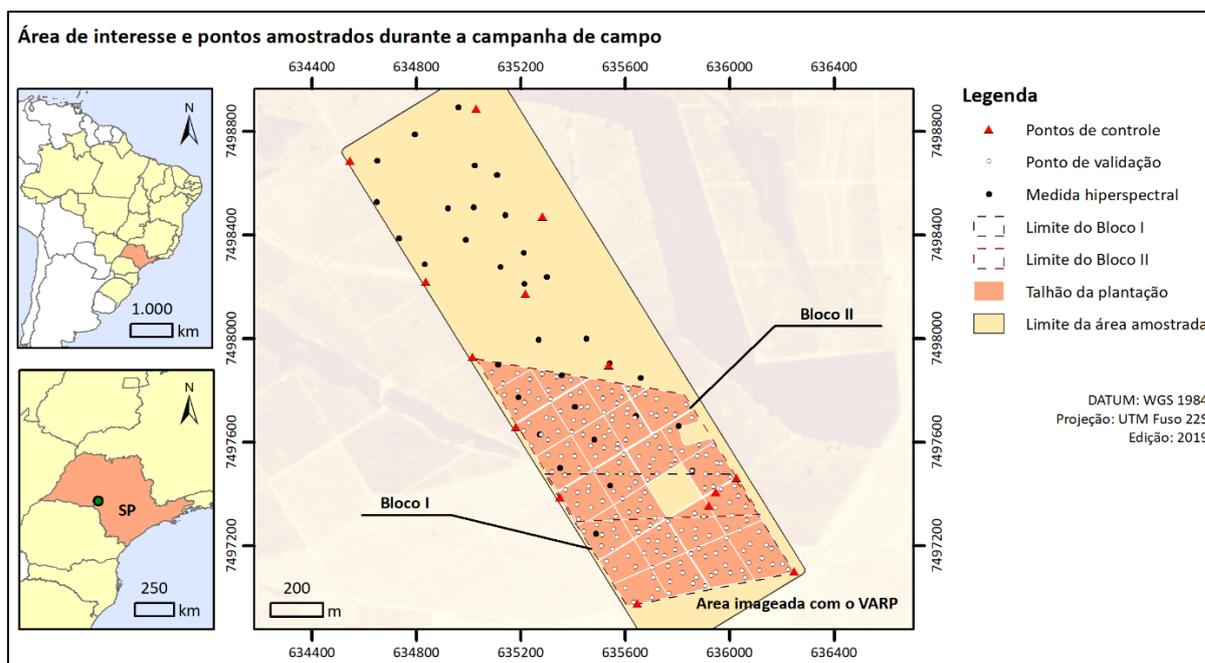
2.2.1 Levantamento dos dados em campo

Realizamos um trabalho de campo no dia 22 de março de 2018, em um pomar de laranjeiras-valência (*Citrus sinensis* Valencia), em porta-enxerto Citrumelo Swingle, em propriedade comercial (Fazenda Brasília) no município de Ubirajara – SP, Brasil (Figura 2). A estação do ano em que foi realizado o campo corresponde ao final do verão e, assim, as laranjeiras assumem o seu estágio vegetativo, uma vez que se trata de uma época importante para o monitoramento do nutriente.

O solo é composto por Argissolos Vermelho-Amarelo Abrupto (PVA4) de textura média, e o clima é classificado em CWA (Köppen), com pluviosidade anual

de 1300 mm, tendo estações do ano bem definidas. As laranjeiras selecionadas para este estudo foram plantadas em 2013, com 752 plantas por hectare, em espaçamento 7 m x 1,9 m. A adubação nitrogenada em solo foi idêntica para todos os talhões avaliados, com 250 kg.ha⁻¹ de nitrogênio, saturado em nitrato de amônia.

Figura 2 – Área de interesse e pontos amostrados durante a campanha de campo.



A área imageada foi separada em 24 talhões, de formato quadrangular, com aproximadamente 125 metros de cada lado. Em cada um desses talhões foram coletadas aproximadamente 70 folhas, localizadas no terceiro ou quarto ramo frutífero de cada árvore, na altura média da copa, da qual corresponde a 2 metros em relação ao solo. 25 árvores por talhão foram selecionadas aleatoriamente para a amostragem. A coleta destas folhas foi realizada entre 11h00min e 18h00min do mesmo dia.

O ARP utilizado neste estudo foi um eBee, modelo SenseFly, do qual embarcamos uma câmera Parrot Sequoia. Essa câmera registra bandas nas faixas espectrais do verde (510-590 nm), do vermelho (620-700 nm), da borda-do-vermelho (725-745 nm) e do infravermelho-próximo (750-830 nm). Adotamos uma sobreposição longitudinal de 80% e lateral de 60%, conforme as especificações do equipamento, e altura de voo de 120 metros, gerando imagens com GSD (*Ground Sample Distance*) de aproximadamente 12 cm.

O voo ocorreu entre 13h00min e 15h00min, sob condições atmosféricas adequadas, e foi autorizado pelo DECEA (Departamento de Controle do Espaço Aéreo) (protocolo 5F7BAF). Antes do voo registramos uma placa de calibração que acompanha a Parrot Sequoia com a finalidade de realizar a calibração radiométrica das imagens.

Um total de nove pontos de controle foram levantados entre às 11h00min e 17h00min para a correção geométrica das imagens multiespectrais coletadas pela câmera Parrot Sequoia embarcada no ARP. Para isso utilizamos o GNSS (*Global Navigation Satellite System*) Leica Plus GS15, dupla frequência (μm), em modo RTK (*Real Time Kinematic*).

2.2.2 Processamento das curvas espectrais e análise química do tecido foliar

As medidas espectrais das folhas das laranjeiras ocorreram durante o imageamento da área, entre as 13h00min e 15h00min, sob as mesmas condições de iluminação. Essas medidas podem ser consideradas representativas para o dossel da planta, uma vez que seja realizado o cálculo de simulação de bandas (MARTINS *et al.*, 2017). Não obstante, fatores como a resolução espacial das imagens devem ser levados em consideração quando analisados os dados.

Para determinar as curvas espectrais, medimos a resposta espectral das folhas de 32 laranjeiras-valência com o espectroradiômetro de campo ASD Fieldspec HandHeld. Esse equipamento registra 512 canais com resolução espectral de 1,6 nm e um campo de visada de 10° , no intervalo de 325 a 1075 nm. O equipamento mede 10 curvas espectrais a cada leitura, para então calcular a curva média, que é utilizada como representativa para o alvo de interesse. Além da coleta de folhas, cada árvore foi georreferenciada com o GNSS.

Calibramos o espectroradiômetro conforme as condições de iluminação local e medimos a refletância de uma placa Lambertiana (*Spectralon® plate*) antes de cada medida. Essa calibração permitiu estimar o Fator de Refletância Hemisférico Cônico (HCRF - *Hemispherical Conical Reflectance Factor*) das folhas, e, em seguida, converter o sinal medido pelo espectroradiômetro em refletância. O HCRF é calculado a partir da equação 1 (ANDERSON *et al.*, 2013).

$$\text{HCRF} (\omega_i \omega_r) = \frac{dL (\theta_r, \Phi_r) (\text{alvo})}{dL (\theta_r, \Phi_r) (\text{referência})} K (\theta_i, \Phi_i, \theta_r, \Phi_r) \quad (1)$$

onde: dL é a radiância, ω é o ângulo sólido, θ e Φ são os ângulos zenital e azimutal, respectivamente; i corresponde ao fluxo incidente e r é o fluxo de energia refletido. O valor K é o fator de correção do equipamento utilizado.

O espectralradiômetro foi posicionado em um ângulo de 45° , em relação à altura da planta para que o campo de visada (FOV - *Field of View*) não ultrapassasse a área das folhas coletadas. Para cada uma das 32 árvores, coletamos de quatro a cinco folhas, correspondendo àquelas medidas pelo espectralradiômetro. As folhas foram colocadas em embalagens plásticas, identificadas e então encaminhadas para a análise química do tecido foliar.

Em laboratório, separamos as amostras foliares dos talhões e das 32 árvores. As folhas foram lavadas e secas em estufa entre 60 e 65° C por 48 horas e, posteriormente, trituradas. Para quantificar o nitrogênio foliar, aplicamos o método de titulação Kjeldahl, que consiste em três etapas, sendo essas: 1) digestão, 2) destilação em destilador de nitrogênio e; 3) titulação com ácido sulfúrico (H_2SO_4) (PRAC, 2018). Obtivemos o nitrogênio foliar para cada uma das amostras e os relacionamos com os talhões imageados (Figura 2) e com as 32 curvas registradas pelo espectralradiômetro em campo.

As curvas espectrais foram agrupadas de acordo com o seu teor de nitrogênio. Os valores de nitrogênio foram classificados em três classes: baixo (menor do que 27 g.kg^{-1}); médio (de 27 a 29 g.kg^{-1}) e; alto (maior do que 29 g.kg^{-1}). Esses limiares foram definidos com base em Quaggio *et al.* (1998), que relacionam o teor de nitrogênio foliar (em g.kg^{-1}) com o ganho de produtividade (em %), em um experimento conduzido com laranjeiras. Os autores afirmam que, a partir de 27 g.kg^{-1} , o ganho em produtividade aproxima-se de 100%, e, depois de 29 g.kg^{-1} , este mesmo ganho começa a declinar.

As curvas espectrais correspondentes às medidas nos 32 pés de laranja-valência foram agrupadas em função das três classes do teor do nitrogênio foliar. Em seguida, determinamos a assinatura espectral de cada uma das classes de nitrogênio (baixo, médio e alto). Para caracterizar o comportamento espectral das laranjas-valência nas faixas espectrais da câmera Parrot Sequoia, realizamos uma simulação de bandas conforme a equação 2 (MARTINS *et al.*, 2017).

$$R_{\text{Sim}}(\lambda_i) = \frac{\sum \lambda \text{HCRF}(\lambda) * \text{SRF}(\lambda)}{\sum \lambda \text{SRF}(\lambda)} \quad (2)$$

onde: $R_{\text{SIM}}(\lambda_i)$ corresponde ao valor de refletância simulada obtida a partir do HCRF no comprimento de onda da banda (λ_i), e $\text{SRF}(\lambda)$ é a função resposta adotada para o sensor, conforme a equação (2.1).

$$\text{SRF}(\lambda_i) = \exp\left[-\frac{(\lambda_i - C\lambda_i)^2}{(2 \times \sigma^2)}\right] \quad (2.1)$$

onde: λ_i corresponde ao comprimento de onda que se deseja obter a função resposta, $C \lambda_i$ equivale ao comprimento de onda central da banda que deseja ser simulada, e σ é a amplitude dessa banda.

Depois de simuladas as bandas para cada faixa espectral da Parrot Sequia, agrupamos as curvas espectrais correspondentes às medidas nos 32 pés de laranja-valência em função das classes do teor do nitrogênio foliar (baixo, médio e alto). As curvas do espectralradiômetro e as curvas simuladas da Parrot Sequoia foram analisadas por comparações pareadas para determinar a possibilidade de se diferenciar, ou não, as mesmas. Utilizamos o teste de Shapiro-Wilk para verificar a normalidade dos dados. Nas análises, adotamos como estatística paramétrica o teste t Student, considerando o intervalo de confiança de 95%.

2.2.3 Processamento das imagens multiespectrais

Ao todo foram registradas 2.389 imagens para a área de interesse. Essas imagens foram processadas no *software* de processamento de imagem Pix4DMapper. Inicialmente, as imagens foram separadas em dois blocos (Bloco I e Bloco II, Figura 2) para otimizar o processamento. Realizamos a fototriangulação das imagens para então, em seguida, estimar os parâmetros de orientação exterior e interior da imagem. Também produzimos um MDS (Modelo Digital de Superfície) da área, e ambos os blocos foram ortorretificados utilizando nove dos pontos de controle levantados com o GNSS, e construídos dois ortomosaicos. A REQM do processo de fototriangulação foi de 0,129 metros.

A calibração radiométrica também foi realizada com o Pix4DMapper. Previamente ao voo, registramos com a Parrot Sequoia uma imagem da placa de

refletância calibrada e, durante o voo, utilizamos o sensor solar da própria câmera para avaliar as condições de iluminação local. O uso da placa de referência calibrada permite que o *software* calibre e corrija a refletância das imagens de acordo com os valores dados pela placa de calibração, levando em consideração as condições de iluminação da captura da imagem, além de certas características do sensor.

As bandas abrangendo as regiões espectrais do verde, vermelho, borda-do-vermelho e infravermelho-próximo (bandas 1, 2, 3 e 4, respectivamente) foram combinadas em um único arquivo, e carregadas no *software* de processamento de imagens ENVI 5.3. Depois, também carregamos os valores de refletância das curvas espectrais simuladas, representativas das classes de nitrogênio. As curvas espectrais serviram como dados de entrada para o treinamento dos algoritmos de classificação supervisionada testados.

Para classificar o teor de nitrogênio foliar, testamos diferentes algoritmos de classificação, consistindo-se naqueles que aceitavam as curvas espectrais como dados de entrada, sendo o: Constrained Energy Minimization (CEM); Linear Spectral Unmixing (LSU); Mixture Tuned Matched Filtering (MTMF); Minimum Distance (MD); Orthogonal Subspace Projection (OSP); Spectral Angle Mapper (SAM) e; Spectral Information Divergence (SID) (Tabela 1). Em seguida aplicamos uma tolerância de 10% na divergência dos valores de pixels para os valores de refletância das curvas espectrais, uma vez que consideramos essa robustez na classificação adequada para a finalidade do estudo. Ao final, os pixels foram agrupados em três classes: baixo ($< 27 \text{ g.kg}^{-1}$); médio ($\geq 27 \text{ g.kg}^{-1}$ e $\leq 29 \text{ g.kg}^{-1}$) e; alto ($> 29 \text{ g.kg}^{-1}$). Os pixels que não atenderam ao limiar de 10% imposto, não foram classificados.

Tabela 1 – Descrição dos algoritmos de classificação testados neste estudo.

Acrônimo	Classificador	Descrição	Referência
CEM	Constrained Energy Minimization	A partir de uma restrição específica, o algoritmo utiliza um filtro de resposta ao impulso finito (FIR - <i>Finite Impulse Response</i>) para passar pelo alvo desejado enquanto minimiza a energia resultante de um plano de fundo diferente dos alvos desejados. Posteriormente, utiliza uma matriz de covariância para caracterizar o plano de fundo desconhecido.	Hong <i>et al.</i> , (2018)
LSU	Linear Spectral Unmixing	Realiza uma combinação linear da refletância do valor de cada pixel da imagem, apresentando duas opções de restrição: o desmembramento irrestrito, onde as abundâncias podem assumir valores negativos, e desmembramento parcialmente restrito, onde as abundâncias são restritas à uma soma-para-umidade.	Wicaksono (2018)
MTMF	Mixture Tuned Matched Filtering	Aplica uma técnica de maximização da resposta de um valor de pixel conhecido, suprime a resposta de fundo desconhecida e cria uma imagem de inviabilidade antes de realizar a classificação para reduzir o número de falsos-positivos.	Yousefi <i>et al.</i> , (2018)
MD	Minimum Distance	Calcula a distância euclidiana entre os valores de refletância dos pixels, classificando-os de acordo com o valor médio dos dados de treinamento.	Shardadhoke (2018)
OSP	Orthogonal Subspace Projection	Calcula um subespaço ortogonal para eliminar a resposta espectral de alvos que não correspondem aos valores dos dados de treinamento, aplicando, em seguida, um filtro para classificar os pixels restantes.	Yu <i>et al.</i> , (2018)
SAM	Spectral Angle Mapper	Baseia-se nos valores espectrais do alvo, determinando a similaridade espectral entre o pixel e as curvas espectrais inseridas como amostra de treinamento ao calcular o ângulo espectral entre ambos, com dimensionalidade equivalente ao número de bandas.	Park <i>et al.</i> , (2017)
SID	Spectral Information Divergence	Aplica um método de classificação espectral que utiliza a medida de divergência para combinar os pixels da imagem com as curvas espectrais utilizadas como referência; quanto menor a divergência entre os dados, maior a probabilidade de os pixels serem semelhantes, e quando o pixel possui uma medida superior ao limite de divergência máximo definido, não é classificado.	Chauhan e Mohan (2017); Shardadhoke (2018)

Cada classificação foi validada pela matriz de confusão, por meio da acurácia global, erro de comissão, erro de omissão e do coeficiente *kappa*. Utilizamos aproximadamente 30.000 pixels espalhados sobre a área imageada para validá-las e os comparamos com os valores de nitrogênio foliar obtidos com as folhas coletadas nos 24 talhões. Para comparar o desempenho dos algoritmos testados, construímos curvas ROC (*Receiver Operating Characteristic*) a partir dos valores de positivos e falso-positivos. Adjunto a curva ROC, calculamos a AUC (*Area Under the Curve*) por meio da regra trapezoidal, uma vez que a consideramos adequada às características dos dados produzidos.

2.3 Resultados e Discussão

Para analisar as curvas espectrais representativas das classes do teor de nitrogênio foliar (baixo, médio e alto), elaboramos um histograma (Figura 3) contendo a frequência de distribuição dos valores de refletância em cada faixa espectral da Parrot Sequoia. Na região do vermelho (Figura 3), as curvas espectrais das classes de nitrogênio médio e alto apresentaram comportamentos próximos,

porém, a análise estatística (Tabela 2) mostrou diferença entre ambas as curvas. Constatamos que o teor do nitrogênio na planta, quando abaixo dos 27 g.kg⁻¹, é detectado facilmente em qualquer um dos comprimentos de onda investigados. A deficiência do nutriente compromete com a diferenciação do pigmento foliar em não apenas na região do visível, como também na do infravermelho (MUHARAM *et al.*, 2015). Essa diferenciação foi expressiva em todos os casos analisados (Tabela 2).

Detectamos que na região verde (510-590 nm) existe um isolamento dos valores de refletância para a curva espectral do nitrogênio de classe “baixo” (teor menor do que 27 g.kg⁻¹) quando comparado com as curvas do nitrogênio “médio” (entre 27 e 29 g.kg⁻¹) e “alto” (acima de 29 g.kg⁻¹) (Figura 3). Contudo, notamos que essas curvas (normal e alto) praticamente se sobrepõe na região do verde. Isso indica a dificuldade de se utilizar a região espectral dessa banda para discriminar o nitrogênio entre 27 e 29 g.kg⁻¹ do teor acima de 29 g.kg⁻¹. O resultado se confirma pelo teste de médias (Tabela 2). Esse resultado é esperado, uma vez que outras pesquisas (CILIA *et al.*, 2014; MOKHELE *et al.*, 2010; KALACSKA *et al.*, 2015) apontaram para a mesma dificuldade em se mensurar o teor de nitrogênio em excesso na região do verde.

Figura 3 – Histograma de distribuição de refletância das curvas espectrais.

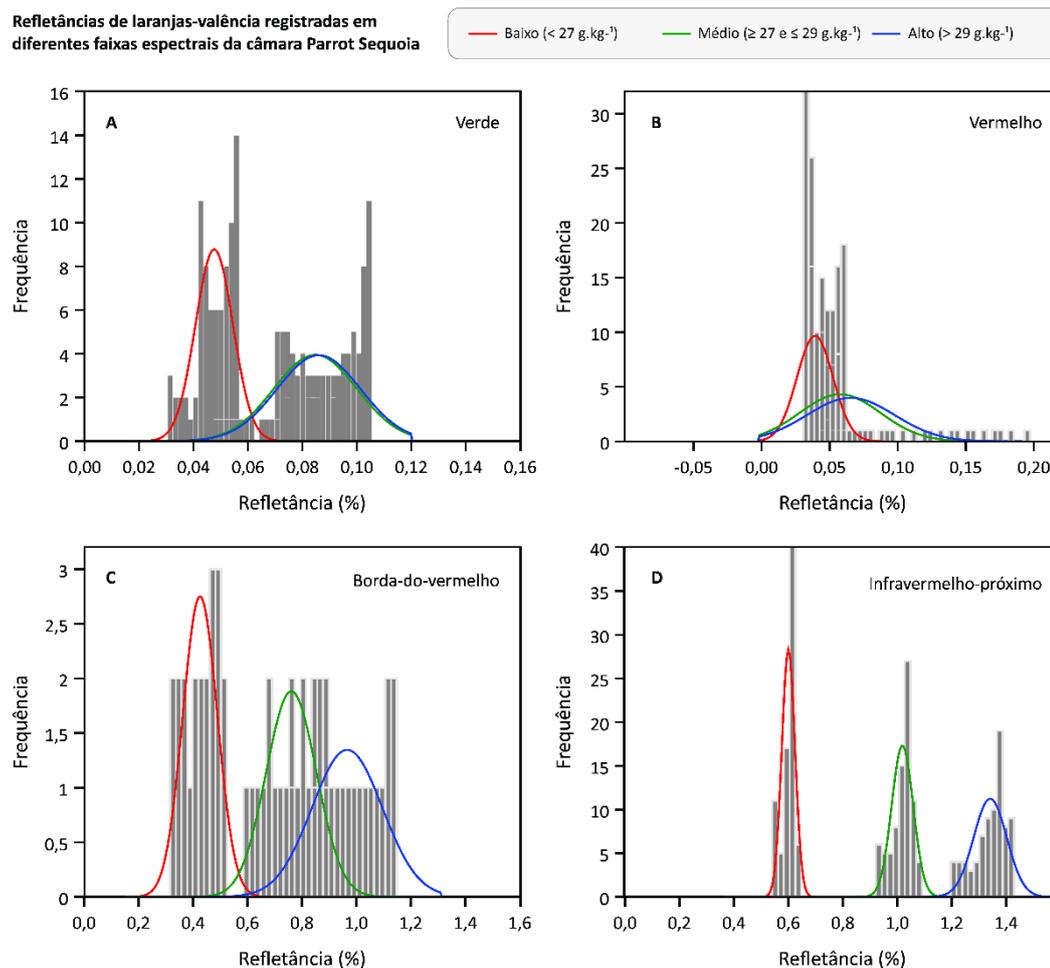


Tabela 2 – Comparação entre a refletância das curvas reais e simuladas.

Banda	Nitrogênio	Estatística Descritiva		Teste de Médias (valor-p) ¹		
		Refletância Média	Erro-Padrão	Baixo e Médio	Médio e Alto	Baixo e Alto
Verde	Baixo	0,0475 ± 0,0068	0,0264			
	Médio	0,0847 ± 0,0153	0,0412	0,0001*	0,4568 ^{ns}	0,0001*
	Alto	0,0859 ± 0,0154	0,0412			
Vermelho	Baixo	0,0393 ± 0,0132	0,0374			
	Médio	0,0576 ± 0,0297	0,0574	0,0001*	0,0005*	0,0001*
	Alto	0,0655 ± 0,0322	0,0591			
Borda-do-vermelho	Baixo	0,4259 ± 0,0633	0,1174			
	Médio	0,7611 ± 0,0925	0,1421	0,0001*	0,0001*	0,0001*
	Alto	0,9662 ± 0,1293	0,1679			
Infravermelho-próximo	Baixo	0,6002 ± 0,0241	0,0509			
	Médio	1,0189 ± 0,0394	0,0655	0,0001*	0,0001*	0,0001*
	Alto	1,3413 ± 0,0608	0,0818			

¹Teste t Student; ^{ns}Não significativo a 5% pelo Teste F. *Significativo a 1% pelo Teste F.

As análises do comportamento espectral de laranjeiras demonstram que, conforme ocorre o aumento do teor de nitrogênio nas folhas, menor é a refletância na região espectral do vermelho, e maior na região do verde (MIN; LEE, 2005; WANG *et al.*, 2017b; JONES *et al.*, 2007). Essa condição está estritamente relacionada ao papel que o nitrogênio desempenha na construção da molécula de clorofila (HUERTA *et al.*, 2013; DELLOYE *et al.*, 2018).

Nosso estudo de caso contrapõe parcialmente os achados supracitados, pois detectamos que, quanto maior o teor de nitrogênio, maior foi a refletância para a região do vermelho. Esse aumento, entretanto, foi pouco expressivo, ocorrendo de uma maneira sutil. Outro fator a ser levado em consideração é que determinamos o comportamento espectral de laranjeiras em condições de iluminação ambiente. Isto pode explicar as diferenças encontradas aqui para outros estudos (MIN; LEE, 2005; XUEFENG *et al.*, 2016).

Na faixa da borda-do-vermelho, verificamos que os valores de refletância para os teores de nitrogênio baixo e alto pouco se sobrepõem (Figura 3C), e que são diferentes entre si (Tabela 2). Isso é confirmado pela literatura, que aponta a borda-do-vermelho como uma faixa estratégica para o monitoramento do nitrogênio em plantas (ATZBERGER *et al.*, 2010).

Constatamos que o intervalo espectral ideal para discriminar o teor de nitrogênio foliar nas laranjeiras corresponde ao infravermelho-próximo (750-830 nm) (Figura 3D), pois, além de diferenciarem entre si, não há sobreposição entre as curvas representativas dos teores de nitrogênio foliar baixo (menor que 27 g.kg⁻¹), médio (entre 27 e 29 g.kg⁻¹) ou alto (acima de 29 g.kg⁻¹).

As variações no comportamento espectral da planta no infravermelho-próximo estão associadas com a organização estrutural de moléculas intracelulares do mesófilo foliar (YANLI *et al.*, 2015). Geralmente, os desbalanços nutricionais e(ou) hídricos são responsáveis por alterações nessa região (CONNELL *et al.*, 2016). No presente estudo, observamos que o aumento da resposta espectral do infravermelho-próximo está associado com o aumento do teor de nitrogênio, e estes resultados corroboram com a literatura (MIPHOKASAP; WANNASIRI, 2018; ATZBERGER *et al.*, 2010; MIN; LEE, 2005; WANG *et al.*, 2017; STELLACCI *et al.*, 2016;). Essa constatação demonstra a importância da banda do infravermelho-próximo em separar a variação de nitrogênio nas folhas de laranjeiras.

2.3.1 Classificação de imagens por algoritmos de análise espectral

No processo de simulação das bandas, constatamos visual (Figura 4) e estatisticamente (Tabela 3), que as curvas espectrais médias simuladas podem ser consideradas iguais, no intervalo de confiança de 99%, às curvas espectrais médias obtidas pelo espectraloradiômetro. Isso é válido para cada intervalo espectral estudado e cada classe de teor de nitrogênio considerada. Os altos valores dos coeficientes de correlação de Pearson (acima de 99,9%) e do R^2 da regressão, associados ao baixo valor da REQM das comparações entre as curvas espectrais (Tabela 3) para distintas faixas espectrais, comprovam que, pela simulação de bandas é possível diferenciar com alta acurácia as classes do nitrogênio foliar (baixo, médio e alto) em laranjeiras-valência.

Figura 4 – Assinatura espectral do nitrogênio foliar e as curvas espectrais simuladas.

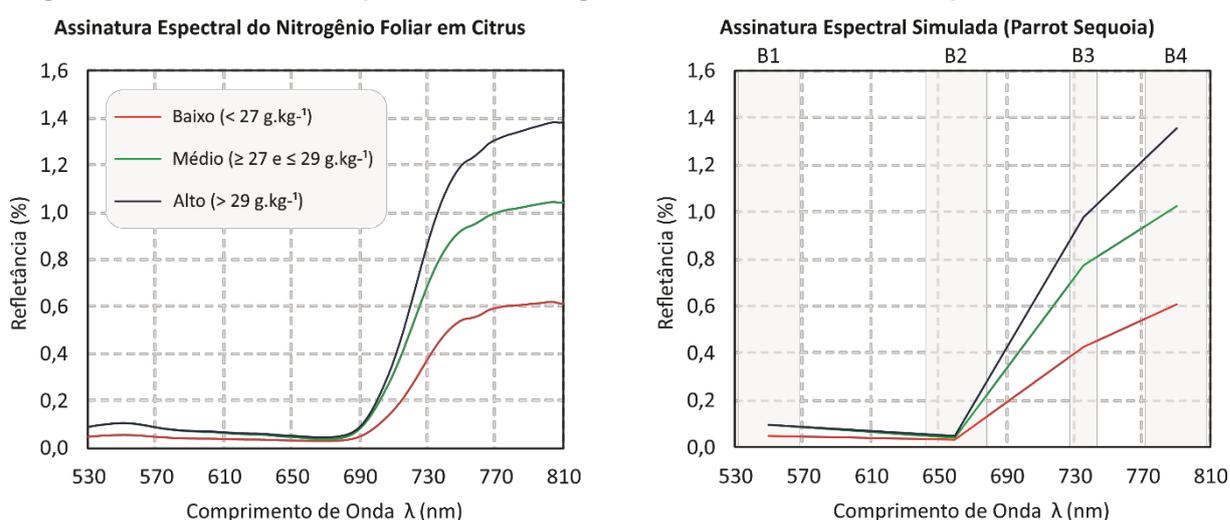


Tabela 3 – Comparativo entre a assinatura espectral e a curva espectral simulada.

Classe	Banda	Refletância (média)	Refletância (simulada)	R ²	REQM ¹	r	Valor-p
Baixo	Verde	0,0475 ± 0,0068	0,0533	0,9996	0,0663	0,9998	0,0001*
	Vermelho	0,0393 ± 0,0132	0,0324				
	Borda-do-vermelho	0,4259 ± 0,0633	0,4303				
	Infravermelho-próximo	0,6002 ± 0,0241	0,6084				
Médio	Verde	0,0847 ± 0,0153	0,0977	0,9997	0,1014	0,9994	0,0003*
	Vermelho	0,0576 ± 0,0297	0,0412				
	Borda-do-vermelho	0,7611 ± 0,0925	0,7692				
	Infravermelho-próximo	1,0189 ± 0,0394	1,0279				
Alto	Verde	0,0859 ± 0,0154	0,0989	0,9998	0,1020	0,9996	0,0001*
	Vermelho	0,0655 ± 0,0322	0,0489				
	Borda-do-vermelho	0,9662 ± 0,1293	0,9769				
	Infravermelho-próximo	1,3413 ± 0,0608	1,3540				

¹Raiz do Erro Quadrático Médio; *Significativo a 1% pelo Teste F.

A abordagem de se treinar um classificador utilizando curvas espectrais simuladas não foi encontrada na literatura até o presente momento para a aplicação na agricultura de precisão. Por essa razão aplicamos as curvas espectrais simuladas no treinamento de cada um dos algoritmos de classificação testados (Tabela 1). Pela classificação, definimos três classes temáticas de pixels que representam laranja-ervalência com quantidades baixo, médio e alto de nitrogênio.

Do conjunto de sete classificadores, o CEM, LSU e o OSP apresentaram menor desempenho, com valores de acurácia global próximos a 40% e de coeficiente *kappa* de aproximadamente 0,10 (Tabela 4), sendo visualmente parecidas (Figura 5). Na área em estudo, apenas um talhão apresentou valor acima do limiar definido como alto, que corresponde a 29,5 g.kg⁻¹. Essa condição explica os valores baixos de acurácia global e do *kappa* para os classificadores CEM, LSU e OSP, que associaram muitos dos pixels à classe de nitrogênio “alto”.

Ainda que o resultado da classificação dos algoritmos SID, MD e MTMF seja visualmente similar (Figura 5), os resultados quantitativos (Tabela 4) demonstram a superioridade do SID (com acurácia global de 73,3% e o coeficiente *kappa* de 0,52) em comparação aos outros classificadores. O SID utiliza uma medida de divergência para criar as classes em relação a curva espectral, e essa abordagem pareceu mais adequada quando envolve o uso de curvas espectrais como dados de entrada. Já o MTMF tende a maximizar a resposta do pixel para então atribuí-lo a uma classe, o que não foi interessante para o resultado final. O MD, por sua vez, não apresenta

um limite como os demais classificadores, e por isso acabou por classificar todos os pixels da imagem na classe mais próxima.

Obtivemos a maior acurácia na aplicação do classificador SAM, sendo a sua acurácia global de 87,5% e o seu índice *kappa* de 0,75 (Tabela 4). Visualmente (Figura 5), foi o resultado com maior discrepância na comparação do grupo dos sete classificadores.

Figura 5 – Demonstração da eficiência dos diferentes algoritmos de classificação.

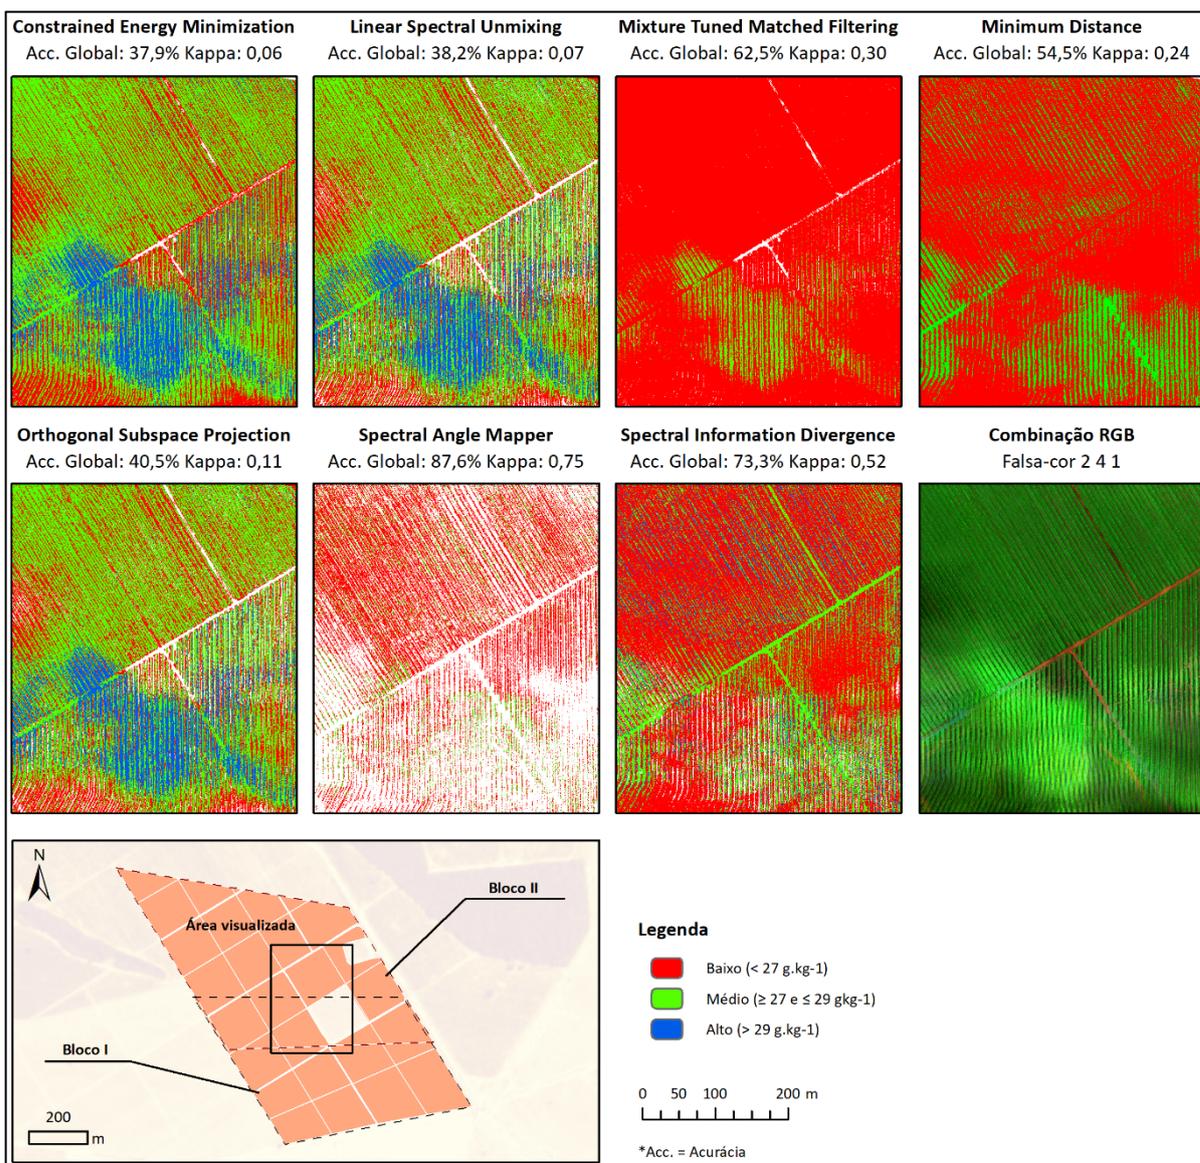


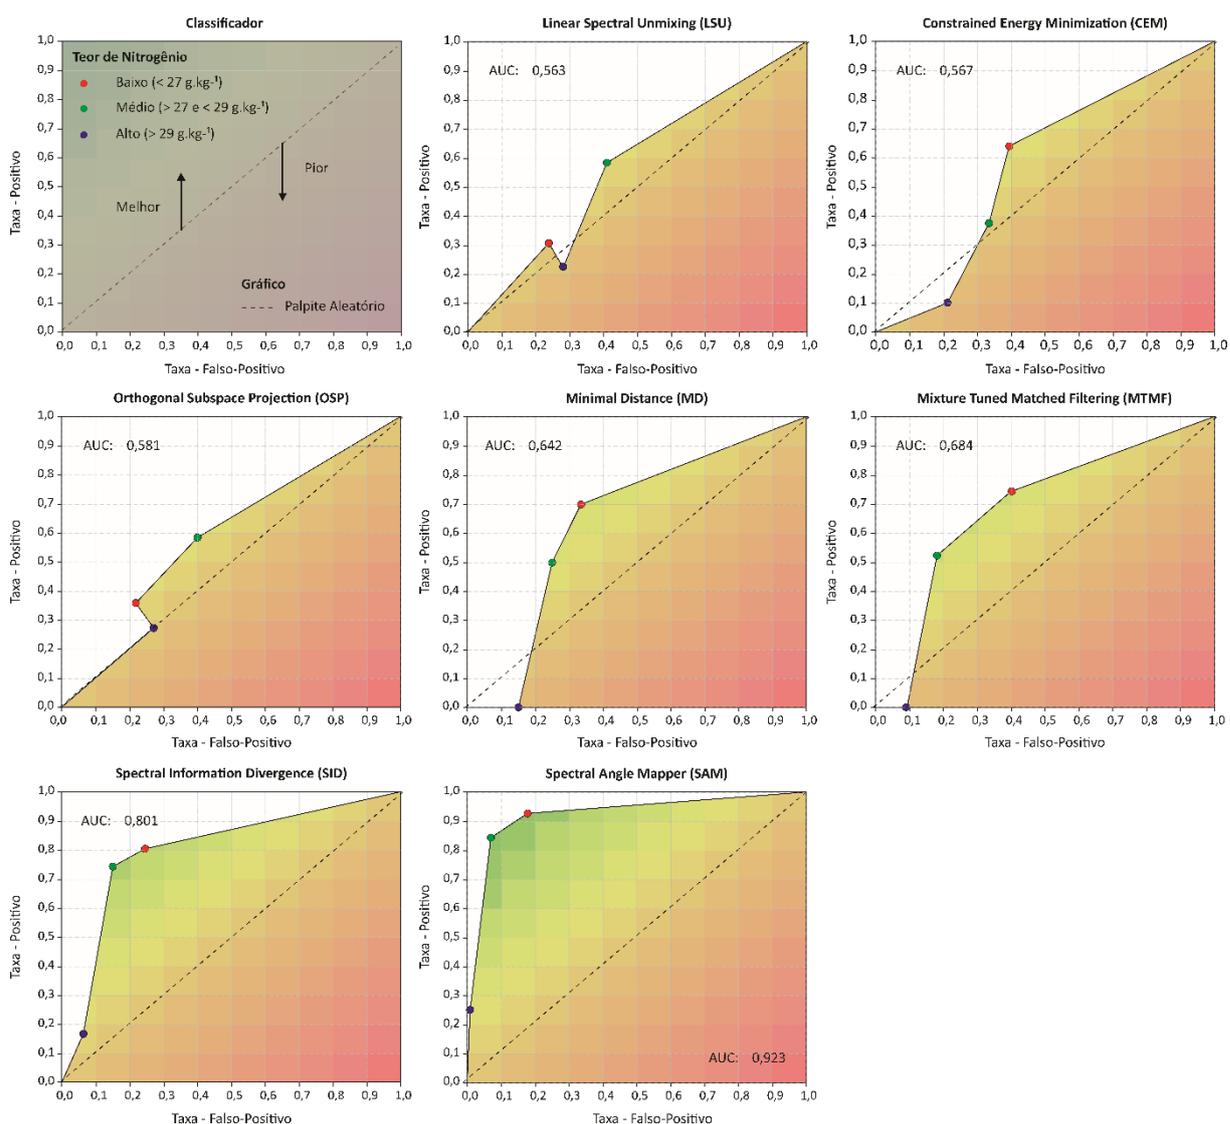
Tabela 4 – Performance dos classificadores de acordo com a referência terrestre.

Classificador Acrônimo	----- Erro de Comissão; Erro de Omissão -----			Acurácia Global	Coeficiente <i>kappa</i>
	N Baixo	N Médio	N Alto		
CEM	62,4%; 69,9%	36,5%; 50,1%	90,0%; 80,0%	37,9%	0,06
LSU	69,1%; 55,5%	41,8%; 56,3%	77,7%; 77,7%	38,2%	0,07
OSP	64,2%; 49,9%	41,8%; 58,9%	72,7%; 69,9%	40,5%	0,11
MD	29,9%; 36,3%	50,1%; 37,5%	100,0%; 100,0%	54,5%	0,24
MTMF	25,7%; 30,3%	47,9%; 33,4%	100,0%; 100,0%	62,5%	0,30
SID	19,4%; 25,0%	25,7%; 19,5%	83,3%; 83,3%	73,3%	0,52
SAM	7,2%; 12,5%	15,7%; 10,9%	75,0%; 51,6%	87,6%	0,75

Para facilitar a comparação do desempenho de cada algoritmo testado, construímos curvas ROC e calculamos as AUC correspondentes (Figura 6). A curva ROC das classificações indica, de maneira geral, os algoritmos que obtiveram melhor desempenho na identificação de laranjeiras-valência com nitrogênio baixo, médio e alto. Com isso demonstramos, novamente, que o SAM foi superior em relação aos algoritmos na classificação das classes de nitrogênio de interesse.

Com exceção dos algoritmos SID e SAM, os classificadores encontraram problemas para classificar os pixels representando o nitrogênio foliar em excesso. A posição dos pontos na área abaixo da diagonal do ROC (linha pontilhada) indica que o desempenho foi inferior ao de um palpite aleatório (Figura 6). Já a AUC de cada classificador demonstra que os piores algoritmos obtiveram valores próximos de 0,5 (CEM, LSU e OSP), indicando que, apesar da baixa performance, ainda se encontram acima de um palpite aleatório no sentido geral. No caso do SID e do SAM, as AUCs foram superiores à dos demais algoritmos, próximas de 1, indicando que as suas classificações apresentaram baixa taxa de falsos-positivos.

Figura 6 – Curva ROC e AUC construída para cada um dos classificadores testados.



Nosso estudo de caso mostrou (Tabela 4 e Figura 6) que a classificação com o algoritmo SAM (Figura 7) é a alternativa mais adequada para avaliar o teor de nitrogênio foliar em laranjeiras. A acurácia global e o índice *kappa* permitem afirmar que a classificação realizada pelo algoritmo SAM foi ótima (LANDIS; KOCH, 1997), e considerada adequada para a finalidade proposta.

Verificamos (Tabela 5) que, apesar dos erros de comissão e omissão serem baixos nas classes de nitrogênio “baixo” e “médio”, os mesmos são elevados para a classe do nitrogênio “alto”. Isso pode estar relacionado com a baixa quantidade de talhões que representa essa classe de nitrogênio na área estudada, o que contribuiu para reduzir a quantidade de pixels avaliados nesta classe.

Figura 7 – Classificação de imagens da câmera Parrot Sequoia utilizando o SAM.

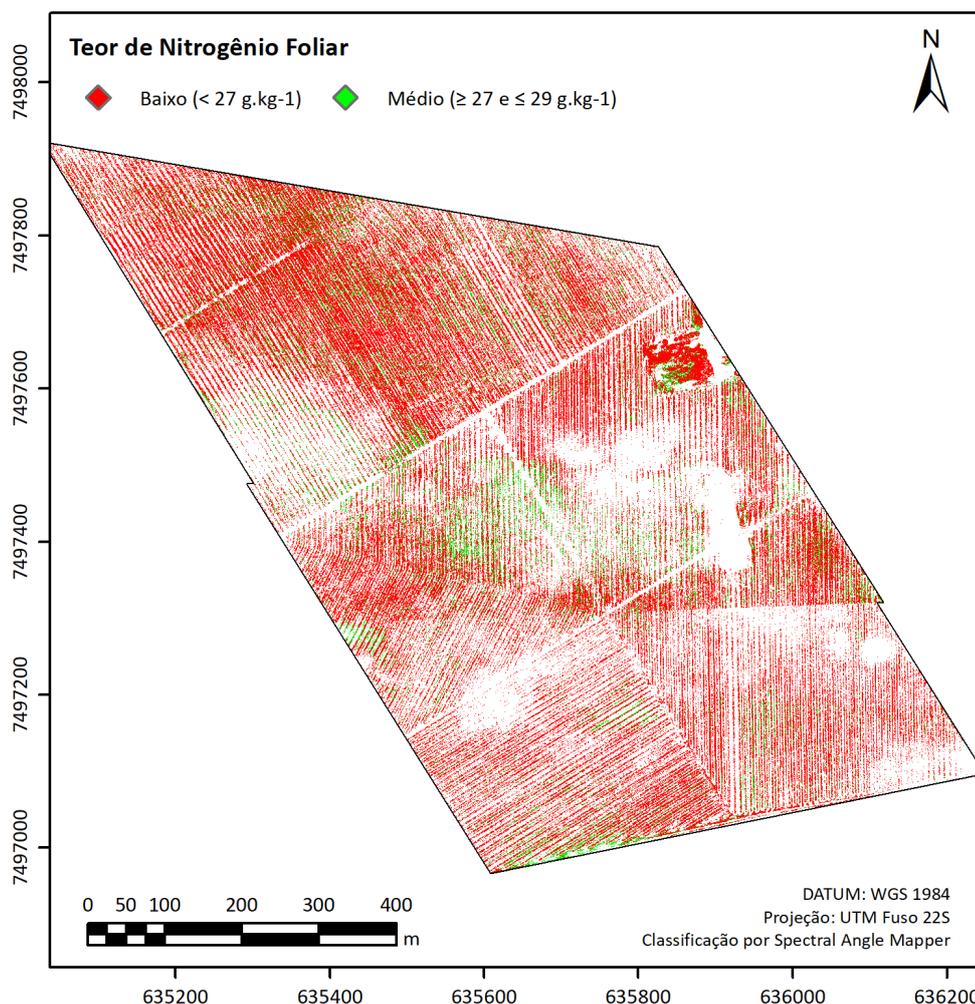
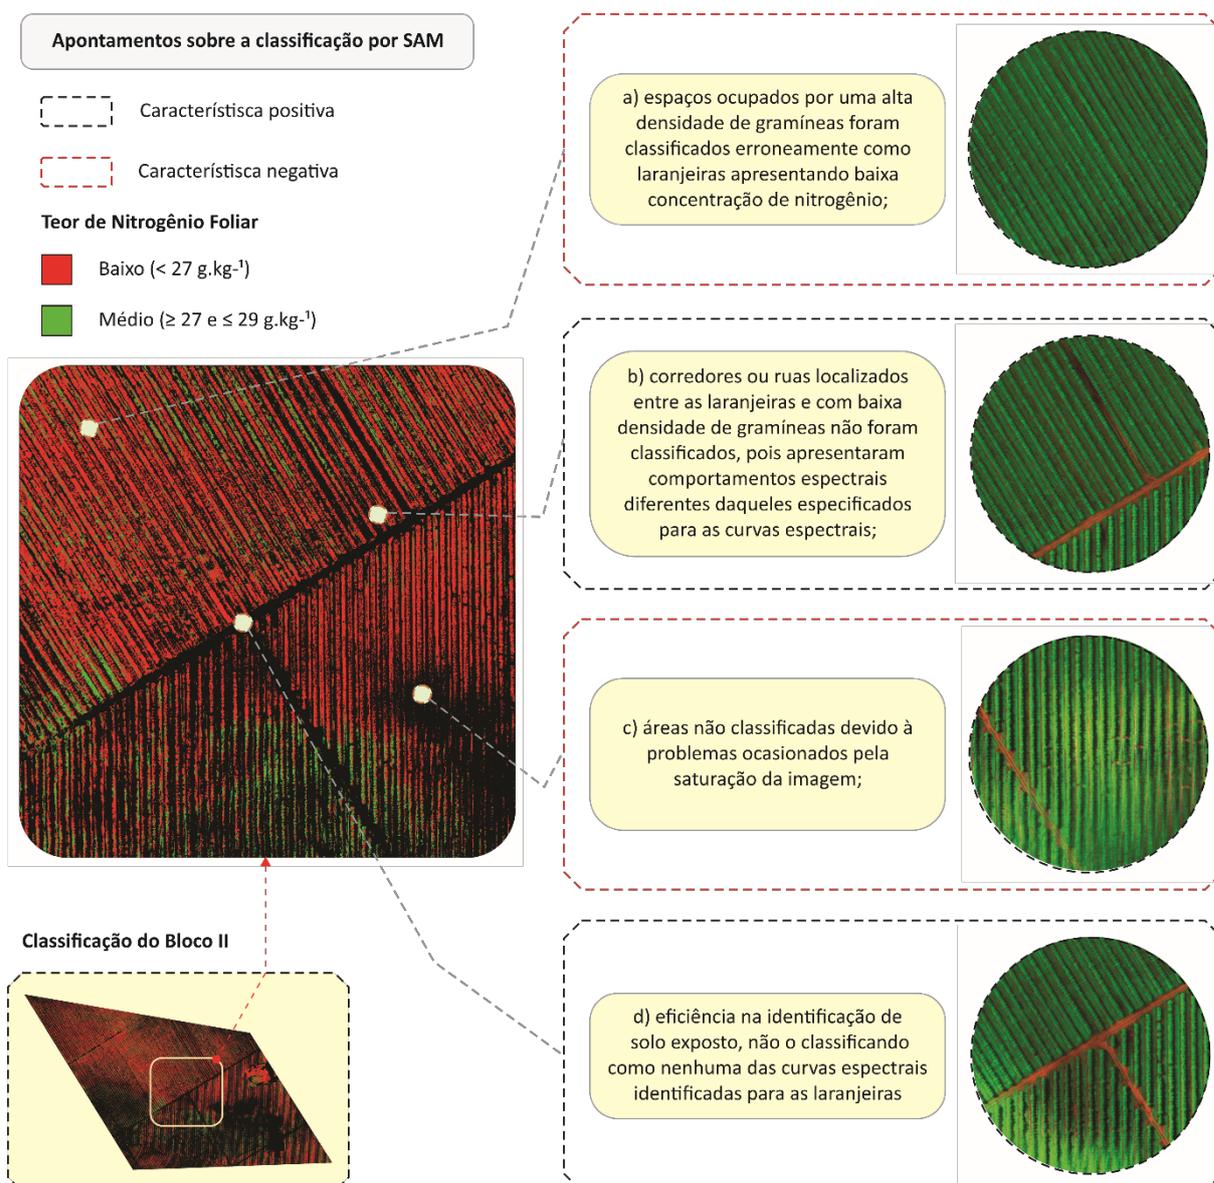


Tabela 5 – Matriz de confusão e erros de omissão e comissão da classificação SAM.

Matriz	Referência Terrestre				Erro de Omissão
	Baixo	Médio	Alto	Total	
Imagem Classificada					
Baixo	15554	1818	402	17774	12,5%
Médio	1005	9849	202	11056	10,9%
Alto	202	12	201	415	51,6%
Total	16761	11679	805	29245	----
Erro de Comissão	7,2%	15,7%	75,0%	----	----
Acurácia Global	87,6 %	Coefficiente kappa	0,75		

A maioria dos talhões imageados apresentou valores de nitrogênio foliar inferiores à 27 g.kg⁻¹, associando-os com a classe “baixo”. A classificação pelo SAM, além de resultar na melhor acurácia global e em maior valor do *kappa*, conseguiu separar os pixels pertencentes a áreas ocupadas por solo exposto e gramíneas dos pixels relacionados com laranjeiras, uma vez que o comportamento espectral dessas áreas não apresenta similaridades com as laranjeiras. A classificação, porém, não está isenta de erros, e algumas observações são realizadas (Figura 8).

Figura 8 – Principais características observadas na imagem classificada com SAM.



A área destacada ao centro do ortomosaico ilustra as características positivas e negativas da classificação com o algoritmo SAM para todo o restante da área imageada. No pomar analisado, muitas das ruas e corredores entre as laranjeiras estão ocupadas com gramíneas, e, em certas áreas, esta gramínea apresenta elevada quantidade de biomassa, o que confundiu o algoritmo. Não obstante, a classificação foi eficiente em áreas não ocupadas com laranjeiras, mesmo contendo gramíneas de menor densidade. Nas áreas de solo exposto, como algumas ruas da plantação e os corredores para a movimentação de veículos, o classificador não associou os pixels com nenhuma das curvas espectrais das classes de nitrogênio foliar, com exceção de pequenos ruídos presentes na imagem.

Um problema, porém, que foi observado com o SAM e com os demais classificadores ocorreu em uma área afetada pela saturação da imagem. O SAM, quando utilizado em imagens com valores de refletância calibrados, apresenta baixa sensibilidade à geometria de iluminação (PARK *et al.*, 2017), e essa característica foi comprovada em nosso estudo. Também comprovamos que o SAM é mais adequado para aplicações envolvendo simulação de bandas, justamente por considerar o ângulo espectral (PETROPOULOS *et al.*, 2010).

Ainda assim, em determinadas áreas (Figura 8C), a resposta espectral foi significativamente alterada, e por esta razão algumas das linhas de plantação não foram atribuídas as classes definidas. Apesar disto, o algoritmo SAM foi superior aos demais classificadores até mesmo em áreas onde essa saturação afetou a resposta espectral das plantas, o que reforça o seu uso para a estimativa do teor de nitrogênio foliar de laranjeiras pela resposta espectral.

2.4 Conclusões

A partir do estudo de caso conduzido, concluímos que o agrupamento e uso de curvas espectrais para classificar o nitrogênio foliar é adequado em laranjeiras-valência. Determinamos que a classificação realizada com o SAM (*Spectral Angle Mapper*), utilizando as curvas espectrais como dados de treinamento do classificador, mostrou-se a mais acurada (acurácia global de 87,5% e índice *kappa* de 0,75) entre os algoritmos testados. As relações do teor de nitrogênio foliar medido em laboratório concordam com a resposta espectral da imagem e, por isso, o Sensoriamento Remoto de alta resolução espacial é eficiente para discriminar o nitrogênio foliar.

Recomendamos que novos estudos empreguem o método proposto, considerando outras épocas do estágio de desenvolvimento da planta, e otimizando o monitoramento de atividades agrícolas ao decorrer do ano. Sugerimos, também, que empreguem este método para classificar o teor de nitrogênio foliar em outras culturas agrícolas. Uma outra recomendação, ainda, é investigar se imagens multiespectrais com maior resolução espacial possibilitam discriminar o nitrogênio foliar, com acurácia similar ou não a aquela obtida neste trabalho.

3 CAPÍTULO II: Potencial de Índices Espectrais de Vegetação ao Diferenciar o Teor de Nitrogênio Foliar em Laranja-Valência em Imagens Multiespectrais de Alta Resolução Espacial

Resumo

O nitrogênio é importante para a atividade fotossintética das laranjeiras, influenciando diretamente na produtividade. A tomada de decisão sobre a aplicação desse nutriente exige o conhecimento prévio do teor na planta. Os índices de vegetação extraídos de imagens multiespectrais têm obtido sucesso como uma análise não-destrutiva para a estimativa do teor de nitrogênio foliar em diversas culturas. Porém, este tipo de análise ainda é pouco explorado em laranjeiras. Assim, este estudo avaliou o potencial de diferentes índices espectrais de vegetação na estimativa do teor de nitrogênio foliar em laranjeiras. Utilizamos como área de estudo um pomar comercial de laranja-valência. Estimamos os índices de vegetação a partir de imagens multiespectrais de alta resolução espacial (*Ground Sample Distance* – GSD de 12cm) obtidas por uma câmera embarcada em uma Aeronave Remotamente Pilotada (ARP). Coletamos as amostras foliares de 24 talhões do pomar, e associamos o teor de nitrogênio dos talhões com a resposta espectral obtida pelos índices. Utilizamos dois conjuntos de amostras, um para a calibração do modelo e outro para a validação. Testamos essa associação em 33 índices de vegetação isoladamente e, também, em combinações entre esses mesmos índices. Constatamos que o índice de melhor desempenho na inferência do teor de nitrogênio foliar em laranjeiras é o CVI (*Chlorophyll Vegetation Index*), com R^2 de 0,81 e Raiz do Erro Quadrático Médio (REQM) de $0,942 \text{ g.kg}^{-1}$. Também observamos que a combinação dos índices foi eficiente, porém não superior ao índice destacado. Constatamos que os índices desenvolvidos para avaliar a clorofila foram superiores aos demais índices para estimar o nitrogênio. Concluímos que é possível estimar o teor de nitrogênio foliar em laranjeiras a partir de índices espectrais obtidos com imagens multiespectrais de alta resolução espacial.

Palavras-chave: Índices Espectrais; Aeronave Remotamente Pilotada; Citrus.

Abstract

Nitrogen is important for the photosynthetic activity of orange trees, directly influencing its productivity. Decision-making on the application of this nutrient requires prior knowledge of the plant content. Vegetation indexes extracted from multispectral images have been successful as a non-destructive analysis for the estimation of leaf nitrogen content in several crops. However, this type of analysis is still slight explored in orange trees. Thus, this study evaluated the potential of different spectral indexes of vegetation in the estimation of leaf nitrogen content in valencia-orange trees. We used as an experimental area a commercial orchard of valencia-orange. We estimated the vegetation indices from multispectral images with high spatial resolution (*Ground Sample Distance* - GSD of 12cm) obtained by a camera on a Remotely Piloted Aircraft (RPA). We collected leaf samples from 24 planting fields and associated the nitrogen content of the fields with the spectral response obtained by the indices. We used two sets of samples, one for the model

calibration and one its validation. We tested this association in 33 individual indices of vegetation, and also in combinations between these indices. We verified that the index with better performance in the inference of the leaf nitrogen content in valencia-orange trees is the CVI (Chlorophyll Vegetation Index), with R^2 of 0.81 and Root Mean-Squared Error (RMSE) of 0.942 g.kg^{-1} . We also observed that the combination of the indices was efficient, but not superior to the highlighted index. We found that the indices developed to evaluate chlorophyll were better than the other indices for nitrogen prediction. We conclude that it is possible to estimate the leaf nitrogen content in valencia-orange trees from spectral indices obtained with multispectral images with high spatial resolution.

Keywords: Spectral Indices; Remotely Piloted Aircraft; Citrus.

3.1 Introdução

Um pré-requisito essencial para a sustentabilidade de culturas agrícolas é o monitoramento, incluindo a análise das propriedades composicionais, estruturais e funcionais da planta (PETROU *et al.*, 2015). A dificuldade de um monitoramento frequente de áreas agrícolas exige o desenvolvimento de métodos rápidos, de baixo custo e não destrutivos na análise de plantas (MELESSE *et al.*, 2007). O uso de dados espectrais tem obtido sucesso em diferentes aplicações, e proporcionado alternativas interessantes na avaliação das condições nutricionais das plantas (STUCKENS *et al.*, 2011).

Estudos (CHHABRA *et al.*, 2010; KROSS *et al.*, 2015; MULLA, 2013) têm se aprofundado no monitoramento da vegetação em diferentes culturas, com o intuito de desenvolver, otimizar e de testar métodos de Processamento Digital de Imagens (PDI). Como método não-destrutivo, o uso de imagens de sensores remotos permite definir o estado fitossanitário das plantas por meio de seu comportamento espectral (FORTES, *et al.*, 2015). O nitrogênio é um dos nutrientes responsáveis por influenciar o estado fitossanitário de uma planta, pois faz parte da molécula de clorofila, que governa a pigmentação foliar, influenciando, a sua resposta espectral (HOMOLOVÁ *et al.*, 2013). Esse nutriente, também, está relacionado com enzimas do crescimento foliar, influenciando seu tamanho (LEMAIRE *et al.*, 2008).

A planta baixo em nitrogênio apresenta a clorose de suas folhas, caracterizada pelo amarelamento uniforme (MUHARAM *et al.*, 2015), o que facilita a sua identificação. Por outro lado, é difícil identificar visualmente uma planta com excesso de nitrogênio, pois a sua pigmentação é semelhante à de uma planta com teores adequados (HUNT *et al.*, 2013). Além disso, a variação nos teores de

nitrogênio influencia a produtividade, o que torna necessário a estimativa de uma curva crítica de adubação (QUAGGIO *et al.*, 1998).

Na detecção do nitrogênio foliar existe a possibilidade de se analisar as culturas por meio de índices espectrais de vegetação, pois os processamentos são simples e rápidos, envolvendo operações matemáticas em imagens (MELESSE *et al.*, 2007). Os índices baseados na resposta espectral das plantas têm sido utilizados não apenas para estimar o teor de nitrogênio foliar (ZHENG *et al.*, 2018; SCHLEMMER *et al.*, 2013; HUANG *et al.*, 2014; KALACSKA *et al.*, 2015), como também avaliar outras características, como a biomassa (CONNELL *et al.*, 2014), a clorofila (HUNT *et al.*, 2013) e o estresse hídrico (KRISHNA *et al.*, 2019).

Alguns exemplos de aplicações em culturas agrícolas envolvem o uso de diferentes índices e combinações de índices espectrais para estimar o nitrogênio em plantas. As combinações de índices foram avaliadas para inferir o nitrogênio em milho (CILIA *et al.*, 2014). Também, o desempenho de índices espectrais individuais foi investigado para prever o teor de nitrogênio no trigo-de-inverno (HE *et al.*, 2015). Outros índices foram utilizados para avaliar o nitrogênio em beterrabas (JAY *et al.*, 2017), no arroz (CHEN *et al.*, 2010; MAHAJAN *et al.*, 2017) e em culturas de cereais com imagens multiespectrais de alta resolução espacial, adquiridas com o auxílio de ARPs (Aeronaves Remotamente Pilotadas) (PERRY *et al.*, 2012).

A ampla disponibilidade de ARPs tem oferecido baixo custo na aquisição de imagens sobre áreas agrícolas, e cresce a demanda por estudos voltados para a análise do potencial dessas imagens em prever o teor de nitrogênio foliar (GABRIEL *et al.*, 2017). Essas aeronaves permitem que câmeras sejam embarcadas, garantindo a tomada de imagens com alta resolução espacial (GAUTAM; PANIGRAHI, 2007). Com ARPs, estudos recentes avaliaram o potencial de índices em estimar o nitrogênio foliar em várias culturas (RAPER; VARCO, 2015; RAMOELO *et al.*, 2012; XU *et al.*, 2018). Ainda assim, novas aproximações devem ser avaliadas, pois o comportamento espectral da vegetação varia de acordo com as características da própria cultura (WÓJTOWICZ *et al.*, 2016).

Os índices espectrais, além de serem desenvolvidos para avaliar as características fisiológicas da vegetação, podem ser aplicados em diferentes escalas, como ao nível foliar ou de dossel (CAMMARANO *et al.*, 2014). A maioria dos índices voltados para a predição do nitrogênio, ou mesmo de pigmentos como a clorofila, foram desenvolvidos em nível foliar, uma vez que consiste em uma

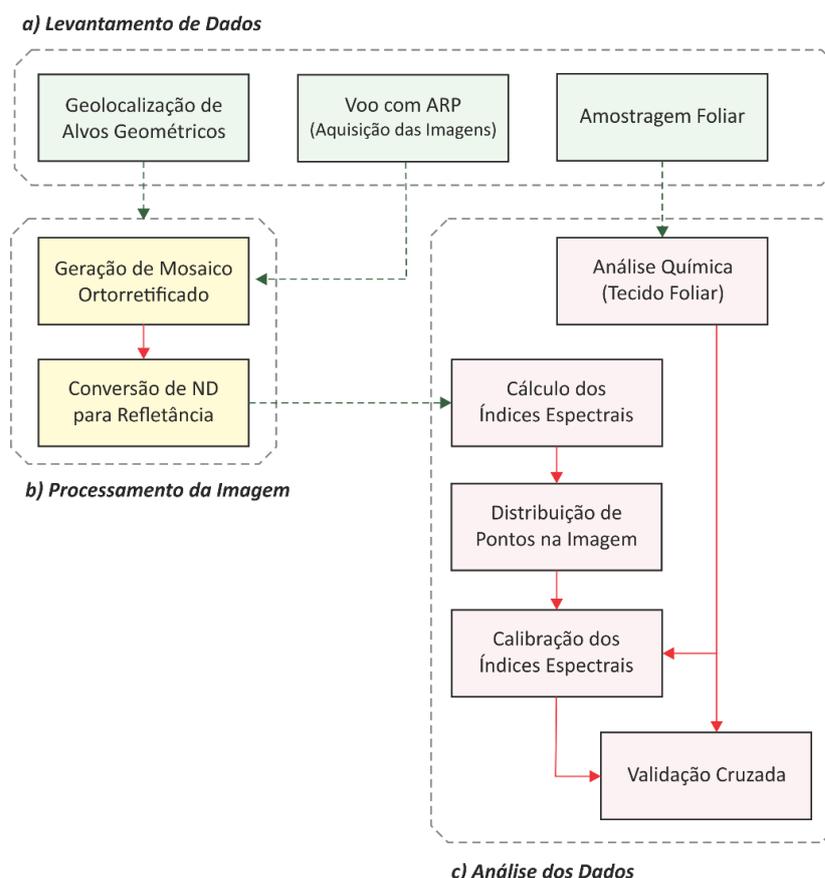
abordagem inicial, antes de se avaliar diferentes escalas (SCHLEMMER *et al.*, 2013). Outros índices foram desenvolvidos ao nível de dossel e consideram a contribuição de sombras e efeitos da anisotropia (SULTANA *et al.*, 2014). Além disso, diferentes índices foram desenvolvidos considerando a energia refletida pelo solo, próximo à planta (HUERTA *et al.*, 2013). Esses índices, quando combinados com índices de pigmentação, podem melhorar a acurácia dos resultados, pois anulam o efeito mencionado (CILIA *et al.*, 2014).

Apesar de diferentes índices espectrais terem sido testados em muitas culturas, utilizando imagens adquiridas por distintos sensores, até o momento, não se sabe de trabalhos que avaliaram índices espectrais de vegetação para laranjeiras no Brasil. Em laranjeiras, um estudo investigou a possibilidade de inferir o nitrogênio foliar por meio de imagens coletadas em ARP (XUEFENG *et al.*, 2016). Todavia, os autores apontam para a necessidade de se otimizar os resultados por meio da aplicação de outras técnicas, uma vez que somente duas técnicas quimiométricas foram aplicadas. Dessa maneira, o objetivo deste estudo foi investigar o potencial de índices espectrais de vegetação na estimativa do teor de nitrogênio foliar em laranjeiras por imagens capturadas com sensor em ARP. Além desse objetivo, testamos se a combinação de índices espectrais é mais adequada para inferir o teor de nitrogênio do que os índices individuais.

3.2 Materiais e Métodos

O método empregado neste estudo encontra-se separado em três fases (Figura 9). Inicialmente, realizamos o levantamento dos dados em um pomar de laranjeiras-valência. Utilizamos uma câmera Parrot Sequoia, embarcada em um ARP, para o imageamento da área. Coletamos 70 amostras foliares das laranjeiras-valência em um total de 24 talhões que compõe a área imageada. Todo o processamento digital das imagens foi realizado no software Pix4DMapper. Na última fase, conduzimos uma análise dos dados, associando os valores dos índices espectrais com aqueles obtidos na análise química do tecido foliar, com modelos de regressão linear e polinomial de segundo grau, e depois realizamos a sua validação.

Figura 9 – Fluxo de trabalho contendo as etapas empregadas neste estudo.

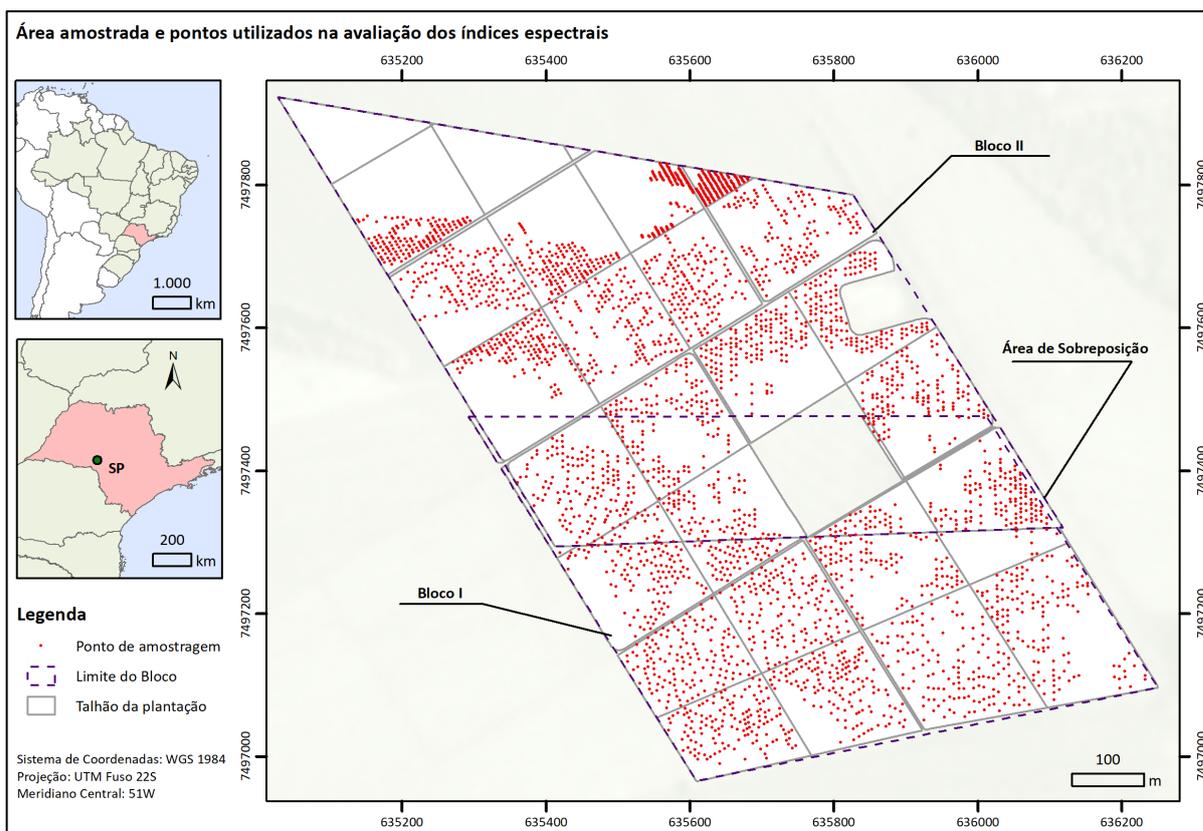


3.2.1 Levantamento dos dados em campo

O estudo foi conduzido em um pomar comercial de laranjeiras-valência (*Citrus sinensis* Valencia) sobre porta-enxerto Citrumelo Swingle. A propriedade cujo o pomar foi analisado pertence a uma área particular da Fazenda Brasília, e encontra-se localizado no município de Ubirajara, estado de São Paulo, Brasil (Figura 10). O solo é caracterizado por Argissolos Vermelho-Amarelo Abrupto (PVA4) de textura média, e o clima é classificado em CWA (Köppen), com pluviosidade anual de 1300 mm, com as estações do ano bem definidas.

As laranjeiras haviam atingido o seu estágio de maturação durante o período do nosso levantamento, com 5 anos desde o plantio inicial. O levantamento foi realizado no dia 22 de março de 2018, e as plantas se encontravam em seu estágio vegetativo. O experimento foi conduzido em área de 71,4 ha, em 24 talhões contendo 752 plantas por hectare, em espaçamento de 7 m x 1,9 m. A área recebeu a mesma quantidade de adubação; 250 kg.ha⁻¹ de nitrogênio saturado em nitrato de amônia.

Figura 10 – Área de estudo e pontos utilizados na avaliação dos índices espectrais.



O voo foi conduzido no mesmo dia da coleta das folhas, entre 13h00min e 15h00min, a 120 metros de altura em relação ao terreno, o que resultou em um GSD (*Ground Sample Distance*) de 12 cm. Utilizamos uma ARP eBee SenseFly, equipada com a câmera Parrot Sequoia e um sensor de luz (Figura 11b). Essa câmera registra imagens nas faixas: verde (510-590 nm), vermelho (620-700 nm), borda-do-vermelho (725-745 nm) e infravermelho-próximo (750-830 nm). A câmera é equipada com uma lente pancromática que permite o registro de imagens em sua cor natural, o que auxilia na identificação e interpretação dos objetos imageados em cada cena (Figura 11c).

Detectamos plantas com sintomas de clorose em suas folhas (Figura 11a e 11b), podendo ser um indicativo de deficiência nutricional relacionada ao nitrogênio. Coletamos cerca de 70 folhas por talhão, distribuídas homogeneamente, com o intuito de representar a quantidade de nitrogênio foliar média para cada talhão. A coleta das folhas ocorreu na altura média da laranjeira, retiradas do terceiro (ou do quarto) ramo frutífero. Depois, separamos e identificamos as amostras dos talhões em embalagens plásticas, e as encaminhamos para análise.

Figura 11 – Vista em campo das laranjeiras (a, b) e a vista aérea (c).



Em laboratório, as folhas foram lavadas e secas em estufa entre 60 e 65°C por 48 horas, para então serem trituradas. Aplicamos o método de titulação Kjeldahl para determinar o teor de nitrogênio foliar, do qual é dividido em três etapas, sendo: 1) digestão, 2) destilação em destilador de nitrogênio e; 3) titulação com ácido sulfúrico (H_2SO_4) (PRAC, 2018).

3.2.2 Processamento das imagens e amostragem espectral nos pontos

O processamento das imagens foi realizado no *software* Pix4DMapper, e o dividimos em dois blocos com o intuito de otimizar o processo. O processamento digital consistiu em: fototriangulação dos blocos de imagens, obtendo os parâmetros de orientação exterior e interior das imagens; a produção do MDS (Modelo Digital de Superfície) e; a geração do ortomosaico de cada bloco de imagens. Os ortomosaicos foram compostos por 2.389 cenas ao todo.

Para realizar a fototriangulação das imagens, utilizamos nove dos pontos de controle distribuídos uniformemente pela propriedade (Figura 9). Os pontos foram levantados com auxílio de um GNSS (*Global Navigation Satellite System*) Leica Plus GS15, de dupla frequência no modo RTK (*Real Time Kinematic*). Obtivemos a REQM (Raiz do Erro Quadrático Médio) na fototriangulação de 0,129 metros.

Em seguida, realizamos a correção radiométrica dos ortomosaicos, isto é, a conversão dos valores em ND (Número Digital) para a refletância de superfície. Esse processamento também foi realizado no *software* Pix4DMapper, com recursos da

Parrot Sequoia. Antes do voo, registramos uma placa de calibração colocada ao chão com a câmera Sequoia, para que o sensor pudesse determinar as condições de calibração locais. Usando os valores dessa placa, o software pode calibrar e corrigir a refletância da imagem levando em considerações as características de iluminação no momento do voo.

No ortomosaico, identificamos na plantação e inserimos 3.360 pontos sobre as laranjeiras (Figura 10), evitando áreas onde houveram falhas de plantio ou problemas de sobreposição das imagens. Depois, recortamos as imagens com base em uma máscara delimitada com os limites dos blocos, e geramos uma faixa de distância de 1 m² em cada ponto, com a finalidade de abranger a copa das laranjeiras. Nesses pontos, extraímos o valor médio da refletância de cada uma das bandas da Sequoia. Denominamos esses pontos como “amostras espectrais”, a partir das quais construímos as suas curvas espectrais médias por talhão.

3.2.3 Cálculo e validação dos índices espectrais

Pela análise química do tecido foliar das 70 folhas coletadas por talhão, determinamos o teor de nitrogênio foliar médio em cada um dos 24 talhões em estudo. Dessa maneira, obtivemos diferentes classes de nitrogênio, e associamos esses resultados com a refletância média determinada por talhão. Para isso utilizamos os pontos de amostragem distribuídos nas copas das laranjeiras, ou seja, agrupamos as assinaturas espectrais médias em função do teor de nitrogênio foliar determinado em laboratório. Em seguida, calculamos o coeficiente de correlação (r) de Pearson entre os valores dos índices e os teores de nitrogênio, o valor-p associado e a variância da distribuição de refletância para cada intervalo espectral da câmera Parrot Sequoia.

Avaliando diferentes pesquisas (CILIA *et al.*, 2014; CAMMARANO *et al.*, 2014; HUANG *et al.*, 2014; ZHENG *et al.*, 2018) e o banco do IDB (Index DataBase) (IDB, 2019), definimos, de acordo com os intervalos espectrais das bandas da Parrot Sequoia, um conjunto de índices para ser testado no presente estudo de caso (Tabela 6). Identificamos os índices de acordo com a sua finalidade (variável) e escala (dossel e/ou foliar). A referência para cada índice remete ao estudo cujo o índice foi aplicado com a mesma finalidade da variável mensurada.

Tabela 6 – Descrição dos índices espectrais de vegetação utilizados neste estudo.

Índice	Fórmula Original	Variável(is)	Escala	Referência
ARVI2 (Atmospherically Resistant Vegetation Index 2)	$-0,18 + 1,17 * \left[\frac{(R\lambda_{nir} - R\lambda_{red})}{(R\lambda_{nir} + R\lambda_{red})} \right]$	Vitalidade	Dossel	Kaufman e Tanre (1992)
CCCI (Canopy Chlorophyll Content Index)	$\frac{(R\lambda_{nir} - R\lambda_{rededge}) / (R\lambda_{nir} + R\lambda_{rededge})}{(R\lambda_{nir} - R\lambda_{red}) / (R\lambda_{nir} + R\lambda_{red})}$	Clorofila	Foliar / Dossel	Herrmann <i>et al.</i> (2010)
CG (Chlorophyll Green)	$(R\lambda_{760:800} / R\lambda_{540:560})^{-1}$	Clorofila	Foliar	Gitelson <i>et al.</i> , (2006)
Clgreen (Chlorophyll Index Green)	$(R\lambda_{nir} / R\lambda_{green}) - 1$	Clorofila / LAI	Foliar	Hunt Jr. <i>et al.</i> (2011)
Clrededge (Chlorophyll Index RedEdge)	$(R\lambda_{nir} / R\lambda_{rededge}) - 1$	Clorofila / LAI	Foliar	Hunt Jr. <i>et al.</i> (2011)
Ctr2 (Simple Ratio 695/760 Carter2)	$R\lambda_{695} / R\lambda_{760}$	Clorofila / Estresse	Foliar	le Maire <i>et al.</i> (2004)
CTVI (Corrected Transformed Vegetation Index)	$\frac{NDVI + 0,5}{ NDVI + 0,5 } * \sqrt{NDVI + 0,5}$	Vegetação	Foliar / Dossel	Perry Jr. <i>et al.</i> (1984)
CVI (Chlorophyll Vegetation Index)	$R\lambda_{nir} * (R\lambda_{red} / R\lambda_{green}^2)$	Clorofila	Dossel	Vincini <i>et al.</i> (2008)
GDVI (Difference NIR/Green Difference Vegetation Index)	$R\lambda_{nir} - R\lambda_{green}$	Vegetação	Foliar	Tucker <i>et al.</i> (1979)
GI (Simple Ratio 554/677 Greenness Index)	$R\lambda_{554} / R\lambda_{677}$	Clorofila	Foliar	Main <i>et al.</i> (2011)
GNDVI (Normalized Difference NIR/Green NDVI)	$(R\lambda_{nir} - R\lambda_{green}) / (R\lambda_{nir} + R\lambda_{green})$	Clorofila	Foliar	Wang <i>et al.</i> (2007)
GRNDVI (Green-Red NDVI)	$\frac{R\lambda_{nir} - (R\lambda_{green} + R\lambda_{red})}{R\lambda_{nir} + (R\lambda_{green} + R\lambda_{red})}$	Vegetação	Foliar / Dossel	Main <i>et al.</i> (2011)
GSAVI (Green Soil Adjusted Vegetation Index)	$\frac{(1 + L) * (R\lambda_{nir} - R\lambda_{green})}{(R\lambda_{nir} + R\lambda_{green} + L)}$	Vegetação	Dossel	IDB (2019)
IPVI (Infrared Percentage Vegetation Index)	$\frac{R\lambda_{nir}}{(R\lambda_{nir} + R\lambda_{red} / 2) * (NDVI + 1)}$	Vegetação	Dossel	Kooistra <i>et al.</i> (2003)
MCARI1 (Modified Chlorophyll Absorption in Reflectance Index 1)	$1,2 * [2,5 * (R\lambda_{800} - R\lambda_{670}) - 1,3 * (R\lambda_{800} - R\lambda_{550})]$	Clorofila	Foliar / Dossel	Haboudane <i>et al.</i> (2004)
MSAVI (Modified Soil Adjusted Vegetation Index)	$\frac{[2 * R\lambda_{nir} + 1 - \sqrt{(2 * R\lambda_{nir} + 1)^2 - 8 * (R\lambda_{nir} - R\lambda_{red})}]}{2}$	Vegetação	Dossel	Wu <i>et al.</i> (2007)
MSR (Modified Simple Ratio)	$(SR - 1) / \sqrt{(SR + 1)}$	Vegetação	Foliar	Chen (2014)
MTVI (Modified Triangular Vegetation Index)	$1,2 * [1,2 * (R\lambda_{800} - R\lambda_{550}) - 2,5 * (R\lambda_{670} - R\lambda_{550})]$	Vegetação	Foliar / Dossel	Haboudane <i>et al.</i> (2004)
ND682/553 (Normalized Difference 682/553)	$(R\lambda_{red} - R\lambda_{green}) / (R\lambda_{red} + R\lambda_{green})$	Vegetação	Foliar / Dossel	Main <i>et al.</i> (2011)
NDVI (Normalized Difference Vegetation Index)	$(R\lambda_{nir} - R\lambda_{red}) / (R\lambda_{nir} + R\lambda_{red})$	Biomassa / Outros	Foliar / Dossel	Huang <i>et al.</i> (2010)
Norm G (Normalized G)	$R\lambda_{green} / (R\lambda_{nir} + R\lambda_{red} + R\lambda_{green})$	Vegetação	Foliar / Dossel	IDB (2019)
Norm NIR (Normalized NIR)	$R\lambda_{nir} / (R\lambda_{nir} + R\lambda_{red} + R\lambda_{green})$	Vegetação	Foliar / Dossel	IDB (2019)
Norm R (Normalized R)	$R\lambda_{red} / (R\lambda_{nir} + R\lambda_{red} + R\lambda_{green})$	Vegetação	Foliar / Dossel	IDB (2019)
OSAVI (Optimized Soil Adjusted Vegetation Index) ^I	$\frac{(1 + Y) * (R\lambda_{800} - R\lambda_{670})}{(R\lambda_{800} + R\lambda_{670} + Y)}$	Vegetação	Dossel	Main <i>et al.</i> (2011)
RDVI (Renormalized Difference Vegetation Index)	$(R\lambda_{800} - R\lambda_{670}) / \sqrt{(R\lambda_{800} + R\lambda_{670})}$	Clorofila	Foliar / Dossel	Main <i>et al.</i> (2011)
SAVI (Soil-Adjusted Vegetation Index) ^{II}	$\frac{(1 + L) * (R\lambda_{800} - R\lambda_{670})}{(R\lambda_{800} + R\lambda_{670} + L)}$	Biomassa	Dossel	Hunt Jr. <i>et al.</i> (2011)
SR672/550 (Simple Ratio 672/550 Datt5)	$R\lambda_{672} / R\lambda_{550}$	Clorofila	Foliar	Main <i>et al.</i> (2011)
SR750/550 (Simple Ratio 750/550 Gitelson and Merzlyak 1)	$R\lambda_{750} / R\lambda_{550}$	Clorofila	Foliar	Main <i>et al.</i> (2011)
SR800/550 (Simple Ratio 800/550)	$R\lambda_{800} / R\lambda_{550}$	Clorofila / Biomassa	Foliar	Ahamed <i>et al.</i> (2010)
TraVI (Transformed Vegetation Index)	$\sqrt{NDVI + 0,5}$	Vegetação	Foliar / Dossel	Hunt Jr. <i>et al.</i> (2011)
TriVI (Triangular Vegetation Index)	$0,5 * [120 * (R\lambda_{750} - R\lambda_{550}) - 200 * (R\lambda_{670} - R\lambda_{550})]$	Clorofila	Foliar / Dossel	Eitel <i>et al.</i> (2007)
VIN (Vegetation Index Number) ou SR (Simple Ratio)	$R\lambda_{nir} / R\lambda_{red}$	Vegetação	Foliar	Ahamed <i>et al.</i> (2010)
WDRVI (Wide Dynamic Range Vegetation Index)	$(0,1 * R\lambda_{nir} - R\lambda_{red}) / (0,1 * R\lambda_{nir} + R\lambda_{red})$	Biomassa / LAI	Foliar / Dossel	Herrmann <i>et al.</i> (2011)

I L = 0,5; II Y = 0,16; NDVI = *Normalized Differential Vegetation Index*; SR = *Simple Ratio*; LAI = *Leaf Area Index* (Índice de Área Foliar). A variável "Vegetação" indica que a aplicabilidade do índice se dá em um sentido geral, e não específico como os demais; NIR = infravermelho-próximo; RedEdge = borda-do-vermelho; Red = vermelho; Green = verde.

Dividimos o conjunto de 3360 pontos em dois subconjuntos de mesmo tamanho (1680 pontos cada), conforme as recomendações de (DORIGO *et al.*, 2007). Um subconjunto foi utilizado para obter a equação da regressão que relaciona o valor do índice espectral, medido nos pontos de amostragem distribuídos nas copas das laranjeiras, com o teor de nitrogênio determinado em laboratório. O outro subconjunto foi utilizado para validar o modelo de regressão gerado.

Para cada índice espectral de vegetação, estimamos o coeficiente de regressão (R^2), a REQM, a equação da regressão, o valor crítico de F, o coeficiente de correlação (r) e o valor-p associado. Na validação cruzada, comparamos o R^2 e a REQM de ambos os subconjuntos; aquele utilizado para a criação do modelo, e aquele para estimar sua acurácia. Por último, avaliamos o tempo de processamento, em segundos, que cada índice exigiu.

A combinação dos índices espectrais foi realizada separando aqueles que consideram a influência da linha de solo em sua resposta (SAVI, OSAVI, MSAVI e GSAVI). A combinação desses índices espectrais com os índices desenvolvidos para a análise da pigmentação (clorofila) pode melhorar a acurácia dos índices (CILIA *et al.*, 2014; CHEN *et al.*, 2010). Em seguida, avaliamos a correlação entre os demais índices (não desenvolvidos especificamente para avaliar a clorofila) para determinar aqueles que melhor se relacionavam com os índices de linha de solo. A partir da análise dos coeficientes de correlação significativos, combinamos esses índices em uma razão simples.

Por último, optamos por gerar uma carta temática para o resultado com o índice espectral de maior acurácia no teste de inferência do teor de nitrogênio foliar em laranjeiras-valência. Os valores de nitrogênio foram divididos em três intervalos, correspondentes aos níveis críticos do nutriente estimados para a produtividade da planta (QUAGGIO *et al.*, 1998). As classes foram de: 23,5 até 26,9 g.kg^{-1} ; de 27,0 até 28,9 g.kg^{-1} , e; de 29,0 até 29,5 g.kg^{-1} . Os valores abaixo de 23,5 g.kg^{-1} e acima de 29,5 g.kg^{-1} , por não se enquadrarem nesses intervalos, foram removidos do resultado final.

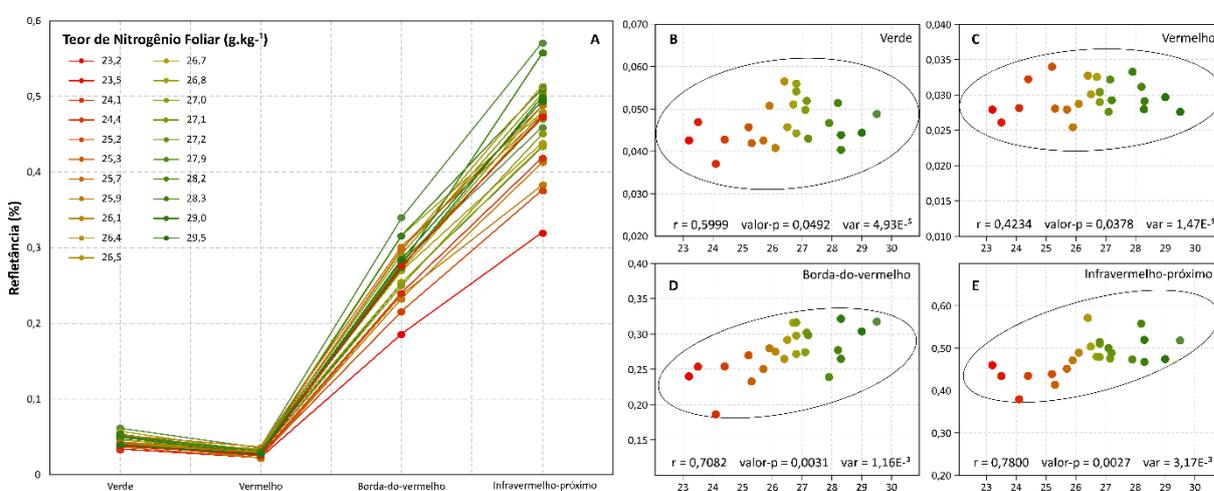
3.3 Resultados e Discussão

A região espectral do visível, em específico nas faixas do verde e do vermelho, é comumente associada com o nitrogênio foliar (ZHAO *et al.*, 2010). Isso

porque o nutriente é essencial para a clorofila, e sua presença em níveis adequados estabiliza a atividade fotossintética (ZHAI *et al.*, 2013). O comportamento espectral de uma planta cítrica é semelhante ao de qualquer outro vegetal (XUEFENG *et al.*, 2016). Conforme ocorre o aumento no teor de nitrogênio foliar, há uma redução na refletância da região espectral do vermelho, e um aumento na região do verde (HUERTA *et al.*, 2013).

A partir das refletâncias médias de cada teor de nitrogênio foliar (Figura 12), observamos a influência do nutriente no comportamento espectral da laranja. Esse comportamento espectral foi semelhante ao encontrado em outras culturas (LI *et al.*, 2012; LI *et al.*, 2018; HOULES *et al.*, 2007). Observamos que os valores de refletância nas faixas do verde ($r = 0,60$) (Figura 12B), da borda-do-vermelho ($r = 0,71$) (Figura 12D) e do infravermelho-próximo ($r = 0,78$) (Figura 12E) obtiveram correlações positivas mais elevadas com o teor de nitrogênio foliar.

Figura 12 – Representação das refletâncias médias em função do teor de nitrogênio foliar em laranjas-valência.



Ao avaliarmos a região espectral do verde, constatamos que o aumento do nitrogênio foliar causou o aumento da refletância nesta faixa. Essa influência do nitrogênio foi observada em outras plantas (SONG; WANG 2016; THOMASON *et al.*, 2011, YU *et al.*, 2014). Apesar disso, esse intervalo tem se mostrado pouco eficaz em discriminar folhas com alto teor do nutriente (WANG *et al.*, 2013; MOKHELE; AHMED, 2010; MOHARANA; DUTTA, 2016).

Na faixa espectral do vermelho (Figura 12C), comumente associada com a absorção de energia pela molécula de clorofila (CROFT *et al.*, 2017; DELLOYE *et*

al., 2018), também ocorreu uma correlação positiva. Isso não é esperado neste tipo de análise, uma vez que o aumento do nitrogênio foliar está relacionado com o aumento da clorofila, que por sua vez reduziria a refletância nesta região do espectro (WANG *et al.*, 2017). Não obstante, trata-se de uma baixa correlação (0,42), e de um aumento de refletância pequeno (abaixo de 0,05), com variação menor do que aquelas encontradas para as demais faixas.

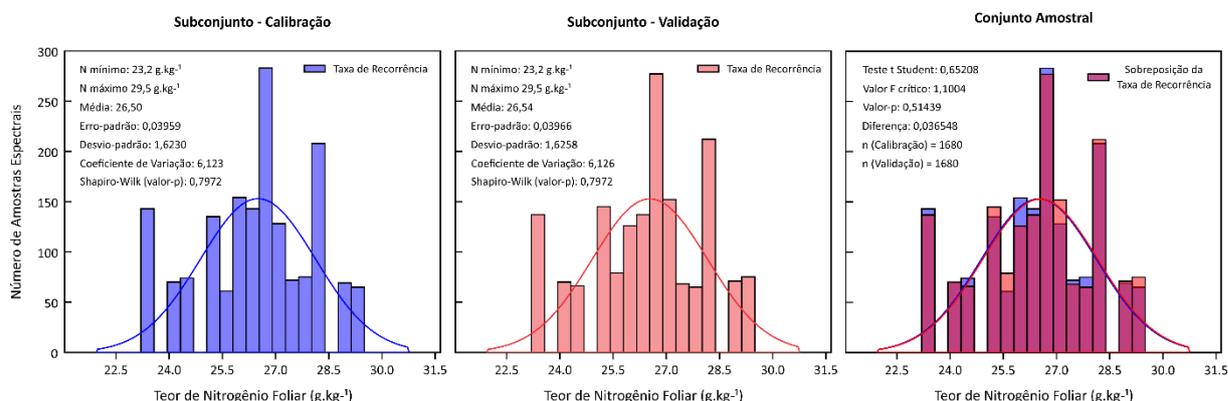
Um intervalo espectral considerado estratégico para o monitoramento do nitrogênio em plantas é a borda-do-vermelho, pois alterações em sua curva indicam altas correlações com a quantidade de nitrogênio presente nas plantas (ATZBERGER *et al.*, 2010). Essa condição está relacionada ao antagonismo entre a elevada taxa de absorção da região do vermelho, pelas moléculas de clorofila, com a elevada taxa de espalhamento e refletância que as plantas, em condições saudáveis, apresentam na região do infravermelho-próximo (LI *et al.*, 2014). No caso das laranjeiras estudadas, a borda-do-vermelho apresentou comportamento mais correlacionado ao nitrogênio do que as faixas do visível (verde e vermelho).

Em relação às variações no comportamento espectral das laranjeiras na faixa do infravermelho-próximo, essas estão associadas com a organização estrutural de moléculas intracelulares do mesófilo (YANLI *et al.*, 2015). O aumento de nitrogênio foliar está relacionado com o aumento na refletância nessa região, e o comportamento espectral observado nas laranjeiras nessa faixa espectral corrobora com o encontrado em outras pesquisas (CONNELL *et al.*, 2016; ATZBERGER *et al.*, 2010; WANG *et al.*, 2017; STELLACCI *et al.*, 2016; MIPHOKASAP; WANNASIRI, 2018). A alta refletância no infravermelho-próximo pode ser explicada pelo maior espalhamento múltiplo de radiação no tecido esponjoso do mesófilo, normalmente provocado pelas folhas mais novas (XUEFENG *et al.*, 2016).

3.3.1 Validação-cruzada dos índices espectrais individuais e combinados

As bandas individuais são importantes para explicar o comportamento espectral da vegetação. Porém, índices espectrais foram desenvolvidos para avaliar, com maior ênfase, os parâmetros biofísicos (FENG *et al.*, 2015). Para tanto, os pontos amostrados na imagem (Figura 10), e utilizados para compor as refletâncias médias (Figura 12A), apresentaram distribuições semelhantes tanto para o subconjunto da calibração como para o subconjunto da validação (Figura 13).

Figura 13 – Distribuição dos pontos de amostragem espectral em função do teor de nitrogênio foliar.



Ambos os subconjuntos amostrais apresentam normalidade (Figura 13) entre os dados, e não encontramos diferenças entre os conjuntos por meio do teste de médias aplicado (p -valor = 0,514). A sobreposição dos dados também demonstra como as frequências de distribuição dos pontos são próximas em todo o conjunto. Assim, consideramos que o modelo construído para a validação dos índices testados é adequado, e que pode ser utilizado na análise de inferência do nitrogênio.

A partir do subconjunto de calibração, levantamos as relações de cada um dos índices testados, derivados das bandas multiespectrais da câmera Parrot Sequoia. Constatamos que 12 dos índices testados (Tabela 7) apresentaram uma alta correlação ($r \geq 0,7$) com o nitrogênio nos dados de ajuste dos modelos de regressão linear e polinomial. Todavia, valores mais baixos de correlação (0,5) já foram utilizados em outras pesquisas para determinar regiões mais propícias a estimativa de nitrogênio em citrus (MIN; LEE, 2005). Ademais, pelo menos 7 dos 33 índices atingiram valores iguais ou superiores ($r \geq 0,78$) a aqueles obtidos na análise das bandas individuais, em específico para a faixa do infravermelho-próximo, que obteve melhor resultado (Figura 12E).

Tabela 7 – Análise de regressão entre os índices espectrais e o teor de nitrogênio.

Índice	R ²	REQM	Equação da Regressão	F	r	valor-p
Acronônimo	Calibração	Calibração	----- Calibração -----	Regressão	Calibração	Correlação
ARVI2	0,12	2,014	67,36x - 31,18	0,4199	0,3504	0,5234
CCCI	0,17	1,975	86,55x - 0,004121	0,5561	0,3954	0,4633
CG	0,77	1,023	3,008x - 5,782	10,2580	0,8796	0,0039
CI_{green}	0,77	1,023	3,008x - 2,774	10,2580	0,8796	0,0039
CI _{rededge}	0,26	1,853	26,13x + 6,714	1,0393	0,5072	0,3185
Ctr2	0,11	2,031	-125,5x + 34,09	0,3623	-0,3282	0,5531
CTVI	0,12	2,020	178,9x - 184,1	0,4000	0,3430	0,5333
CVI	0,71	1,159	3,572x + 0,2191	7,3310	0,8424	0,0125
GDVI	0,63	1,015	-698,6x² + 607,1x - 104,9	2,8764	0,6996	0,1033
GI	0,30	1,797	-23,09x + 62,69	1,2963	-0,5493	0,2666
GNDVI	0,62	1,331	186x - 126,6	4,8260	0,7853	0,0383
GRNDVI	0,36	1,721	82,78x - 33,62	1,6837	0,5996	0,2072
GSAVI	0,72	0,879	-1608x² + 1989x - 588,1	3,2110	0,7190	0,0863
IPVI	0,13	2,006	87,83x - 51,58	0,4487	0,3607	0,5096
MCARI1	0,65	0,988	-394,2x ² + 523,7x - 46,9	2,4850	0,6731	0,1285
MSAVI	0,86	0,613	-1748x ² + 2431x - 817,1	6,3653	0,6626	0,0190
MSR	0,23	1,887	6,52x + 2,101	0,8944	0,4792	0,3541
MTVI	0,65	0,988	-394,2x ² + 523,7x - 46,9	2,4850	0,6731	0,1285
ND682/553	0,11	2,029	37x + 33,79	0,3713	0,3319	0,5482
NDVI	0,12	2,014	78,81x - 43,3	0,4199	0,3504	0,5234
Norm G	0,67	1,234	-438,4x + 63,11	6,1050	-0,8188	0,0213
Norm NIR	0,36	1,721	165,6x - 116,4	1,9838	0,5996	0,1723
Norm R	0,11	2,030	-168,6x + 35,29	2,8698	-0,3288	0,1037
OSAVI	0,49	1,529	68,43x - 25,89	2,9349	0,7032	0,1001
RDVI	0,74	0,854	-2168x² + 2671x - 795,3	2,9289	0,7028	0,1004
SAVI	0,78	0,785	-2123x ² + 2747x - 861,5	3,4944	0,6813	0,0743
SR672/550	0,10	1,575	-881,4x ² + 1197x - 379,4	0,1227	0,1982	0,7293
SR750/550	0,81	0,941	7,301x - 18,77	12,6620	0,8991	0,0016
SR800/550	0,77	1,023	3,008x - 5,782	10,2580	0,8796	0,0039
T _{ra} VI	0,12	2,020	178,9x - 184,1	0,4000	0,3430	0,5333
T _{ri} VI	0,53	1,835	-0,7818x ² + 24,49x - 164,3	1,1190	0,5212	0,3011
VIN	0,27	1,832	0,9866x + 9,754	1,1346	0,5238	0,2978
WDRVI	0,58	1,076	-466,2x ² + 238,9x - 3,666	3,1659	0,7166	0,0884

*Índices destacados em negrito apresentaram coeficientes de correlação (r) próximos ou superiores à 0,70.

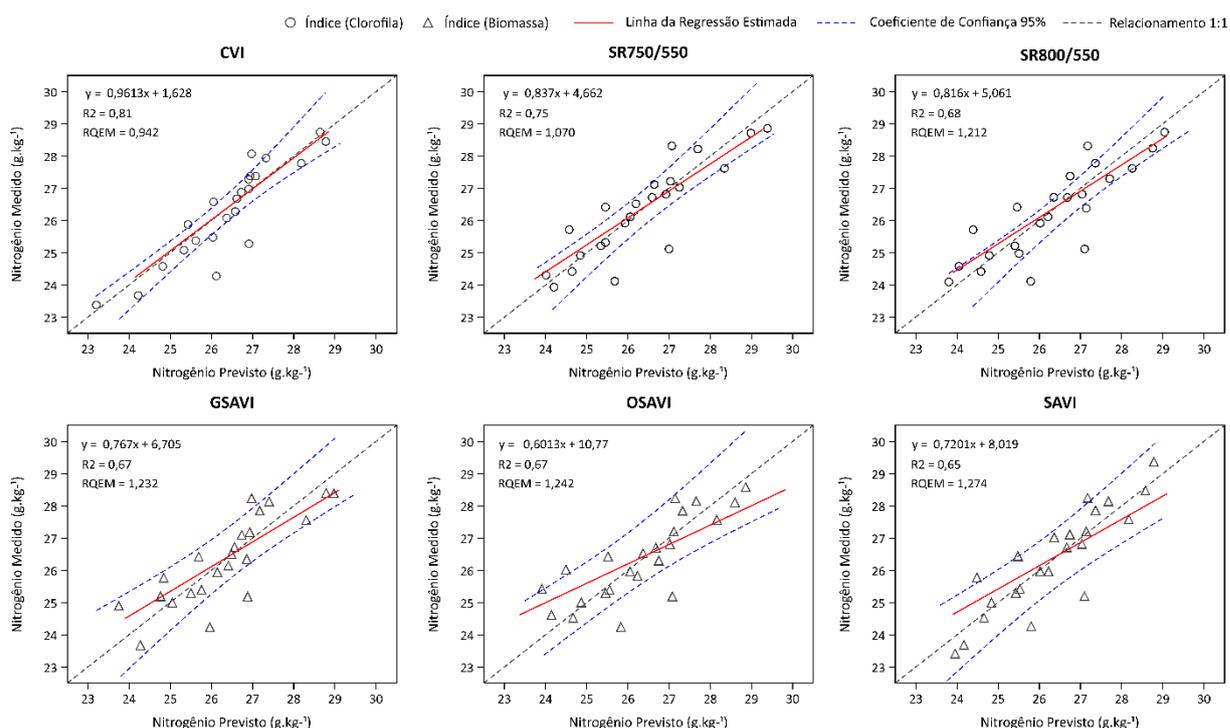
Na sequência, realizamos a validação cruzada dos índices testados, categorizando esses índices de acordo com a variável de análise para a qual foram desenvolvidos (Tabela 8). Os índices espectrais desenvolvidos para a avaliação da clorofila que apresentaram melhores resultados na estimativa do teor de nitrogênio foram o CVI e o SR750/550, com R² de 0,81 e 0,75, respectivamente, e os índices CG, CI_{green} e SR800/550, com R² de 0,68. No caso dos índices desenvolvidos para a avaliação da biomassa e demais parâmetros, o GSAVI, MSAVI e o SAVI obtiveram

as melhores previsões do teor de nitrogênio foliar, com o R^2 equivalente a 0,67, 0,67 e 0,65, respectivamente. Optamos por representar a regressão e a distribuição das médias entre o nitrogênio foliar medido e o nitrogênio foliar previsto para esses índices (Figura 14).

Tabela 8 – Validação-cruzada entre os índices espectrais analisados neste estudo.

Índice Acrônimo	R ² Validação	REQM Validação	Tempo de Processamento	Índice Acrônimo	R ² Validação	REQM Validação	Tempo de Processamento
Índices para a avaliação de clorofila e pigmentos				Índices para a avaliação de biomassa e demais parâmetros			
CVI	0,81	0,942	9,105"	GSAVI	0,67	1,232	8,974"
SR750/550	0,75	1,070	7,289"	MSAVI	0,67	1,242	11,238"
CG	0,68	1,212	8,547"	SAVI	0,65	1,274	9,011"
Cl _{green}	0,68	1,212	8,147"	Norm G	0,60	1,354	8,021"
SR800/550	0,68	1,212	7,302"	GDVI	0,60	1,356	7,058"
RDVI	0,65	1,264	8,852"	MTVI	0,60	1,364	10,478"
MCARI1	0,60	1,364	10,486"	WDRVI	0,52	1,488	10,882"
GNDVI	0,57	1,410	8,158"	Norm NIR	0,41	1,645	7,998"
GI	0,46	1,579	7,789"	GRNDVI	0,41	1,645	9,487"
T _r VI	0,33	1,759	9,878"	OSAVI	0,40	1,662	9,178"
SR672/550	0,28	1,818	7,321"	VIN	0,38	1,698	7,428"
Cl _{rededge}	0,25	1,856	8,089"	MSR	0,32	1,774	8,425"
CCCI	0,18	1,943	12,485"	ND682/553	0,29	1,813	7,842"
Ctr2	0,17	1,961	7,874"	IPVI	0,20	1,929	8,789"
				NDVI	0,19	1,939	8,486"
				ARVI2	0,19	1,939	8,945"
				CTVI	0,18	1,947	8,456"
				T _{ra} VI	0,18	1,947	8,097"
				Norm R	0,17	1,962	8,068"

Figura 14 – Dispersão para a validação-cruzada dos índices espectrais.



Como critério de desempate para os índices CG, Clgreen e SR800/550, que apresentaram o mesmo coeficiente de regressão e a mesma REQM, utilizamos o tempo de processamento, que foi menor para o índice SR800/550. Estimamos que esses índices apresentaram resultados iguais devido a própria semelhança de seus cálculos. Não obstante, como SR800/550 é uma razão simples entre as bandas, torna-se um índice mais fácil de ser aplicado mesmo por outros sensores.

Outro índice comumente utilizado para a avaliação do nitrogênio foliar é o GNDVI. Esse índice demonstrou estar relacionado com o nutriente em culturas como o trigo-de-inverno, com R^2 de 0,70 (LI *et al.*, 2018), e o milho, com R^2 de 0,88 (LI *et al.*, 2014). Porém, o mesmo apresentou R^2 de 0,29 na avaliação do arroz (HUANG *et al.*, 2017), indicando que nem sempre produz uma boa estimativa. Em nosso estudo de caso, o GNDVI obteve resultados medianos (R^2 de 0,57), o que não consideramos como suficiente para caracterizar o teor de nitrogênio foliar de laranjeiras-valência.

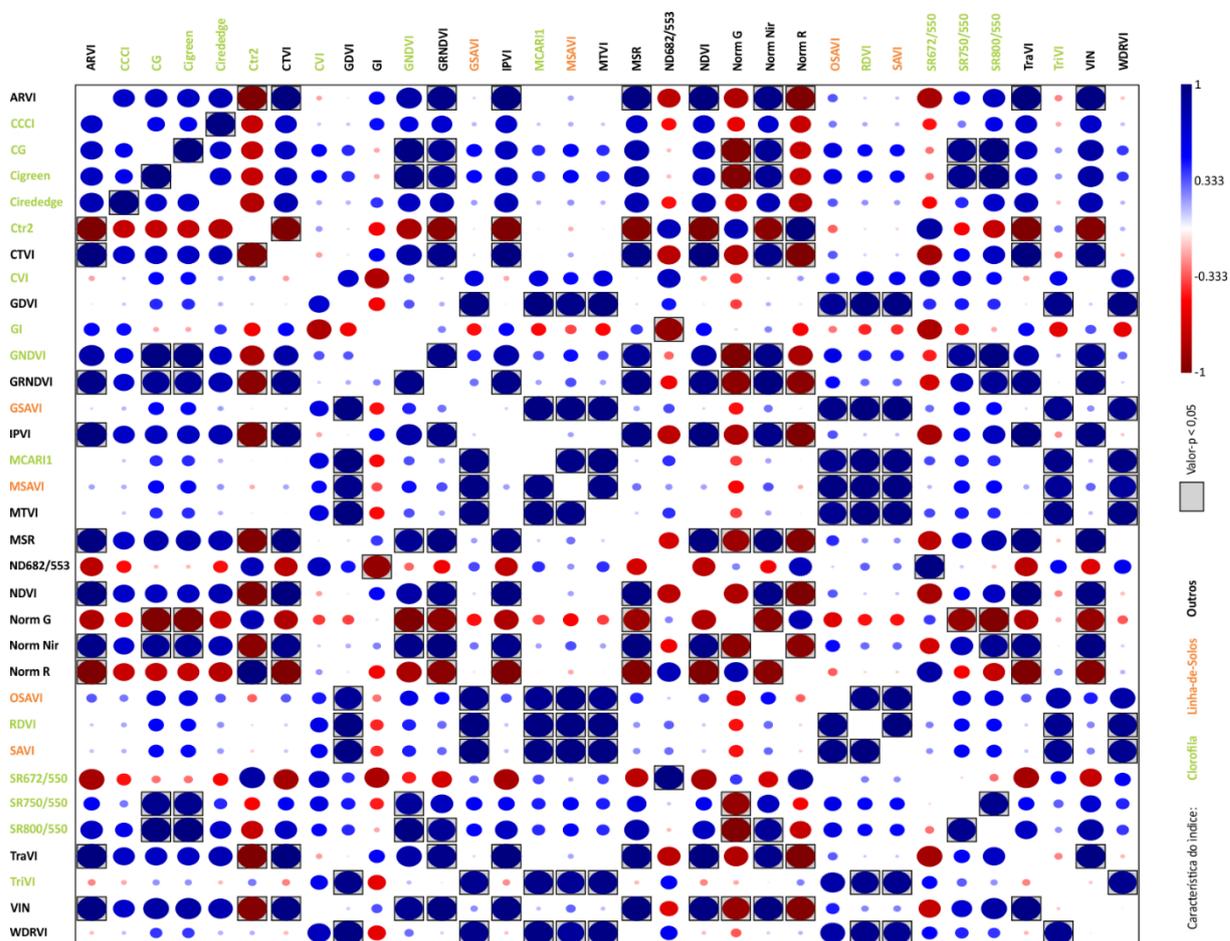
Os índices relacionados a biomassa, de um modo geral, apresentaram problemas para avaliar as quantidades de nitrogênio foliar; condição, esta, observada na literatura (KNOBLAUCH *et al.*, 2017). Essa baixa performance também pode estar associada com as características da planta analisada, uma vez que a laranjeira é uma planta perene e, por se encontrar em estágio vegetativo no período da análise, não apresentou variações elevadas com relação a sua biomassa, mas sim com a clorose foliar (Figura 11a e 11b).

Os índices desenvolvidos para a avaliação da clorofila foram melhores devido a relação direta que o pigmento possui com o teor de nitrogênio. Entretanto, estudos recentes indicam a razão entre índices como uma alternativa potencialmente adequada para identificar o nitrogênio foliar (KOOISTRA; CLEVERS, 2016; CILIA *et al.*, 2014). Isso porque a razão entre um índice desenvolvido para avaliar o pigmento, a nível foliar, com um índice desenvolvido ao nível de dossel considerando o brilho do solo, minimiza os impactos provenientes do sombreamento e propagação de energia radiométrica do substrato (CAMMARANO *et al.*, 2014). A combinação desses índices tende a normalizar as diferenças proporcionadas por esses efeitos.

Para avaliar a relação entre os índices que consideram a linha de solo (SAVI, MSAVI, OSAVI e GSAVI), com os demais índices, produzimos uma matriz de correlação (Figura 15). Essa matriz demonstrou que os índices GDVI, MTVI e

WDRVI, apesar de não serem desenvolvidos para a avaliação da clorofila, apresentaram correlações significativas com os índices de linha de solo.

Figura 15 – Matriz de correlação entre os índices espectrais testados neste estudo.



O cálculo das razões entre os índices resultou em muitas combinações, com valores variados de correlação com o nitrogênio foliar medido. Por essa razão, optamos por apresentar somente as melhores combinações obtidas, com coeficiente de correlação (r) próximo ou acima de 0,70 (Tabela 9). As combinações realizadas com os índices Cgreen, GI, RDVI e WDRVI apresentaram as melhores relações com os dados de calibração

Tabela 9 – Análise de regressão das melhores combinações de índices espectrais.

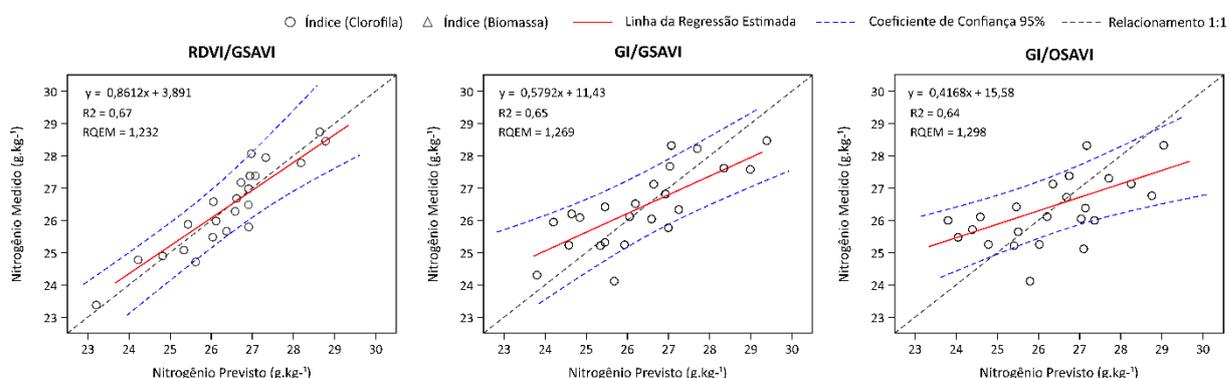
Razão entre Índices	R ²	REQM	Equação	F	r	valor-p
	Calibração	Calibração	----- Calibração -----	Regressão	Calibração	Correlação
Clgreen/OSAVI	0,51	1,506	2,317x - 3,248	3,1090	0,7134	0,0911
GI/GSAVI	0,78	0,432	-31,52x ² + 156,3x - 166,4	4,4098	-0,7714	0,0469
GI/MSAVI	0,77	0,479	-39,75x ² + 174,9x - 165	4,0058	-0,7561	0,0572
GI/OSAVI	0,90	0,940	-169,3x ² + 689,9x - 674,9	8,5531	-0,7859	0,0076
GI/SAVI	0,78	0,692	-40,28x ² + 190,7x - 198,3	4,0653	-0,7585	0,0555
RDVI/GSAVI	0,89	0,925	-74202,5x ² + 148754x - 74523,7	8,0786	-0,7900	0,0092
WDRVI/GSAVI	0,50	1,527	32,68x + 14,09	2,9456	0,7038	0,0995
WDRVI/MSAVI	0,48	1,554	37,34x + 14,01	2,7425	0,6910	0,1112
WDRVI/OSAVI	0,49	1,540	33,74x + 16,13	2,8453	0,6976	0,1051
WDRVI/SAVI	0,50	1,514	34,04x + 14,22	3,0442	0,7096	0,0943

A partir da análise de regressão entre os dados de validação, estimamos os valores de regressão e o tempo de processamento para as razões entre os índices (Tabela 10). As combinações realizadas com os índices RDVI/GSAVI, GI/GSAVI e GI/OSAVI atingiram os melhores resultados, com R² equivalente a 0,67, 0,65 e 0,64, e REQM de 1,232, 1,269 e 1,298, respectivamente (Figura 16).

Tabela 10 – Validação-cruzada entre as combinações de índices espectrais.

Razão entre Índices	R ²	REQM	Tempo de Processamento	Razão entre Índices	R ²	REQM	Tempo de Processamento
<i>Índices para a avaliação de clorofila e pigmentos</i>				<i>Índices para a avaliação de biomassa e demais parâmetros</i>			
Clgreen/OSAVI	0,56	1,383	12,582"	WDRVI/GSAVI	0,28	1,821	14,058"
GI/GSAVI	0,65	1,269	12,182"	WDRVI/MSAVI	0,27	1,835	14,348"
GI/MSAVI	0,63	1,303	12,004"	WDRVI/OSAVI	0,29	1,817	14,587"
GI/OSAVI	0,64	1,298	12,537"	WDRVI/SAVI	0,30	1,804	13,987"
GI/SAVI	0,63	1,301	12,345"				
RDVI/GSAVI	0,67	1,232	13,441"				

Figura 16 – Dispersão para a validação das combinações de índices.

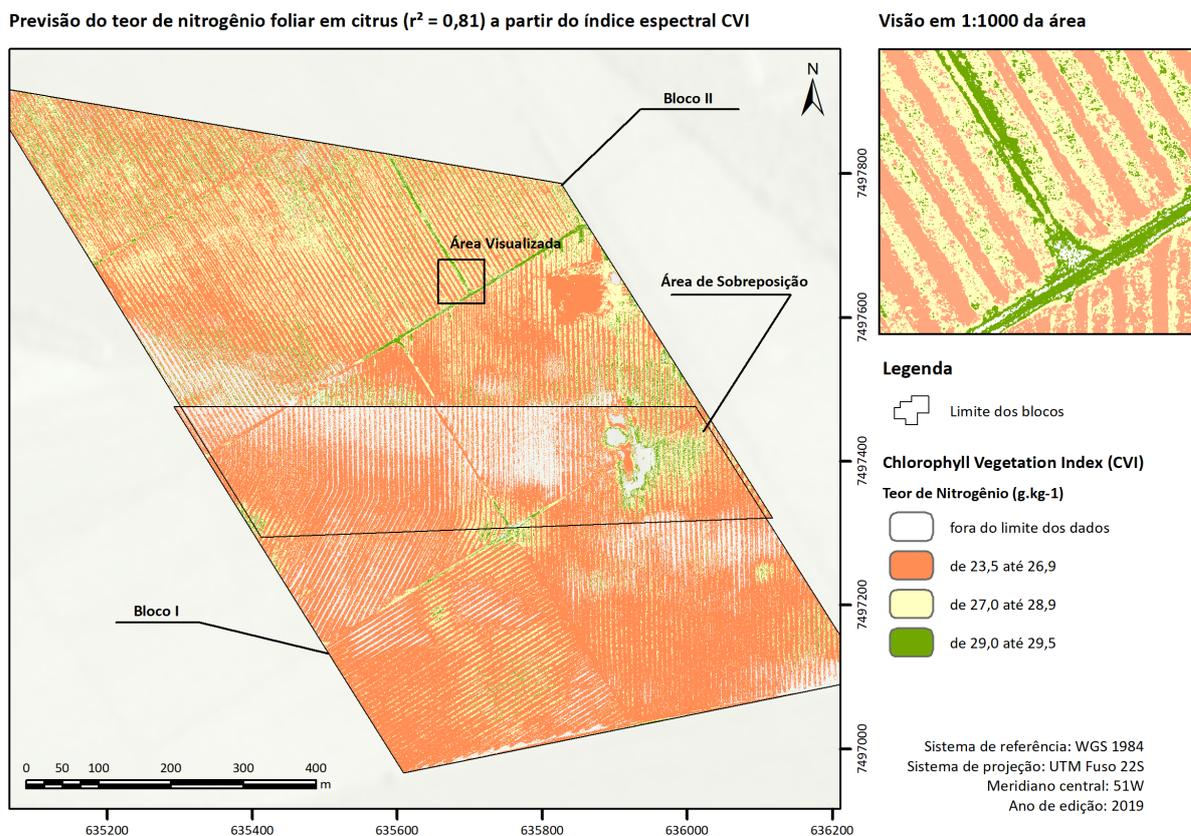


A combinação de índices como MCARI/OSAVI, TCARI/OSAVI; MCARI/MTVI2; MTCI/MSAVI, e mesmo outras combinações são comuns na literatura, e foram testadas para diferentes culturas. Para a avaliação do teor de nitrogênio foliar em trigo, o MCARI/MTVI2 obteve um R^2 de 0,59, enquanto o TCARI/OSAVI obteve melhor valor para a avaliação do milho, com R^2 de 0,66 (CHEN *et al.*, 2010). Por outro lado, essa combinação MCARI/MTVI2 apresentou baixa correlação com o trigo-de-inverno, com um R^2 de 0,0067 (HUANG *et al.*, 2014). Também na avaliação do nitrogênio em milho, por meio de imagens aéreas, a combinação MCARI/MTVI2 foi considerada a melhor, atingindo um R^2 de 0,59 (CILIA *et al.*, 2014). Apesar disso, o mesmo estudo conclui que o índice individual MTVI2 apresentou um R^2 superior, de 0,80.

O cálculo da combinação dos índices resultou em correlações próximas e acima de 0,7. No caso dos índices GI, RDVI e WDRVI, os resultados da correlação e da regressão foram superiores aos obtidos com esses índices individualmente, o que comprova a eficiência da razão entre índices em otimizar alguns dos índices que não consideram a linha de solo em seu cálculo. Observamos que, apesar da combinação melhorar a relação entre certos índices espectrais com o nitrogênio, é exigido um tempo de processamento maior devido a complexibilidade do cálculo. Isso pode ser considerado um fator de complicação para análises envolvendo conjuntos de imagens superiores ao testado neste estudo.

A partir das constatações entre os índices e combinações, optamos por representar visualmente o índice CVI (Figura 17), pois o consideramos como o índice espectral mais adequado para a estimativa do teor de nitrogênio foliar em laranjeiras-valência. Observamos que para as áreas não ocupadas com laranjeiras, como as construções e as estradas de acesso, e em áreas onde houveram problemas mais intensos causados pela saturação da imagem, os valores foram abaixo de qualquer outra classe de nitrogênio medido (na legenda, abaixo de $23,5 \text{ g.kg}^{-1}$).

Figura 17 – Inferência do teor de nitrogênio foliar em citrus a partir do índice CVI.



O CVI não separou adequadamente as laranjeiras de outras plantas, como o caso das gramíneas, que se encontravam em altas densidades entre as ruas da plantação. O índice, ainda, confundiu as áreas ocupadas por estradas e vias com elevadas concentrações de nitrogênio (Figura 17 – Visão em 1:1000 da área). Por essas razões, o emprego de índices espectrais em imagens para culturas ainda é limitado, pois não garante a separabilidade do alvo. Ainda assim, sua relação com o nutriente é interessante, e serve como um indicativo para discriminar linearmente o teor de nitrogênio foliar.

O CVI foi desenvolvido com o intuito de avaliar a clorofila total da planta a partir da análise dos valores de refletância na região do verde, do vermelho e do infravermelho (VINCINI *et al.*, 2008). O índice permite avaliar o conteúdo de clorofila ao nível de dossel, e por isso não especifica o comprimento de onda necessário, mas apenas a faixa espectral ou banda a ser utilizada. Essa condição é interessante, pois permite que o índice seja aplicado por diferentes sensores, inclusive multiespectrais. Apesar da resolução espectral da câmera Parrot Sequoia nas bandas utilizadas para compor o índice ser de 100 nm cada, o resultado pode

ser considerado adequado. O CVI apresentou, para laranjeiras, resultados semelhantes a aqueles encontrados para outras culturas com diferentes índices (KALACSKA *et al.*, 2015; CILIA *et al.*, 2014; HUANG *et al.*, 2014; ZHENG *et al.*, 2018).

3.4 Conclusões

Concluimos que o índice espectral CVI é o mais adequado para estimar o teor de nitrogênio entre o conjunto de índices testados, uma vez que apresentou um R^2 de 0,81 e uma REQM de $0,942 \text{ g.kg}^{-1}$. Em geral, índices espectrais desenvolvidos para determinar a clorofila foram superiores a aqueles desenvolvidos para avaliar a biomassa e os demais parâmetros da vegetação. Já os índices desenvolvidos para avaliar a nível foliar não se mostraram interessantes devido à limitação imposta pelas bandas do sensor utilizado no presente estudo, uma vez que esses índices exigem intervalos específicos em seus cálculos.

A combinação de índices, dada pela razão entre o índice desenvolvido para avaliar a clorofila, com índices desenvolvidos considerando a linha de solo, permite melhorar a estimativa do teor de nitrogênio foliar, atingindo resultados superiores aos comparados dos mesmos índices individuais. A combinação, porém, não foi superior ao índice individual CVI. Por último, entendemos que, apesar de as bandas individuais indicarem uma correlação positiva com o nutriente, os índices espectrais demonstraram essa relação com mais clareza. Consideramos, portanto, o emprego de índices espectrais como adequado para estimar o teor de nitrogênio foliar em laranjeiras ao nível multiespectral com imagens de alta resolução espacial.

4 CONCLUSÃO GERAL

Nossa pesquisa inferiu o teor de nitrogênio foliar em laranjeiras-valência por meio de imagens multiespectrais de alta resolução espacial e, para isso, testamos duas abordagens distintas. Comprovamos que é possível classificar e estimar o teor de nitrogênio foliar ao nível multiespectral de alta resolução espacial. A abordagem de empregar imagens multiespectrais, adquiridas por sensor embarcado em plataforma do tipo ARP, ao monitoramento do nitrogênio na laranjeira-valência, até o momento, é inovadora. Outros estudos aplicaram diferentes métodos para medir o nitrogênio em plantas cítricas, porém esses correspondem a técnicas diferentes e plantas de menor representatividade do gênero citrus do que as valências.

O estudo de caso conduzido demonstrou que o *Spectral Angle Mapper* é o classificador mais indicado para inferir o teor de nitrogênio em laranjeiras-valência (acurácia global de 87,5% e coeficiente *kappa* de 0,75), tendo as curvas espectrais como dados de entrada. O classificador apresentou alta capacidade de diferenciar as plantas com nitrogênio em quantidade “médio” e “baixo”. Além disso, o algoritmo foi eficaz em reduzir a influência dos efeitos de iluminação, além de apresentar bom desempenho para separar a planta de outros alvos, como estradas e gramíneas.

Demostramos que os índices espectrais de vegetação são válidos para discriminar as quantidades de nitrogênio em laranjeiras-valência. Concluímos que o *Chlorophyll Vegetation Index* é o índice que melhor caracteriza o teor de nitrogênio foliar. Embora desenvolvido ao nível de dossel, esse índice inferiu o nitrogênio em laranjeiras com boa acurácia ($R^2 = 0,81$ e $REQM = 0,942 \text{ g.kg}^{-1}$). O CVI consiste-se em uma alternativa pouco complexa, e pode ser aplicado em imagens adquiridas por diferentes sensores por não exigir, no cálculo, comprimentos de onda específicos.

Recomendamos a aplicação das abordagens metodológicas propostas neste estudo em outras culturas agrícolas. Outra possibilidade é testar a abordagem em imagens de menor resolução espacial, obtidas por sensores orbitais. Sugerimos investigar o potencial da abordagem proposta em monitorar o teor de nitrogênio em laranjeiras-valência em momentos diferentes daquele testado neste estudo. Ademais, apontamos a necessidade de trabalhos futuros que investiguem algoritmos de aprendizagem de máquina para otimizar a separação das laranjeiras dos demais alvos, com melhor eficiência, no processo de classificação das imagens.

REFERÊNCIAS

- AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K. C. A review of remote sensing methods for biomass feedstock production. **Biomass & Bioenergy**, v. 35, n. 7, p. 2455-2469, 2011.
- ANDERSON, K.; ROSSINI, M.; LABRADOR, J. P.; BALZAROLO, M.; ARTHUR, A.; FAVA, F.; JULITTA, T.; VESCOVO, L. Inter-comparison of hemispherical conical reflectance factors (HCRF) measured with four fibre-based spectrometers. **Remote sensing and sensors**, v. 21, n. 1, p. 605-617, 2013.
- ATZBERGER, C.; GUERIF, M.; BARET, F.; WERNER, W. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. **Computers and Electronics in Agriculture**, v. 73, p. 165-173, 2010.
- BASSO, B.; FIORENTINO, C.; CAMMARANO, D.; SCHULTHESS, U. Variable rate nitrogen fertilizer response in wheat using remote sensing. **Precision Agriculture**, v. 17, n. 2, p. 168–182, 2016.
- CAMMARANO, D.; FITZGERALD, G. J.; CASA, R.; BASSO, B. Assessing the robustness of vegetation indices to estimate wheat N in Mediterranean environments. **Remote Sensing**, v. 6, p. 2827-2844, 2014.
- CHAUHAN, H.J.; MOHAN, B.K. Effectiveness of SID as Spectral Similarity Measure to Develop Crop Spectra from Hyperspectral Image, *Journal of the Indian Society of Remote Sensing*, v. 45, n. 12, p. 1-10, 2017.
- CHEN P.; HABOUDANE, D.; TREMBLAY, N.; WANG, J.; VIGNEAULT, P.; LI, B. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v. 114, p. 1987–1997, 2010.
- CHEN, J. M. Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229-242, 2014.
- CHEN, P.; HABOUDANE, D.; TREMBLAY, N.; WANG, J.; VIGNEAULT, P.; BAOGUO, L. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v. 114, p. 1987-1997, 2010.
- CHHABRA, A.; MANJUNATH, K. R.; PANIGRAPHY, S. Non-point source pollution in Indian agriculture: Estimation of nitrogen losses from rice crop using remote sensing and GIS. **International Journal of Applied Earth Observation and Geoinformation**, v. 12, p. 190–200, 2010.
- CILIA, C.; PANIGADA C.; ROSSINI, M.; MERONI, M.; Busetto, L.; AMADUCCI, S.; BOSCHETTI, M.; PICCHI, V.; COLOMBO, R. Nitrogen Status Assessment for Variable Rate Fertilization in Maize through Hyperspectral Imagery. **Remote Sensing**, v. 6, p. 6549-6565, 2014.

CONNELL, J. L. O.; BYRD, K. B.; KELLY, M. Remotely-Sensed Indicators of N-Related Biomass Allocation in *Schoenoplectus acutus*. **PLoS ONE**, v. 9, n. 3, p. 01-09, 2014.

CROFT, H.; CHEN, H. M.; LUO, X.; BARLETT, P.; CHEN, B.; STAEBLER, R. Leaf chlorophyll content as a proxy for leaf photosynthetic capacity. **Global Change Biology**, v. 23, p. 3513–352, 2017.

DELLOYE, C.; WEISS, M.; DEFOURNY, P. Retrieval of the canopy chlorophyll content from Sentinel-2 spectral bands to estimate nitrogen uptake in intensive winter wheat cropping systems. **Remote Sensing of Environment**, v. 216, p. 245-261, 2018.

DORIGO, W. A.; MILLA, R. Z.; WIT, A. J. W.; BRAZILE, J.; SINGH, R.; SCHAEPMAN, M. E. A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. **International Journal of Applied Earth Observation and Geoinformation**, v. 9, p. 165–193, 2007.

DZIKITI, S.; VERREYNNE, S. J.; STUCKENS, J.; STREVER, A.; VERSTRAETEN, W. W.; SWENNEN, R.; THERON, K. I.; COPPING, P. Seasonal variation in canopy reflectance and its application to determine the water status and water use by citrus trees in the Western Cape, South Africa. **Agricultural and Forest Meteorology**, v. 151, p. 1035-1044, 2011.

EITEL, J. U. H.; LONG, D. S.; GESSLER, P. E.; SMITH, A. M. S. Using in situ measurements to evaluate the new RapidEye™ satellite series for prediction of wheat nitrogen status. **International Journal of Remote Sensing**, v. 28, n. 18, p. 4183-4190, 2007.

FENG, W.; GUO, B. B.; ZHANG, H. Y.; HE, L.; ZHANG, Y. S.; WANG, Y. H.; ZHU, Y. J.; GUO, T. C. Remote estimation of above ground nitrogen uptake during vegetative growth in winter wheat using hyperspectral red-edge ratio data. **Field Crops Research**, v. 180, p. 197-206, 2015.

FORTES, R.; PRIETO, M. H.; MARTÍN, A. G.; CÓRDOBA, A.; MARTÍNEZ, L.; CAMPILLO, C. Using NDVI and guided sampling to develop yield prediction maps of processing tomato crop. **Spanish Journal of Agricultural Research**, v. 13, n. 1, p. 002-004, 2015.

GABRIEL, J. L.; TEJADA, P. J. Z.; HERRERA, P. J. L.; MARTÍN, E. P.; AYUSO, M. A.; QUEMADA, M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. **Biosystems Engineering**, v. 160, p. 124-133, 2017.

GAUTAM, R. K.; PANIGRAHI, S. Leaf nitrogen determination of corn plant using aerial images and artificial neural networks. **Canadian Biosystems Engineering**, v. 49, p. 71-79, 2007.

GITELSON, ANATOLY A.; KEYDAN, GALINA P.; MERZLYAK, MARK N. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin

contents in higher plant leaves. **Geophysical Research Letters**, v. 33, n. 11, p. L11402, 2006.

HABOUDANE, DRISS; MILLER, JOHN R.; PATTEY, ELIZABETH; ZARCO-TEJADA, PABLO J.; STRACHAN, IAN B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, n. 3, p. 337-352, 2004.

HAMEED, K.; CHAI, D.; RASSAU, A. A comprehensive review of fruit and vegetable classification techniques. **Journal of Image and Vision Computing**, v. 80, p. 24-44, 2018.

HE, L.; SONG, X.; FEND, W.; GUO, B. B.; ZHANG, Y. S.; WANG, Y. H.; WANG, C. Y.; GUO, T. C. Improved remote sensing of leaf nitrogen concentration in winter wheat using multi-angular hyperspectral data. **Remote Sensing of Environment**, v. 174, p. 122-133, 2016.

HERRMANN, I.; KARNIELI, A.; BONFIL, D. J.; COHEN, Y.; ALCHANATIS, V. SWIR-based spectral indices for assessing nitrogen content in potato fields. **International Journal of Remote Sensing**, v. 31, n. 19, p. 5127-5143, 2010.

HOLZAPFEL, C. B.; LAFOND, G. P.; BRANDT, S. A.; BULLOCK, P. R.; IRVINE, R. B.; MORRISON, M. K.; MAY, W. E.; JAMES, D. C. Estimating canola (*Brassica napus* L.) yield potential using an active optical sensor. **Canadian Journal of Plant Science**, v. 89, n. 6, p. 1149-1160, 2009.

HOMOLOVÁ, L.; MALENOVSKÝ, Z.; CLEVERS, J.G. P. W.; SANTOS, G. G.; SCHAEPMAN, M. E. Review of optical-based remote sensing for plant trait mapping. **Ecological Complexity**, vol. 15, pp. 1-16, 2013.

HONG, Z.; LI, X.; HAN, Y.; CHANG, Y.; WANG, J.; ZHOU, R.; HU, K. Automatic sub-pixel coastline extraction based on spectral mixture analysis using EO-1 Hyperion data. **Frontiers in Earth Science**, v. 12, p. 1-17, 2018.

HOULES, V.; GUERIF, M.; MARY, B. Elaboration of a nitrogen nutrition indicator for winter wheat based on leaf area index and chlorophyll content for making nitrogen recommendations. **European Journal of Agronomy**, v. 27, p. 01-11, 2007.

HUANG, S.; MIAO, Y.; YUAN, F.; GNYP, M. L.; YAO, Y.; CAO, Q.; WANG, H.; LENZ-WIEDEMANN, V. I. S.; BARETH, G. Potential of RapidEye and WorldView-2 Satellite Data for Improving Rice Nitrogen Status Monitoring at Different Growth Stages. **Remote Sensing**, v. 9, n. 3, p. 227, 2017.

HUANG, W.; YANG, Q.; PU, R.; YANG, S. Estimation of Nitrogen Vertical Distribution by Bi-Directional Canopy Reflectance in Winter Wheat. **Sensors**, v. 14, n. 11, p. 20347-20359, 2014.

HUANG, Y.; LAN, Y.; GE, Y.; HOFFMANN, W. C.; THOMSON, S. J. Spatial Modeling and Variability Analysis for Modeling and Prediction of Soil and Crop Canopy

Coverage Using Multispectral Imagery from an Airborne Remote Sensing System. **Transactions of the ASABE**, v. 53, n. 4, p. 1321-1329, 2010.

HUERTA, R. F. M.; GONZALEZ, R. G. G.; MEDINA, L. M. C.; PACHECO, I.; OLIVAREZ, J. P. AND VELAZQUEZ, R. V. A Review of Methods for Sensing the Nitrogen Status in Plants: Advantages, Disadvantages and Recent Advances. **Sensors**, v. 13, p. 10823-10843, 2013.

HUNT JR., E. RAYMOND; DAUGHTRY, C. S. T.; EITEL, JAN U. H.; LONG, D. S. Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. **Agronomy Journal**, v. 103, p. 1090-1099, 2011.

HUNT, E. R. J.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S. T.; PERRY, E. M.; Akhmedov, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013.

IDB. Index DataBase. **A database for remote sensing indices**. The IDB Project, 2011-2019. Disponível em: <https://www.indexdatabase.de/>. Acesso em: 07 fev. 2019

JAY, S.; MAUPAS, F.; BENDOULA, R.; GORRETTA, N. Retrieving LAI, chlorophyll and nitrogen contents in sugar beet crops from multi-angular optical remote sensing: Comparison of vegetation indices and PROSAIL inversion for field phenotyping. **Field Crops Research**, v. 210, p. 33-46, 2017.

JENSEN, R. J. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2. ed. Harlow: Pearson New International Edition, 2014. 619 p.

JOHNSON, K.; SANKARAN, S.; EHSANI, R. Identification of Water Stress in Citrus Leaves Using Sensing Technologies. **Agronomy**, v. 3, p. 747-756, 2013.

JONES, C. L.; WECKLER, P. R.; MANESS, N. O.; JAYASEKARA, R.; STONE, M. L. Remote sensing to estimate chlorophyll concentration in spinach using multi-spectral plant reflectance. **American Society of Agricultural and Biological Engineers**, v. 50, n. 6, p. 2267-2273, 2007.

KALACSKA, M.; LALONDE, M.; MOORE, T. R. Estimation of foliar chlorophyll and nitrogen content in an ombrotrophic bog from hyperspectral data: Scaling from leaf to image. **Remote Sensing of Environment**, v. 169, p. 270-279, 2015.

KAUFMAN, Y. J.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.

KNOBLAUCH, C.; WATSON, C.; BERENDONK, C.; BECKER, R.; MONNING, N. W.; WICHERN, F. Relationship between Remote Sensing Data, Plant Biomass and Soil Nitrogen Dynamics in Intensively Managed Grasslands under Controlled Conditions. **Sensors**, v. 17, n. 7, p. 01-13, 2017.

KNYAZIKHIN, Y.; SCHULL, M. A.; STENBERG, P.; MÖTTUS, M.; RAUTIAINEN, M.; YANG, Y.; MARSHAK, P.; CARMONA, P. L.; KAUFMANN, R. K.; LEWIS, P.; DISNEY, M. I.; VANDERBILT, V.; DAVIS, A. B.; BARET, F.; JACQUEMOUD, S.; LYAPUSTIN, A.; MYNENI, R. B. Hyperspectral remote sensing of foliar nitrogen content. **PNAS**, v. 110, n. 27, p. 185-192, 2012.

KOOISTRA, L.; CLEVERS, J. G. P. W. Estimating potato leaf chlorophyll content using ratio vegetation indices. **Remote Sensing Letters**, v. 7, n. 6, p. 611-620, 2016.

KOOISTRA, L.; LEUVEN, R. S. E. W.; WEHRENS, R.; NIENHUIS, P. H.; BUYDENS, L. M. C. A comparison of methods to relate grass reflectance to soil metal contamination. **International Journal of Remote Sensing**, v. 24, n. 24, p. 4995-5010, 2003.

KRISHNA, G., SAHOO, R. N., SINGH, P., BAJPAI, V., PATRA, H., KUMAR, S., SAHOO, P. M. Comparison of various modelling approaches for water deficit stress monitoring in rice crop through hyperspectral remote sensing. **Agricultural Water Management**, v. 213, p. 231-244, 2019.

KROSS, A.; MCNAIRN, H.; LAPEN, D.; SUNOHARA, M.; CHAMPAGNE, C. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, p. 235-248, 2015.

LANDIS, J. Richard; KOCH, Gary G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, [s.l.], v. 33, n. 1, p.159-174, 1977.

LE MAIRE, G.; FRANCOIS, C.; DUFRENE, E. Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. **Remote Sensing of Environment**, v. 89, n. 1, p. 1-28, 2004.

LE MAIRE, G.; JEUFFROY, M. H.; GASTAL, F. Diagnosis tool for plant and crop N status in vegetative stage Theory and practices for crop N management. ScienceDirect. **European Journal of Agronomy**, v. 28, p. 614-624, 2008.

LEMAIRE, G.; GASTAL, F.; PLENET, D. Dynamics of N uptake and N distribution in plant canopies. Use of crop N status index in crop modelling. In: LEMAIRES, G.; BURNS, I.G. Eds. **Diagnostic Procedures for Crop N Management**. INRA: Paris, 1997. p. 15-29.

LI, F.; MIAO, Y.; FENG, G.; YUAN, F.; YUE, S.; GAO, X.; LIU, Y.; LIU, B.; USTIN, S. L.; CHEN, X. Improving estimation of Summer maize nitrogen status with red edge-based spectral vegetation indices. **Field Crops Research**, v. 157, p. 111-123, 2014.

LI, X.; LEE, W. S.; EHSANI, R.; MISHRA, A. R.; YANG, C.; MANGAN, R. L. Spectral difference analysis and airborne imaging classification for citrus greening infected trees. **Computers and Electronics in Agriculture**, v. 83, p. 32-46, 2012.

LI, Z.; JIN, X.; YANG, G.; DRUMMOND, J.; YANG, H.; CLARK, B.; LI, Z.; ZHAO, C. Remote Sensing of Leaf and Canopy Nitrogen Status in Winter Wheat (*Triticum aestivum*L.) Based on N-PROSAIL Model. **Remote Sensing**, v. 10, p. 1463, 2018.

LIU, Y.; SUN, X.; OUYANG, A. Nondestructive measurement of soluble solid content of navel orange fruit by visible–NIR spectrometric technique with PLSR and PCA-BPNN. **Food Science and Technology**, v. 43, p. 602-607, 2010.

LÓPEZ, J. A.; VERDIGUIER, E. I.; CHOVA, L. G.; MARÍ, J. M.; BARREIRO, J. Z. R.; VALLS, G. C.; MARAVILLA, J. C. Land cover classification of VHR airborne images for citrus grove identification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, p. 115–123, 2011.

LUO, C.; XUE, L.; LIU, M.; LI, J.; WANG, X. Nondestructive Measurement of Sugar Content in Navel Orange Based on Vis-NIR Spectroscopy. In: LI D., LIU Y., CHEN Y. (eds) Computer and Computing Technologies in Agriculture IV. CCTA 2010. **IFIP Advances in Information and Communication Technology**, v. 347, 2010.

MAHAJAN, G. R.; PANDEY, R. N.; SAHOO, R. N.; GUPTA, V. L.; DATTA, S. C.; KUMAR, D. Monitoring nitrogen, phosphorus and sulphur in hybrid rice (*Oryza sativa* L.) using hyperspectral remote sensing. **Precision Agriculture**, v.18, p.736-761, 2017.

MAIMAITIJIANG, M.; GHULAM, A.; SIDIKE, P.; HARTLING, S.; MAIMAITIYIMING, M.; PETERSON, K.; SHAVERS, E.; FISHMAN, J.; PETERSON, J.; KADAM, S.; BURKEN, J.; FRITSCHI, F. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 134, p. 43-58, 2017.

MAIN, RUSSELL; CHO, MOSES AZONG; MATHIEU, RENAUD; O'KENNEDY, MARTHA M.; RAMOELO, ABEL; KOCH, SUSAN. An investigation into robust spectral indices for leaf chlorophyll estimation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 6, p. 751-761, 2011.

MARTINS, G. D.; GALO, M. L. B. T.; VIEIRA, B. S. Detecting and Mapping Root-Knot Nematode Infection in Coffee Crop Using Remote Sensing Measurements. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n.12, p. 5395-5403, 2017.

MATESE, A.; BARALDI, R.; BERTON, A.; CESARACCIO, C.; GENNARO, S. F. D.; DUCE, P.; FACINI, O.; MAMELI, M. G.; PIGA, A.; ZALDEI, A. Estimation of Water Stress in Grapevines Using Proximal and Remote Sensing Methods. **Remote Sensing**, v. 10, n. 1, p. 114-122, 2018

MELESSE, A. M. *et al.* Remote Sensing Sensors and Applications in Environmental Resources Mapping and Modelling. **Sensors**, v.7, p. 3209-3241, 2007.

MELESSE, A. M. WENG, Q.; THENKABAIL, P.; SENAY, G. B. Remote Sensing Sensors and Applications in Environmental Resources Mapping and Modelling. **Sensors**, v. 7, n. 12, p. 3209-3241, 2007.

- MENESATTI, P.; ANTONUCCI, F.; PALLOTTINO, F.; ROCCUZZO, G.; ALLEGRA, M.; STAGNO, F.; INTRIGLIOLO, F. Estimation of plant nutritional status by Vis–NIRspectrophotometric analysis on orange leaves [Citrus sinensis (L) Osbeck cv Tarocco]. **Byosystems Engineering**, v. 105, p. 448-454, 2010.
- MIN, M.; LEE, W. Determination of significant wavelengths and prediction of nitrogen content for citrus. **American Society of Agricultural Engineers**, v. 48, n. 2, p. 455-461, 2005.
- MIN, M.; LEE, W. S.; KIM, Y. H.; BUCKLIN, R. A. Nondestructive Detection of Nitrogen in Chinese Cabbage Leaves Using VIS–NIR Spectroscopy. **Hortscience**, v. 41, n. 1, p. 162-166, 2006.
- MIPHOKASAP, P.; WANNASIRI, W. Estimations of Nitrogen Concentration in Sugarcane Using Hyperspectral Imagery, **Sustainability**, v. 10, p. 1266-1282, 2018.
- MISTELE, B.; SCHMIDHALTER, U. Estimating the nitrogen nutrition index using spectral canopy reflectance measurements. **European Journal of Agronomy**, v. 29, p. 184–190. 2008.
- MOHARANA, S.; DUTTA, S. Spatial variability of chlorophyll and nitrogen content of rice from hyperspectral imagery. **Journal of Photogrammetry and Remote Sensing**, v. 122, p. 17–29, 2016.
- MOKHELE, T. A.; AHMED, F. B. Estimation of leaf nitrogen and silicon using hyperspectral remote sensing. **Journal of Applied Remote Sensing**, v. 4, p. 1-18, 2010.
- MUHARAM, F. M.; MASS, S. J.; BRONSON, K. F.; DELAHUNTY, T. Estimating Cotton Nitrogen Nutrition Status Using Leaf Greenness and Ground Cover Information. **Remote Sensing**, v. 7, p. 7007-7028, 2015.
- MULLA, D. J. Twenty-five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, p. 358-371, 2013.
- NEVES, M. F.; TROMBIN, V. G. **Anuário da Citricultura 2017**. 1. ed. CITRUSBR, São Paulo, 2017. p. 60.
- NOVOTNÁ K.; RAJSNEROVÁ P.; MÍŠA P.; MÍŠA M.; KLEM K. Normalized red-edge index - new reflectance index for diagnostics of nitrogen status in barley. **Mendel Net**, p. 120-124. 2013.
- PARK, J. J.; OH, S.; PARK, K. A.; FOUCHER, P. Y.; JANG, J. C.; LEE, M.; KIM, T. S.; KANG, W. S. The Ship Detection Using Airborne and In-situ Measurements Based on Hyperspectral Remote Sensing, **Journal of the Korean earth science society**, v. 38, n. 7, p. 535-545, 2017.

PERRY JR, CHARLES R.; LAUTENSCHLAGER, LYLE F. Functional equivalence of spectral vegetation indices. **Remote Sensing of Environment**, v. 14, n. 1-3, p. 169-182, 1984.

PERRY, E. M.; FITZGERALD, G. J.; NUTTALL, J. G.; O'LEARY, G. J.; SCHULTHESS, U.; WHITLOCK, A. Rapid estimation of canopy nitrogen of cereal crops at paddock scale using a Canopy Chlorophyll Content Index. **Field Crops Research**, v. 134, p. 158-164, 2012.

PETROPOULOS, G. P.; VADREVU, K. P.; XANTHOPOULOS, G.; KARANTOUNIAS, G.; SCHOLZE, M. A Comparison of Spectral Angle Mapper and Artificial Neural Network Classifiers Combined with Landsat TM Imagery Analysis for Obtaining Burnt Area Mapping. **Sensors**, v. 10, p. 1967-1985, 2010.

PETROU, Z. I.; MANAKOS, I.; STATHAKI, T. Remote sensing for biodiversity monitoring: a review of methods for biodiversity indicator extraction and assessment of progress towards international targets. **Biodivers Conserv**, v. 24, n. 10, p. 2333–2363, 2015.

PRAC. PanReac AppliChem. Nitrogen Determination by Kjeldahl Method. ITW Reagents, v. 1, 2018.

QUAGGIO, J. A.; CANTARELLA, H.; RAIJ, B. VAN. Phosphorus and potassium soil test and nitrogen leaf analysis as a base for citrus fertilization, **Nutrient Cycling in Agroecosystems**, v. 52, p. 67-74, 1998.

RAMOELO, A.; SKIDMORE, A. K.; CHO, M. A.; SCHLER, M.; MATHIEU, R.; HEITKONIG, I. M. A. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, p. 151-162, 2012.

RAPER, T. B.; VARCO, J. J. Canopy-scale wavelength and vegetative index sensitivities to cotton growth parameters and nitrogen status. **Precision Agriculture**, v. 16, p. 62-76, 2015.

RECIO, J. A.; HERMOSILLA, T.; RUIZ, L. A.; PALOMAR, J. Automated extraction of tree and plot-based parameters in citrus orchards from aerial images. **Computers and Electronics in Agriculture**, v. 90, p. 24-34, 2013.

ROMERO-TRIGUEROS, C.; NORTES, P. A.; ALARCÓN, J. J.; HUNINK, J. E.; PARRA, M.; CONTRERAS, S.; DROOGERS, P.; NICOLÁS, E. Effects of saline reclaimed waters and deficit irrigation on Citrus physiology assessed by UAV remote sensing. **Agricultural Water Management**, v. 183, p. 60-69, 2016.

RUIZ, F. G.; SANKARAN, S.; MAJA, J. M.; LEE, W. S.; RASMUSSEN, J.; EHSANI, R. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. **Computers and Electronics in Agriculture**, v. 91, p. 106-115, 2013.

SCHLEMMER, M.; GITELSON, A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 47-54, 2013.

SHARDADHOKE, J. A. Image clustering and classification technique: a review. **International Journal on Recent and Innovation Trends in Computing and Communication**, v. 5, n. 12, p. 281-283, 2018.

SONG, Y.; WANG, J. Soybean canopy nitrogen monitoring and prediction using ground based multispectral remote sensors. **IEEE, International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 6389-6392, 2016.

STAGAKIS, S.; GONZÁLES-DUGO, V.; CID, P.; GUILLÉN-CLIMENT, M. L.; ZARCO-TEJADA, P. J. Monitoring water stress and fruit quality in an orange orchard underregulated deficit irrigation using narrow-band structural and physiological remote sensing indices. **Journal of Photogrammetry and Remote Sensing**, v. 71, p. 47-61, 2012.

STELLACCI, A. M.; CASTRIGNANÒ, A.; TROCCOLI, A. Selecting optimal hyperspectral bands to discriminate nitrogen status in durum wheat: a comparison of statistical approaches. **Environmental Monitoring and Assessment**, v. 188, n. 3., p. 01-15, 2016.

STUCKENS, J.; DZIKITI, S.; VERSTRAETEN, W. W.; VERREYNNE, S.; SWENNEM, R.; COPPIN, P. Physiological interpretation of a hyperspectral time series in a citrus orchard. **Agricultural and Forest Meteorology**, v. 151, p. 1002-1015, 2011.

SULTANA, S. R.; ALI, A.; AHMAD, A.; MUBEEN, M.; ZIA-UL-HAQ, M.; AHMAD, S.; ERCISLI, S.; JAAFAR, H. Z. E. Normalized Difference Vegetation Index as a Tool for Wheat Yield Estimation: A Case Study from Faisalabad, Pakistan. **Hindawi Publishing Corporation Scientific World Journal**, 2014.

TEAL, R. K.; TUBANA, B.; GIRMA, K.; FREEMAN, K. W.; ARNALL, D. B.; WALSH, O.; RAUN, W. R. In-season prediction of corn grain yield potential using normalized difference vegetation index. **Agronomy Journal**, v. 98, p. 1488-1494, 2006.

THOMASON, W. E.; PHILLIPS, S. B.; DAVIS, P. H.; WARREN, J. G.; ALLEY, M. M.; REITER, M. S. Variable nitrogen rate determination from plant spectral reflectance in soft red winter wheat. **Precision Agric.**, v. 12, p. 666-681, 2011.

TUCKER, C. J.; ELGIN JR, J. H.; MCMURTREY III, J. E.; FAN, C. J. Monitoring corn and soybean crop development with hand-held radiometer spectral data. **Remote Sensing of Environment**, v. 8, n. 3, p. 237-248, 1979.

USDA. United States Department of Agriculture. **Agricultural Statistics 2017**. National Agricultural Statistics Service. United States Government Printing Office, Washington, 2017.

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

WANG, C.; FENG, M.; YANG, W.; DING, G.; XIAO, L.; LI, G.; LIU, T. Extraction of Sensitive Bands for Monitoring the Winter Wheat (*Triticum aestivum*) Growth Status and Yields Based on the Spectral Reflectance. **PLoS ONE**, v. 12, n. 1, p. 1-16, 2017a.

WANG, F.; HUANG, J.; WANG, Y.; LIU, Z.; ZHANG, F. Estimating nitrogen concentration in rape from hyperspectral data at canopy level using support vector machines. **Precision Agric**, v. 14, n. 2, p. 172-183, 2013.

WANG, FU-MIN; HUANG, JING-FENG; TANG, YAN-LIN; WANG, XIU-ZHEN. New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. **Rice Science**, v. 14, n. 3, p. 195-203, 2007.

WANG, J.; SHEN, C.; LIU, N.; JIN, X.; FAN, X.; DONG, C.; XU, Y. Non-Destructive Evaluation of the Leaf Nitrogen Concentration by In-Field Visible/Near-Infrared Spectroscopy in Pear Orchards, **Sensors**, v. 17, n. 3, p. 538-553, 2017b.

WICAKSONO, P. Assessment of PlanetScope images for benthic habitat and seagrass species mapping in a complex optically shallow water environment. **International Journal of Remote Sensing**, v. 39, n. 17, p. 5739-5765, 2018.

WÓJTOWICZ, M.; WÓJTOWICZ, A.; PIEKARCZYK, J. Application of remote sensing methods in agriculture. **Communications in Biometry and Crop Science**, v. 11, n. 1, p. 31-50, 2016.

WU, JINDONG; WANG, DONG; BAUER, MARVIN E. Assessing broadband vegetation indices and QuickBird data in estimating leaf area index of corn and potato canopies. **Field Crops Research**, v. 102, n. 1, p. 33-42, 2007.

XU, Y.; SMITH, S. E.; GRUNWALD, S.; ABD-ELRAHMAN, A.; WANI, S. P.; NAIR, V. D. Estimating soil total nitrogen in smallholder farm settings using remote sensing spectral indices and regression kriging. **Catena**, v. 163, p. 111-122, 2018.

XUEFENG, L.; QIANG, L.; SHAOLAN, H.; SHILAI, Y.; DEYU, H.; ZHITAO, W.; RANGJIN, X.; YONGQIANG, Z.; LIE, D. Estimation of carbon and nitrogen contents in citrus canopy by low-altitude remote sensing. **International Journal of Agric. & Biol. Eng.**, v. 9, n. 5, p. 149-157, 2016.

YANLI, L.; QIANG, L.; SHAOLAN, H.; SHILAI, Y.; XUEFENG, L.; RANGJIN, X.; YOUNGQIANG, Z.; LIE, D. Prediction of nitrogen and phosphorus contents in citrus leaves based on hyperspectral imaging, **International Journal of Agricultural and Biological Engineering**, v. 8, p. 80-88, 2015.

YE, X.; SAKAI, K.; ASADA, S.; SASAO, A. Use of airborne multispectral imagery to discriminate and map weed infestations in a citrus orchard. **Weed Biology and Management**, v. 7, p. 23-30, 2007.

YE, X.; SAKAI, K.; GARCIANO, L. O.; ASADA, S. I.; SASAO, A. Estimation of citrus yield from airborne hyperspectral images using a neural network model. **Ecological Modelling**, v. 198, p. 426-432, 2006.

YOUSEFI, S. L.; RANJBAR, H.; ALIREZAEI, S.; DARGAHI, S. Application of Mixture Tuned Matched Filtering on ASTER Data for Hydrothermal Alteration Mapping Related to Porphyry Cu Deposits in Jabal-Barez Ranges, Kerman Copper Belt, Iran. **Journal of Sciences**, v. 29, n. 3, p. 271-280, 2018.

YU, C.; LEE, L. C.; CHANG, C. I.; XUE, B.; SONG, M.; CHEN, J. Band-Specified Virtual Dimensionality for Band Selection: An Orthogonal Subspace Projection Approach. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 5, p. 2822-2832, 2018.

YU, Q.; WANG, S.; SHI, H.; KUN, H.; ZHOU, L. An Evaluation of Spaceborne Imaging Spectrometry for Estimation of Forest Canopy Nitrogen Concentration in a Subtropical Conifer Plantation of Southern China. **Journal of Resources and Ecology**, v 5, n. 1, p. 01-10, 2014.

ZHAI, Y.; CUI, L.; ZHOU, X.; GAO, Y.; FEI, T.; GAO, W. Estimation of nitrogen, phosphorus, and potassium contents in the leaves of different plants using laboratory-based visible and near-infrared reflectance spectroscopy: comparison of partial least-square regression and support vector machine regression methods. **International Journal of Remote Sensing**, v. 34, n. 7, p. 2502-2518, 2013.

ZHAO, D.; REDDY, K. R.; KAKANI, G.; READ, J. J. Remote-sensing algorithms for estimating nitrogen uptake and nitrogen-use efficiency in cotton. **Soil and Plant Science**, v. 60, p. 500-509, 2010.

ZHENG, H.; LI, W.; JIANG, J.; LIU, Y.; CHENG, T.; TIAN, Y.; ZHU, Y.; CAO, W.; ZHANG, Y.; YAO, X. A Comparative Assessment of Different Modeling Algorithms for Estimating Leaf Nitrogen Content in Winter Wheat Using Multispectral Images from an Unmanned Aerial Vehicle. **Remote Sensing**, v. 10, p. 20-26, 2018.

ZOU, W.; SCHEN, C.; YIN, G. Application of image recognition technology in agricultural production process. **International Agricultural Engineering Journal**, v. 27, n. 2, p. 318-326, 2018.

ANEXO A – Relatório do Posicionamento por Ponto Preciso

A seguir encontra-se o documento produzido pelo Instituto Brasileiro de Geografia e Estatística (IBGE), referente ao processamento do PPP (Posicionamento por Ponto Preciso) para os dados coletados com o GNSS Leica Plus GS15, em modo RTK, na propriedade estudada.

Página 1 de 2 ▼



Instituto Brasileiro de Geografia e Estatística

Sumário do Processamento do marco: BASE FAZENDA

Início: AAAA/MM/DD HH:MM:SS,SS	2018/03/22 14:02:06,00
Fim: AAAA/MM/DD HH:MM:SS,SS	2018/03/22 20:46:11,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	LEIGS15 NONE
Órbitas dos satélites:¹	RÁPIDA
Frequência processada:	L3
Intervalo do processamento(s):	1,00
Sigma² da pseudodistância (m):	5,000
Sigma da portadora (m):	0,010
Altura da Antena³ (m):	1,415
Ângulo de Elevação (graus):	10,000
Resíduos da pseudodistância (m):	0,40 GPS
Resíduos da fase da portadora (cm):	0,61 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM (m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-22° 37' 29,3278"	-49° 40' 37,7322"	540,12	7497408.507	635948.251	-51
Na data do levantamento ⁵	-22° 37' 29,3209"	-49° 40' 37,7337"	540,12	7497408.720	635948.210	-51
Sigma(95%)⁶ (m)	0,001	0,002	0,004			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-5,63					
Altitude Ortométrica (m)	545,75					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

²O termo "Sigma" é referente ao desvio-padrão.

³Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵A data de levantamento considerada é a data de início da sessão.

⁶Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário.

Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181.

Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCan) Processamento autorizado para uso do IBGE.

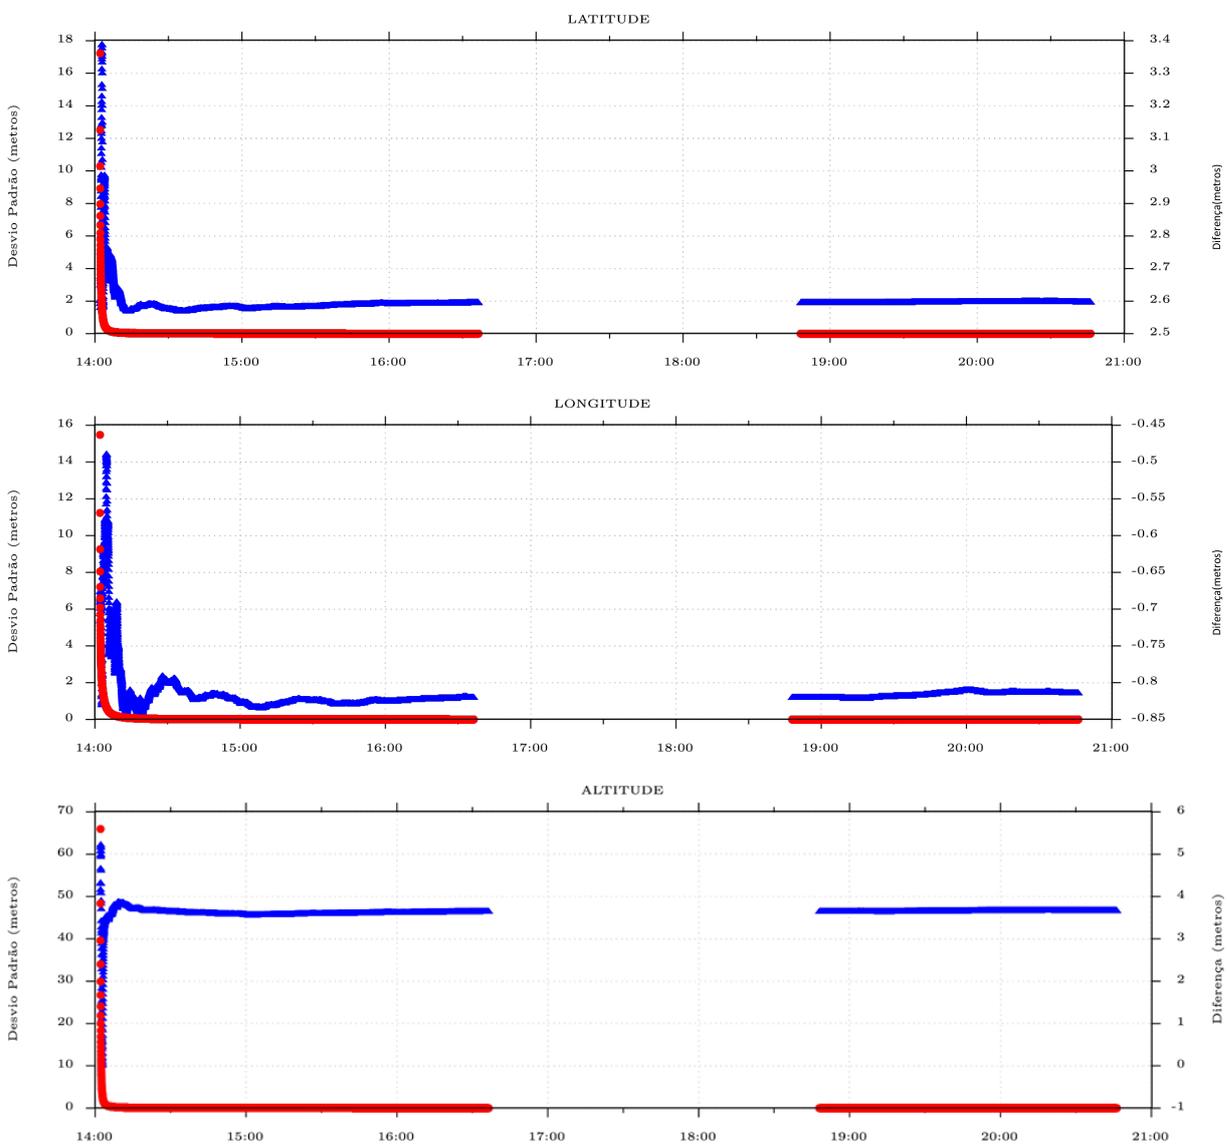
Processado em: 23/03/2018 17:18:53

Página 2 de 2 ▼

Desvio Padrão e Diferença da Coordenada a Priori

BASE0810.18°

Diferença ▲
Desvio Padrão ● Padrão



Processado em: 23/03/2018 17:18:53

ANEXO B – Comprovante de Autorização do Voo

Segue, abaixo, a mensagem via e-mail trocada entre o Prof. Dr. Edson Takashi Matsubara (UFMS), responsável pelo voo com a ARP eBee SenseFly na propriedade Fazenda Brasília, com o Departamento de Controle do Espaço Aéreo (DECEA), recebida com dois dias de antecedência ao voo.

----- Forwarded message -----

From: **DECEA** <web@decea.gov.br>
Date: 2018-03-20 10:17 GMT-04:00
Subject: [SARPAS] Solicitação #5F7BAF aprovada
To: edsontm@facom.ufms.br

Prezado(a) EDSON TAKASHI MATSUBARA,

Em atenção ao processo identificado pelo protocolo **5F7BAF**, que trata de solicitação referente à autorização de utilização do espaço aéreo por aeronave remotamente pilotada, no período de **22/03/2018 09:00 UTC a 22/03/2018 22:00 UTC** e nas coordenadas **-22.622888653220695/-49.67795708465576**, informo a Vossa Senhoria que este Departamento é **favorável** à operação solicitada, com o seguinte parecer:

Operação condicionada à inexistência de aeronaves tripuladas nas proximidades. Reitera-se que é terminantemente proibido o compartilhamento de espaço aéreo entre aeronaves tripuladas e não tripuladas, devendo a aeronave remotamente pilotada ser recolhida ao menor sinal de alguma aeronave tripulada na região. Satisfeita essa condicionante este Centro é de parecer favorável à operação.

Além disso, o operador RPAS deve observar as seguintes condicionantes:

1. Manter a operação em VLOS, encerrando imediatamente o voo da RPA, caso a continuidade das atividades venha causar perigo aos demais usuários do espaço aéreo, pessoas ou propriedades no solo;
2. Não compartilhar o espaço aéreo com a aviação tripulada, interrompendo o voo da RPA caso seja observada a aproximação de outra aeronave em trajetória conflitante;
3. Não ultrapassar, durante a operação da RPA, a Altura máxima de 390 ft;
4. Realizar operação VLOS, mantendo um afastamento horizontal máximo de 500 m entre a RPA e a RPS;
5. A menos que expressamente autorizado pelos proprietários, estar sua projeção vertical no solo afastada, pelo menos, 30 m de edificações, estruturas, patrimônios e animais;
6. Estar sua projeção vertical no solo afastada, pelo menos, 30 m de concentração de pessoas não anuentes; e
7. Não voar sobre áreas povoadas e aglomeração de pessoas (exceto aquelas anuentes e/ou envolvidas na operação do RPAS).

Esta autorização é válida até **24.03.2018 às 22:00** e se refere, exclusivamente, à utilização do espaço aéreo e aos aspectos de segurança de voo e de proteção à navegação aérea, não eximindo o requerente do que lhe compete na observância de normas e diretrizes estabelecidas por outros órgãos públicos.

Equipe SARPAS
Departamento de Controle do Espaço Aéreo (DECEA)

ANEXO C – Relatório de Qualidade do Processamento das Imagens

Neste anexo contém o relatório de qualidade produzido pelo *software* Pix4DMapper durante o processamento do ortomosaico gerreferenciado das imagens da câmera Parrot Sequoia. Esse processamento foi separado em dois blocos, com a finalidade de se obter uma melhor performance.

Quality Report



Generated with Pix4Dmapper Pro version 4.1.21

Important: Click on the different icons for:

- Help to analyze the results in the Quality Report
- Additional information about the sections

Click [here](#) for additional tips to analyze the Quality Report

Summary

Project	bloco1_teste2
Processed	2018-05-25 17:21:42
Camera Model Name(s)	Sequoia_4.0_1280x960 (Green), Sequoia_4.0_1280x960 (Red), Sequoia_4.0_1280x960 (Red edge), Sequoia_4.0_1280x960 (NIR)
Rig name(s)	«Sequoia»
Average Ground Sampling Distance (GSD)	12.48 cm / 4.91 in
Time for Initial Processing (without report)	32m:31s

Quality Check

Images	median of 23347 keypoints per image	
Dataset	1183 out of 1200 images calibrated (98%), 7 images disabled	
Camera Optimization	0.04% relative difference between initial and optimized internal camera parameters	
Matching	median of 5110.17 matches per calibrated image	
Georeferencing	yes, no 3D GCP	

Calibration Details

Number of Calibrated Images	1183 out of 1207
Number of Geolocated Images	1207 out of 1207

Initial Image Positions

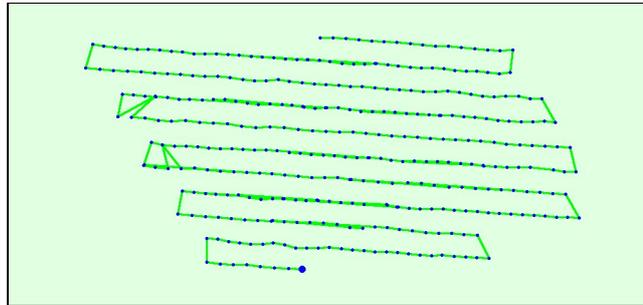
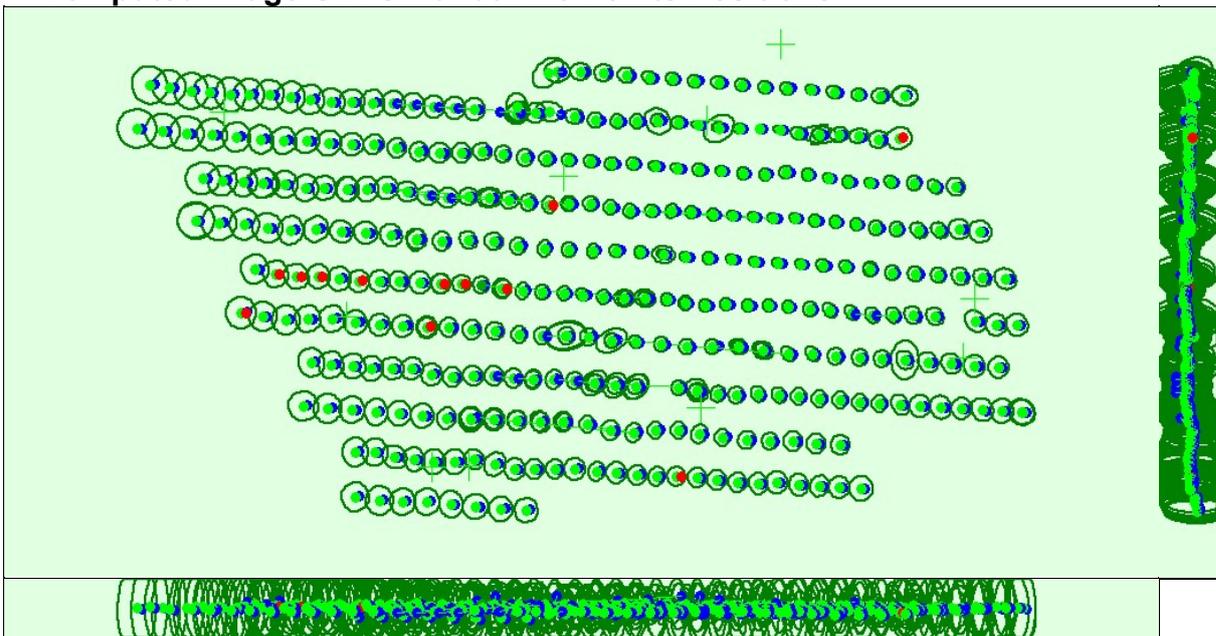


Figure 2: Top view of the initial image position. The green line follows the position of the images in time starting from the large blue dot.

Computed Image/GCPs/Manual Tie Points Positions



Uncertainty ellipses 50x magnified

Figure 3: Offset between initial (blue dots) and computed (green dots) image positions as well as the offset between the GCPs initial positions (blue crosses) and their computed positions (green crosses) in the top-view (XY plane), front-view (XZ plane), and side-view (YZ plane). Red dots indicate disabled or uncalibrated images. Dark green ellipses indicate the absolute position uncertainty of the bundle block adjustment result.

Absolute camera position and orientation uncertainties

	X [m]	Y [m]	Z [m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	0.242	0.230	0.538	0.119	0.114	0.046
Sigma	0.072	0.071	0.218	0.015	0.023	0.012

Bundle Block Adjustment Details



Number of 2D Keypoint Observations for Bundle Block Adjustment	2374024
Number of 3D Points for Bundle Block Adjustment	919218
Mean Reprojection Error [pixels]	0.203

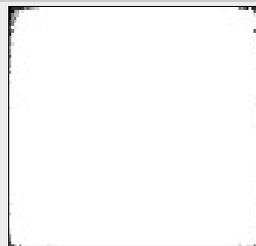
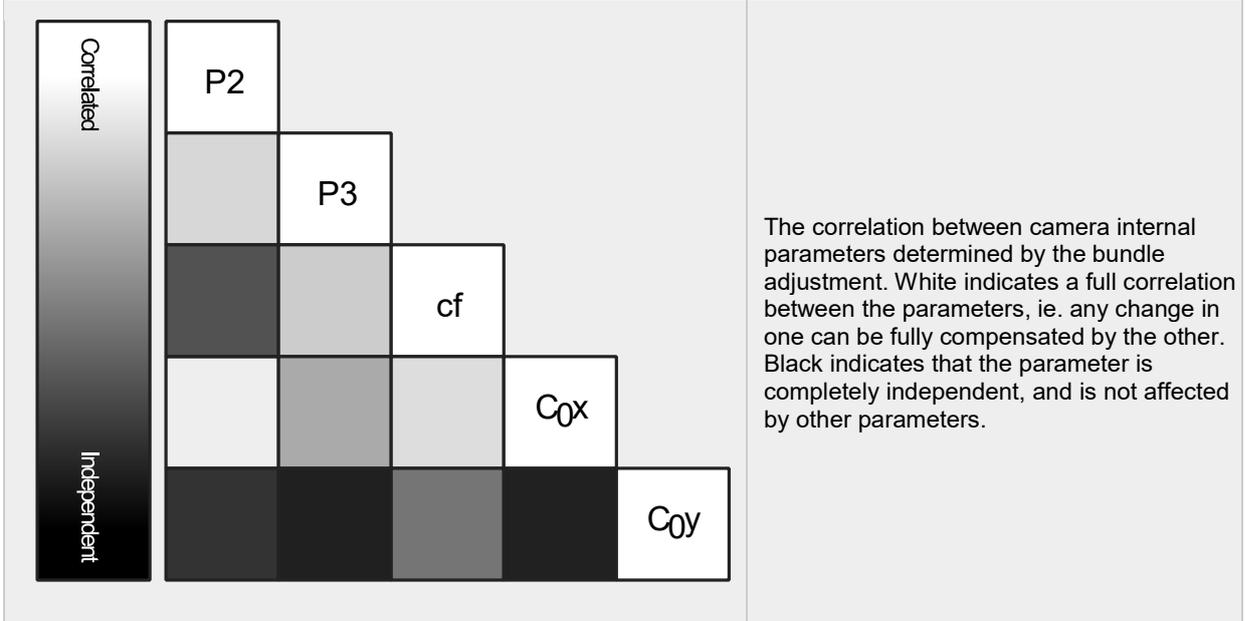
Internal Camera Parameters

Sequoia_4.0_1280x960 (Green). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]



EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.012117	-0.149979	0.000000	1659.47	0.00	0.00	1659.47	667.91	498.55
Optimized Values	0.000000	1.000000	0.010812	-0.150554	0.000000	1662.08	0.00	0.00	1662.08	668.58	499.55
Uncertainties (Sigma)			0.000575	0.001025		0.66	0.00	0.00	0.66	0.11	0.17



The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera. The color ranges from black and white. White indicates that, on average, more than 10 tie points have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted. Click on the image to see the average direction and magnitude of error for each pixel. Note that the vectors are scaled for better visualization. The magnitude of 1 indicates the magnitude of 1 pixel error.

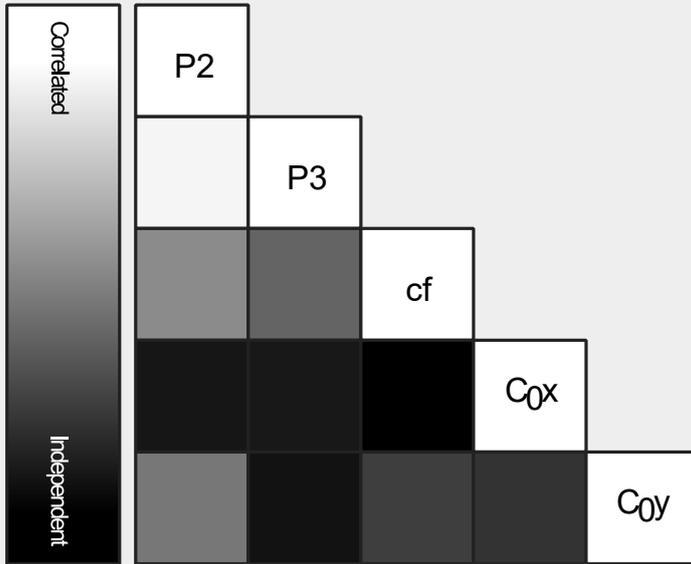
? Internal Camera Parameters

Sequoia_4.0_1280x960 (Red). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

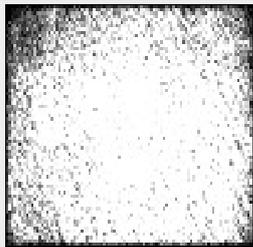


EXIF ID:
Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.020186	-0.165127	0.000000	1658.38	0.00	0.00	1658.38	680.76	490.61
Optimized Values	0.000000	1.000000	0.006038	-0.146823	0.000000	1664.71	0.00	0.00	1664.71	678.70	491.78
Uncertainties (Sigma)			0.001562	0.002571		0.76	0.00	0.00	0.76	0.27	0.27



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera model. The color coded between black and white. White indicates that, on average, more than 10 ATPs have the pixel location. Black indicates that, on average, 0 ATPs have the pixel location. Click on the image to see the average direction and magnitude for each pixel. Note that the vectors are scaled for better visualization. The scale bar indicates the magnitude of 1 pixel error.

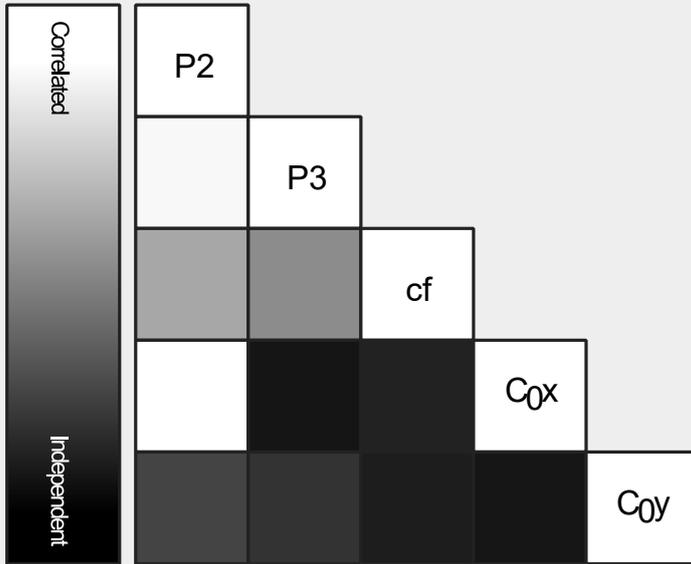
Internal Camera Parameters

Sequoia_4.0_1280x960 (Red edge). Sensor Dimensions: 4.800 [mm] x 3.600

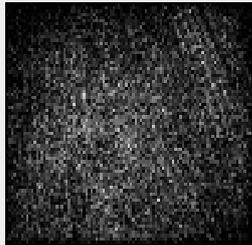
[mm]
EXIF ID:
Sequoia_4.0_1280x960



	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.020579	-0.164646	0.000000	1668.23	0.00	0.00	1668.23	674.88	509.87
Optimized Values	0.000000	1.000000	0.004835	-0.143655	0.000000	1674.75	0.00	0.00	1674.75	677.39	511.02
Uncertainties (Sigma)			0.002326	0.003979		0.86	0.00	0.00	0.86	0.44	0.41



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



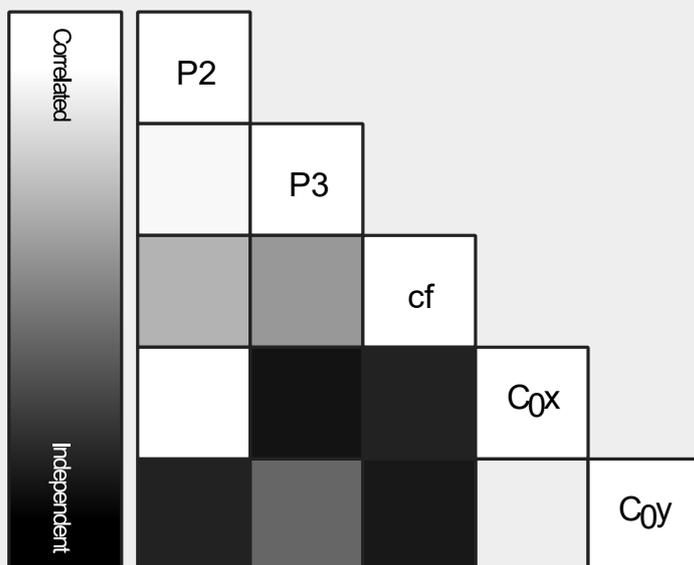
The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera node, is color coded between black and white. White indicates that, on average, more than 10 ATPs have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted. Click on the image to see the average direction and magnitude of the vectors for each pixel. Note that the vectors are scaled for better visualization. The magnitude indicates the magnitude of 1 pixel error.

Internal Camera Parameters

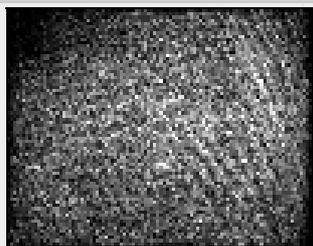
Sequoia_4.0_1280x960 (NIR). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]
 EXIF ID: Sequoia_4.0_1280x960



	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.016113	-0.157434	0.000000	1662.68	0.00	0.00	1662.68	682.92	508.18
Optimized Values	0.000000	1.000000	0.012635	-0.157672	0.000000	1667.65	0.00	0.00	1667.65	679.61	512.00
Uncertainties (Sigma)			0.002597	0.004314		0.93	0.00	0.00	0.93	0.46	0.42



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera model, is color coded between black and white. White indicates that, on average, more than 16 ATPs have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization. The scale bar indicates the magnitude of 1 pixel error

🔍 Camera Rig «Sequoia» Relatives. Images: 1060

	Transl X [m]	Transl Y [m]	Transl Z [m]	Rot X [degree]	Rot Y [degree]	Rot Z [degree]
Sequoia_4.0_1280x960 (Green)	Reference Camera					
Sequoia_4.0_1280x960 (Red)						
Initial Values	0.000	-0.015	0.000	-0.361	-0.100	-0.092
Optimized values	0.000	-0.015	0.000	-0.327	-0.154	-0.086
Uncertainties (sigma)				0.014	0.016	0.002
Sequoia_4.0_1280x960 (Red edge)						
Initial Values	0.015	0.000	0.000	-0.119	0.032	0.067
Optimized values	0.015	0.000	0.000	-0.144	0.081	0.071
Uncertainties (sigma)				0.022	0.025	0.003
Sequoia_4.0_1280x960 (NIR)						
Initial Values	0.015	-0.015	0.000	-0.518	-0.199	0.011
Optimized values	0.015	-0.015	0.000	-0.505	-0.256	0.015
Uncertainties (sigma)				0.023	0.027	0.003

2D Keypoints Table

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	23347	5110
Min	13746	3
Max	34145	13892
Mean	22667	4998

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Green)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	23704	5960
Min	14073	241
Max	34145	11875
Mean	22878	5639

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	22920	3411
Min	14733	212
Max	28315	13892
Mean	21275	4972

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red edge)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	22522	1567
Min	13746	3
Max	29435	5063
Mean	21776	1755

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (NIR)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	23832	3025
Min	14883	107
Max	32772	12239
Mean	23929	3626

Median / 75% / Maximal Number of Matches Between Camera Models

	Sequoia_4.0_1 (Green)	Sequoia_4.0_128 (Red)	Sequoia_4 (Red edge)	Sequoia_4.0_128 (NIR)
Sequoia_4.0_1280x960 (Green)	53 / 308 / 7137	7 / 24 / 744	4 / 19 / 617	1 / 4 / 25
Sequoia_4.0_1280x960 (Red)		457 / 1915 / 9995	3 / 29 / 143	2 / 15 / 29
Sequoia_4.0_1280x960 (Red edge)			567 / 1410 / 3812	31 / 146 / 2264
Sequoia_4.0_1280x960 (NIR)				241 / 1276 / 8349

3D Points from 2D Keypoint Matches

	Number of 3D Points Observed
In 2 Images	624389
In 3 Images	170797
In 4 Images	66808
In 5 Images	29456
In 6 Images	12975
In 7 Images	6876
In 8 Images	3736
In 9 Images	1973
In 10 Images	996
In 11 Images	518
In 12 Images	324
In 13 Images	183
In 14 Images	95
In 15 Images	51
In 16 Images	17
In 17 Images	12
In 18 Images	8
In 19 Images	4

2D Keypoint Matches

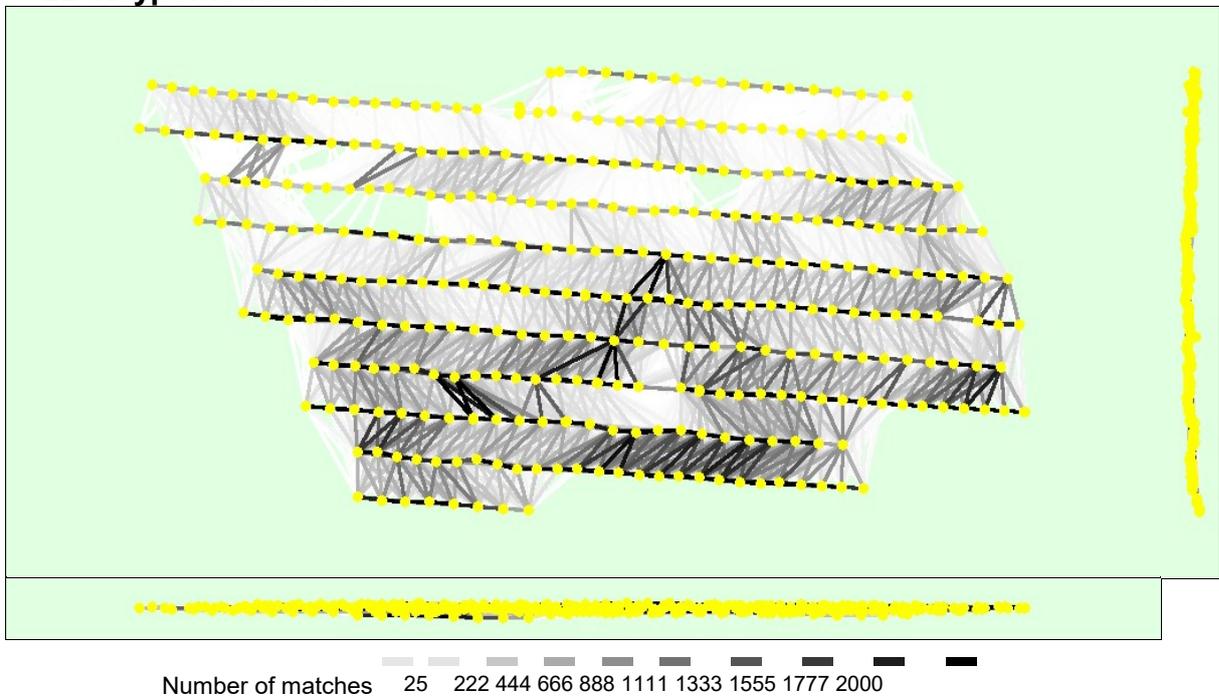


Figure 5: Computed image positions with links between matched images. The darkness of the links indicates the number of matched 2D keypoints between the images. Bright links indicate weak links and require manual tie points or more images.

Manual Tie Points

MTP Name	Projection Error [pixel]	Verified/Marked
P01	0.427	51 / 51
mtp17	1.024	58 / 58
mtp14	2.902	50 / 50
mtp13	2.831	35 / 35
P02	0.424	26 / 26
mtp15	0.344	18 / 18
mtp12	3.020	39 / 42
P07	0.476	42 / 42
mtp16	1.308	48 / 48
P03	0.319	18 / 18

Projection errors for manual tie points. The last column counts the number of images where the manual tie point has been automatically verified vs. manually marked.

Geolocation Details

Absolute Geolocation Variance

Min Error [m]	Max Error [m]	Geolocation Error X [%]	Geolocation Error Y [%]	Geolocation Error Z [%]
-	-15.00	3.32	0.00	0.00
-15.00	-12.00	0.00	0.00	0.00
-12.00	-9.00	0.00	0.00	0.00
-9.00	-6.00	0.00	0.09	0.34
-6.00	-3.00	0.00	0.34	3.07
-3.00	0.00	0.00	19.61	89.77
0.00	3.00	0.34	79.71	5.80
3.00	6.00	94.97	0.26	0.68
6.00	9.00	0.94	0.00	0.09
9.00	12.00	0.00	0.00	0.00
12.00	15.00	0.34	0.00	0.26
15.00	-	0.09	0.00	0.00
Mean [m]		3.989887	0.317466	-1.526081
Sigma [m]		4.576572	0.555336	1.351640
RMS Error [m]		6.071590	0.639674	2.038592

Min Error and Max Error represent geolocation error intervals between -1.5 and 1.5 times the maximum accuracy of all the images. Columns X, Y, Z show the percentage of images with geolocation errors within the predefined error intervals. The geolocation error is the difference between the initial and computed image positions. Note that the image geolocation errors do not correspond to the accuracy of the observed 3D points.

Relative Geolocation Variance

Relative Geolocation Error	Images X [%]	Images Y [%]	Images Z [%]
[-1.00, 1.00]	74.60	99.91	99.74
[-2.00, 2.00]	96.25	100.00	100.00
[-3.00, 3.00]	96.59	100.00	100.00
Mean of Geolocation Accuracy [m]	5.000000	5.000000	10.000000
Sigma of Geolocation Accuracy [m]	0.000000	0.000000	0.000000

Images X, Y, Z represent the percentage of images with a relative geolocation error in X, Y, Z.

Geolocation Orientational Variance	RMS [degree]
Omega	3.977
Phi	3.964
<i>Kappa</i>	10.640

Geolocation RMS error of the orientation angles given by the difference between the initial and computed image orientation angles.

Initial Processing Details

System Information

Hardware	CPU: Intel(R) Core(TM) i5-3570 CPU @ 3.40GHz RAM: 8GB GPU: Intel(R) HD Graphics (Driver: 10.18.10.4425), RDPDD Chained DD (Driver: unknown), RDP Encoder Mirror Driver (Driver: unknown), RDP Reflector Display Driver (Driver: unknown)
Operating System	Windows 7 Professional, 64-bit

Coordinate Systems

Image Coordinate System	WGS84 (egm96)
Output Coordinate System	WGS 84 / UTM zone 22S (egm96)

Processing Options

Detected Template	No Template Available
Keypoints Image Scale	Full, Image Scale: 2
Advanced: Matching Image Pairs	Aerial Grid or Corridor
Advanced: Matching Strategy	Use Geometrically Verified Matching: yes
Advanced: Keypoint Extraction	Targeted Number of Keypoints: Automatic
Advanced: Calibration	Calibration Method: Standard Internal Parameters Optimization: All External Parameters Optimization: All Rematch: Auto, no
Rig «Sequoia» processing	optimize relative rotation using a subset of secondary cameras

Point Cloud Densification details

Processing Options

Image Scale	multiscale, 1/2 (Half image size, Default)
Point Density	Optimal
Minimum Number of Matches	3
3D Textured Mesh Generation	yes
3D Textured Mesh Settings:	Resolution: Medium Resolution (default) Color Balancing: no
LOD	Generated: no
Advanced: 3D Textured Mesh Settings	Sample Density Divider: 1
Advanced: Image Groups	Green, NIR, Red, Red edge
Advanced: Use Processing Area	yes
Advanced: Use Annotations	yes
Time for Point Cloud Densification	12m:36s
Time for Point Cloud Classification	NA
Time for 3D Textured Mesh Generation	05m:08s

Results

Number of Generated Tiles	1
Number of 3D Densified Points	3187186
Average Density (per m ³)	1.67

DSM, Orthomosaic and Index Details

Processing Options

DSM and Orthomosaic Resolution	1 x GSD (12.5 [cm/pixel])
DSM Filters	Noise Filtering: yes Surface Smoothing: yes, Type: Sharp
Raster DSM	Generated: yes Method: Triangulation Merge Tiles: yes
Orthomosaic	Generated: yes Merge Tiles: yes GeoTIFF Without Transparency: yes Google Maps Tiles and KML: no
Raster DTM	Generated: yes Merge Tiles: yes
DTM Resolution	5 x GSD (12.5 [cm/pixel])
Index Calculator: Radiometric Calibration	Generated: yes
Index Calculator: Reflectance Map	Generated: yes Resolution: 1 x GSD (12.5 [cm/pixel]) Merge Tiles: yes
Index Calculator: Indices	green, nir, red, red_edge, ndvi

Time for DSM Generation	46s
Time for Orthomosaic Generation	16m:59s
Time for DTM Generation	01m:26s
Time for Contour Lines Generation	00s
Time for Reflectance Map Generation	22m:16s
Time for Index Map Generation	03m:05s

Camera Radiometric Correction i

Sequoia_4.0_1280x960	Green	Camera and Sun Irradiance
Sequoia_4.0_1280x960	Red	Camera and Sun Irradiance
Sequoia_4.0_1280x960	Red edge	Camera and Sun Irradiance
Sequoia_4.0_1280x960	NIR	Camera and Sun Irradiance

Quality Report i



Generated with Pix4Dmapper Pro version 4.1.21

- Important: Click on the different icons for:
- Help to analyze the results in the Quality Report
 - Additional information about the sections
- Click [here](#) for additional tips to analyze the Quality Report

Summary i

Project	bloco2_final
Processed	2018-07-12 11:14:10
Camera Model Name(s)	Sequoia_4.0_1280x960 (Green), Sequoia_4.0_1280x960 (Red), Sequoia_4.0_1280x960 (Red edge), Sequoia_4.0_1280x960 (NIR)
Rig name(s)	«Sequoia»
Average Ground Sampling Distance (GSD)	13.04 cm / 5.13 in
Area Covered	0.664 km ² / 66.4488 ha / 0.26 sq. mi. / 164.2835 acres
Time for Initial Processing (without report)	12m:29s

Quality Check i

Images	median of 10000 keypoints per image	
Dataset	1206 out of 1221 images calibrated (98%), 12 images disabled	
Camera Optimization	0% relative difference between initial and optimized internal camera parameters	
Matching	median of 3733.69 matches per calibrated image	
Georeferencing	yes, 4 GCPs (4 3D), mean RMS error = 0.129 m	

Preview

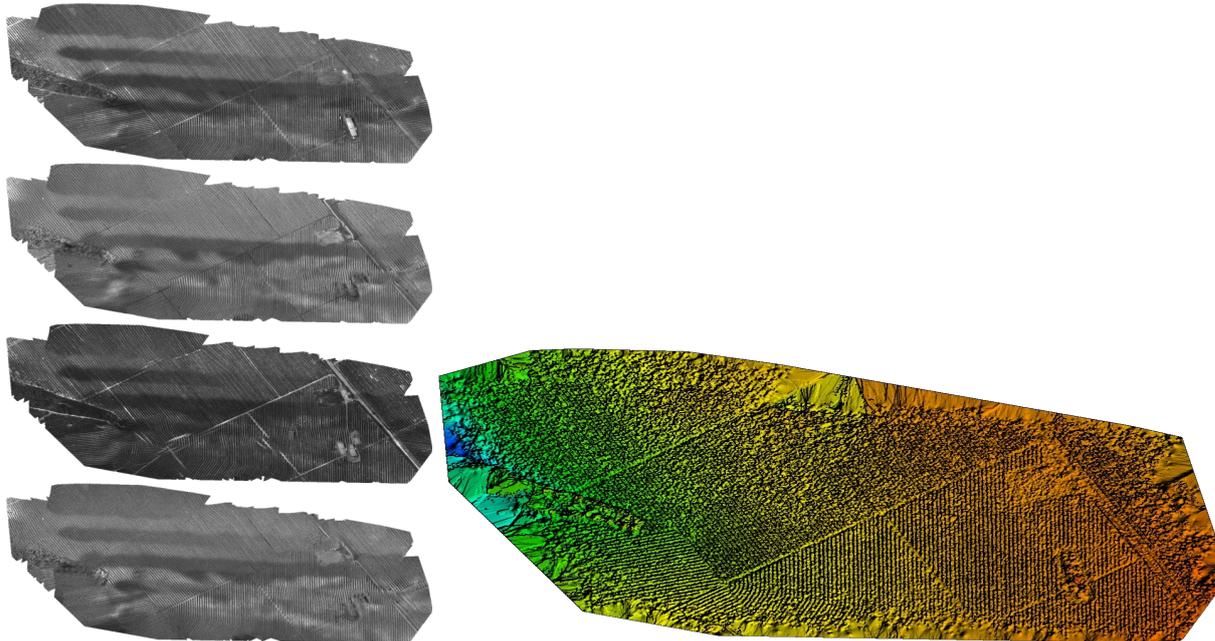


Figure 1: Orthomosaic and the corresponding sparse Digital Surface Model (DSM) before densification.

Calibration Details

Number of Calibrated Images	1206 out of 1233
Number of Geolocated Images	1233 out of 1233

Initial Image Positions

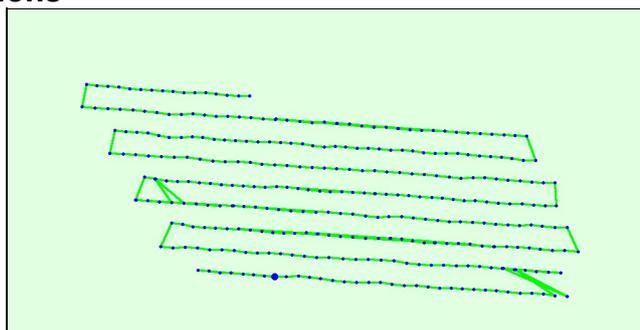
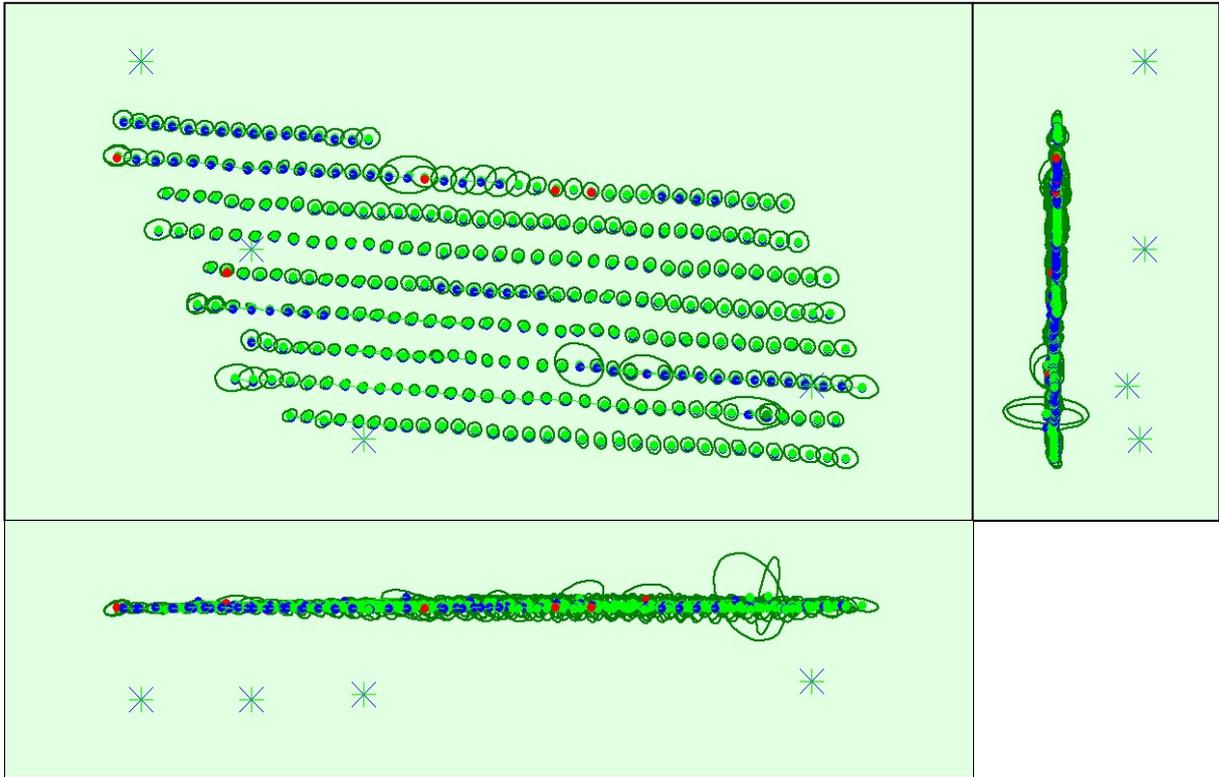


Figure 2: Top view of the initial image position. The green line follows the position of the images in time starting from the large blue dot.

Computed Image/GCPs/Manual Tie Points Positions



Uncertainty ellipses 10x magnified

Figure 3: Offset between initial (blue dots) and computed (green dots) image positions as well as the offset between the GCPs initial positions (blue crosses) and their computed positions (green crosses) in the top-view (XY plane), front-view (XZ plane), and side-view (YZ plane). Red dots indicate disabled or uncalibrated images. Dark green ellipses indicate the absolute position uncertainty of the bundle block adjustment result.

Absolute camera position and orientation uncertainties

	X [m]	Y [m]	Z [m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	1.108	1.017	1.093	0.448	0.490	0.181
Sigma	0.460	0.305	0.577	0.150	0.217	0.089

Overlap

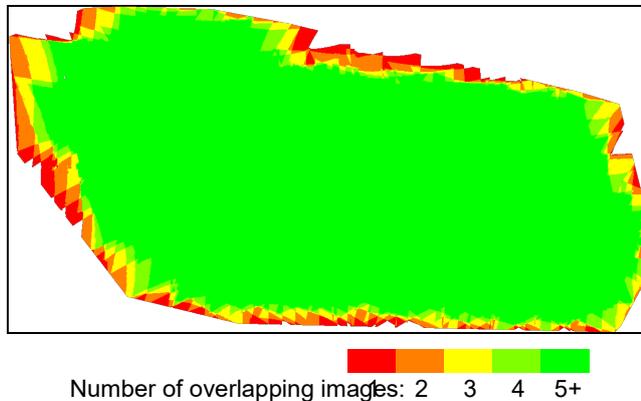


Figure 4: Number of overlapping images computed for each pixel of the orthomosaic. Red and yellow areas indicate low overlap for which poor results may be generated. Green areas indicate an overlap of over 5 images for every pixel. Good quality results will be generated as long as the number of keypoint matches is also sufficient for these areas (see Figure 5 for keypoint matches).

Bundle Block Adjustment Details



Number of 2D Keypoint Observations for Bundle Block Adjustment	1452219
Number of 3D Points for Bundle Block Adjustment	537446
Mean Reprojection Error [pixels]	0.406



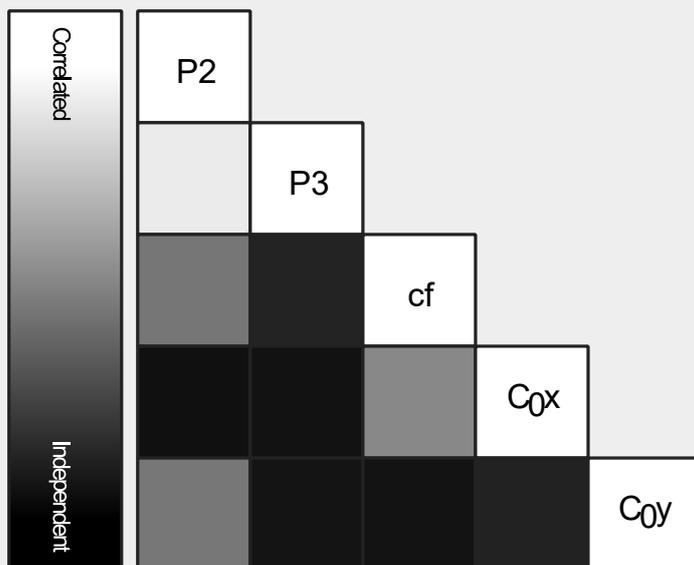
Internal Camera Parameters

Sequoia_4.0_1280x960 (Green). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

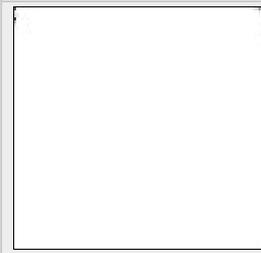


EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.012117	-0.149979	0.000000	1659.47	0.00	0.00	1659.47	667.91	498.55
Optimized Values	0.000000	1.000000	0.012080	-0.149868	0.000000	1659.50	0.00	0.00	1659.50	667.94	498.59
Uncertainties (Sigma)			0.007068	0.011965		4.64	0.00	0.00	4.64	1.22	1.15



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



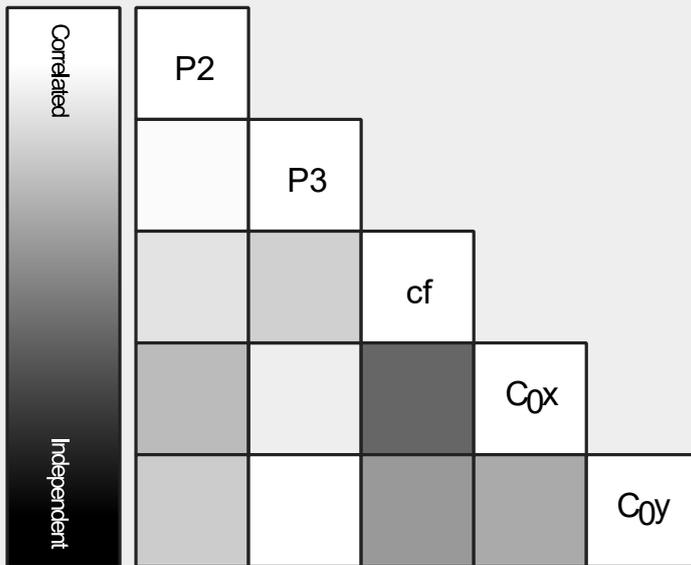
The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the scene, is visualized here. White indicates that, on average, more tie points have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the tie point vectors for each pixel. Note that the vectors are scaled for better visualization. The scale is 1 pixel error.

Internal Camera Parameters

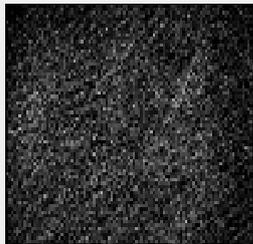
Sequoia_4.0_1280x960 (Red). Sensor Dimensions: 4.800 [mm] x 3.600

[mm]
EXIF ID:
Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.020186	-0.165127	0.000000	1658.38	0.00	0.00	1658.38	680.76	490.61
Optimized Values	0.000000	1.000000	0.018830	-0.161126	0.000000	1658.38	0.00	0.00	1658.38	680.75	490.61
Uncertainties (Sigma)			0.036537	0.059627		10.13	0.00	0.00	10.13	5.76	4.72



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



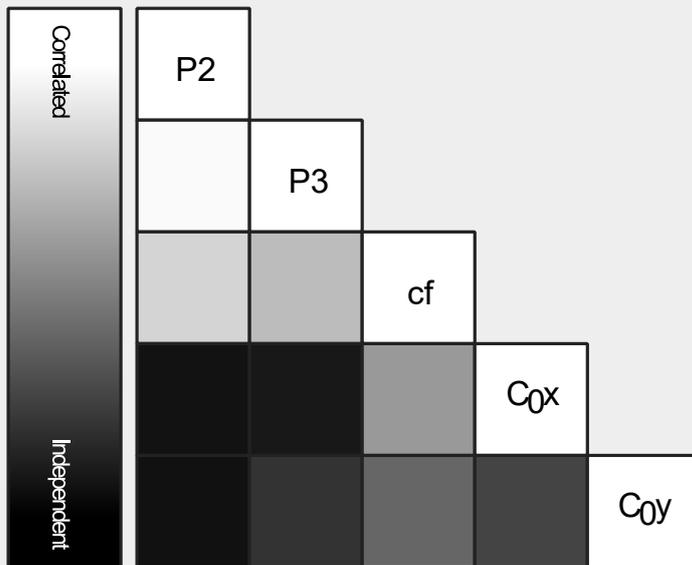
The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the scene, is visualized here. White indicates that, on average, more tie points have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the tie point vectors for each pixel. Note that the vectors are scaled for better visualization. The scale is 1 pixel error.

Internal Camera Parameters

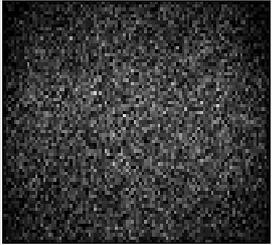
Sequoia_4.0_1280x960 (Red edge). Sensor Dimensions: 4.800 [mm] x 3.600

[mm]
EXIF ID:
Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.020579	- 0.164646	0.000000	1668.23	0.00	0.00	1668.23	674.88	509.87
Optimized Values	0.000000	1.000000	0.019160	- 0.161788	0.000000	1668.23	0.00	0.00	1668.23	674.89	509.88
Uncertainties (Sigma)			0.027260	0.046018		7.94	0.00	0.00	7.94	4.91	4.11



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



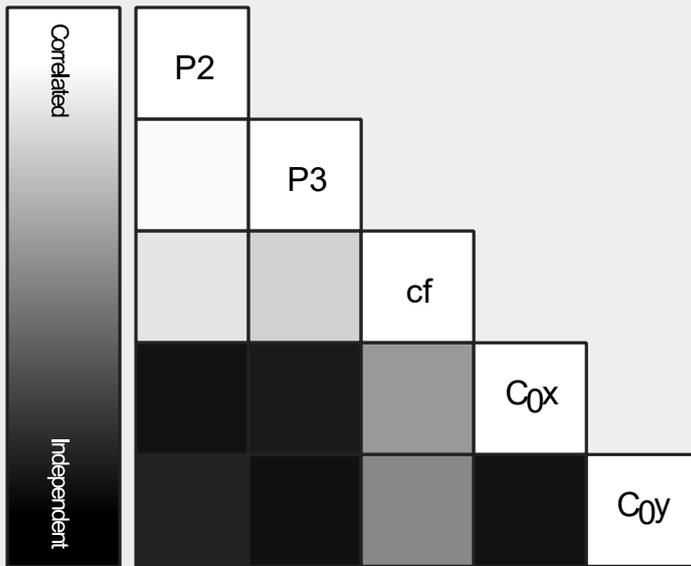
The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera model, is color coded between black and white. White indicates that, on average, more than 16 ATPs have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization. The scale bar indicates the magnitude of 1 pixel error.

Internal Camera Parameters

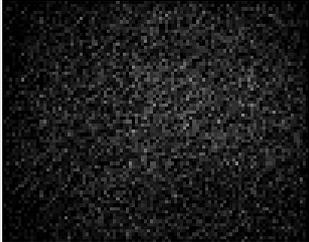
Sequoia_4.0_1280x960 (NIR). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.016113	-0.157434	0.000000	1662.68	0.00	0.00	1662.68	682.92	508.18
Optimized Values	0.000000	1.000000	0.016436	-0.157946	0.000000	1662.68	0.00	0.00	1662.68	682.92	508.18
Uncertainties (Sigma)			0.039400	0.065420		10.63	0.00	0.00	10.63	7.45	6.37



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera model, is color coded between black and white. White indicates that, on average, more than 16 ATPs have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization. The scale bar indicates the magnitude of 1 pixel error.

Camera Rig «Sequoia» Relatives. Images: 1196

	Transl X [m]	Transl Y [m]	Transl Z [m]	Rot X [degree]	Rot Y [degree]	Rot Z [degree]
Sequoia_4.0_1280x960 (Green)	Reference Camera					
Sequoia_4.0_1280x960 (Red)						

Initial Values	0.000	-0.015	0.000	-0.361	-0.100	-0.092
Optimized values	0.000	-0.015	0.000	-0.324	-0.006	-0.094
Uncertainties (sigma)				0.272	0.331	0.037
Sequoia_4.0_1280x960 (Red edge)						
Initial Values	0.015	0.000	0.000	-0.119	0.032	0.067
Optimized values	0.015	0.000	0.000	-0.138	-0.026	0.077
Uncertainties (sigma)				0.233	0.279	0.030
Sequoia_4.0_1280x960 (NIR)						
Initial Values	0.015	-0.015	0.000	-0.518	-0.199	0.011
Optimized values	0.015	-0.015	0.000	-0.318	-0.020	0.013
Uncertainties (sigma)				0.361	0.422	0.042

2D Keypoints Table

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	3734
Min	9520	4
Max	10000	5999
Mean	9995	3559

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Green)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	3943
Min	9633	265
Max	10000	5999
Mean	9998	4013

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	2692
Min	9520	7
Max	10000	4398
Mean	9984	2219

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red edge)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	1533
Min	9714	8
Max	10000	5186
Mean	9979	1963

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (NIR)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	2421
Min	10000	4

Max	10000	5611
Mean	10000	2316

Median / 75% / Maximal Number of Matches Between Camera Models

	Sequoia_4.0_1 (Green)	Sequoia_4.0_128 (Red)	Sequoia_4 (Red edge)	Sequoia_4.0_128 (NIR)
Sequoia_4.0_1280x960 (Green)	55 / 272 / 3408	6 / 24 / 1104	6 / 24 / 1107	2 / 5 / 394
Sequoia_4.0_1280x960 (Red)		266 / 1119 / 3705	2 / 3 / 67	2 / 4 / 37
Sequoia_4.0_1280x960 (Red edge)			192 / 1286 / 3372	24 / 113 / 788
Sequoia_4.0_1280x960 (NIR)				107 / 2522 / 3847

? 3D Points from 2D Keypoint Matches



	Number of 3D Points Observed
In 2 Images	356057
In 3 Images	95241
In 4 Images	41563
In 5 Images	19532
In 6 Images	10156
In 7 Images	5724
In 8 Images	3378
In 9 Images	2076
In 10 Images	1284
In 11 Images	865
In 12 Images	573
In 13 Images	364
In 14 Images	249
In 15 Images	143
In 16 Images	98
In 17 Images	60
In 18 Images	41
In 19 Images	24
In 20 Images	10
In 21 Images	1
In 22 Images	2
In 23 Images	4
In 25 Images	1

2D Keypoint Matches

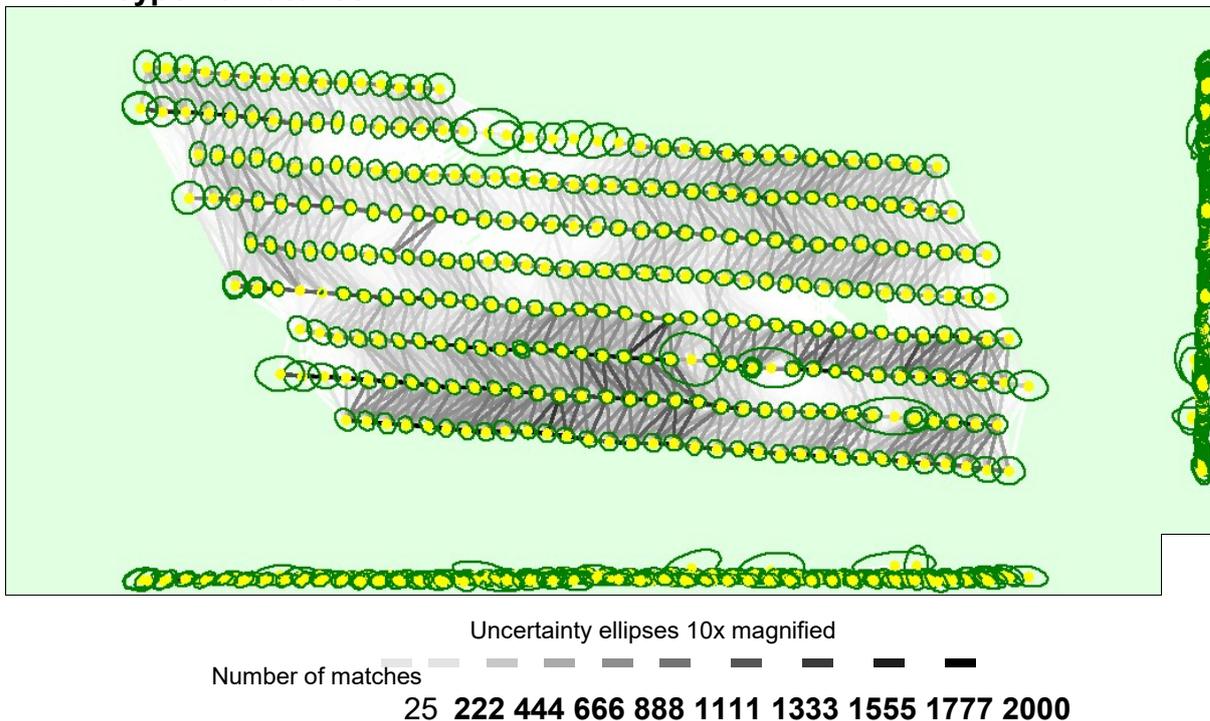


Figure 5: Computed image positions with links between matched images. The darkness of the links indicates the number of matched 2D keypoints between the images. Bright links indicate weak links and require manual tie points or more images. Dark green ellipses indicate the relative camera position uncertainty of the bundle block adjustment result.

Relative camera position and orientation uncertainties

	X [m]	Y [m]	Z [m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	1.127	1.090	0.671	0.436	0.486	0.224
Sigma	0.470	0.322	0.272	0.144	0.214	0.088

Geolocation Details

Ground Control Points

GCP Name	Accuracy XY/Z [m]	Error X [m]	Error Y [m]	Error Z [m]	Projection Error [pixel]	Verified/Marked
P03 (3D)	0.020/ 0.020	-0.111	0.239	0.011	0.738	44 / 52
P05 (3D)	0.020/ 0.020	0.201	-0.050	0.032	0.656	63 / 63
P06 (3D)	0.020/ 0.020	0.081	0.189	-0.052	0.194	3 / 5
P07 (3D)	0.020/ 0.020	-0.193	-0.271	-0.004	0.627	23 / 30
Mean [m]		-0.005349	0.026660	-0.002922		
Sigma [m]		0.154929	0.203799	0.030899		
RMS Error [m]		0.155022	0.205536	0.031037		

Localisation accuracy per GCP and mean errors in the three coordinate directions. The last column counts the number of calibrated images where the GCP has been automatically verified vs. manually marked.

? Absolute Geolocation Variance

Min Error [m]	Max Error [m]	Geolocation Error X [%]	Geolocation Error Y [%]	Geolocation Error Z [%]
-	-4.30	0.00	0.00	0.00
-4.30	-3.44	0.00	0.00	0.00
-3.44	-2.58	0.00	0.00	0.00
-2.58	-1.72	0.00	0.00	0.00
-1.72	-0.86	0.00	0.00	6.69
-0.86	0.00	52.87	49.53	39.81
0.00	0.86	47.13	50.47	50.05
0.86	1.72	0.00	0.00	3.45
1.72	2.58	0.00	0.00	0.00
2.58	3.44	0.00	0.00	0.00
3.44	4.30	0.00	0.00	0.00
4.30	-	0.00	0.00	0.00
Mean [m]		-0.173392	-2.549217	-0.032401
Sigma [m]		0.138180	0.381502	0.523293
RMS Error [m]		0.221717	2.577606	0.524295

Min Error and Max Error represent geolocation error intervals between -1.5 and 1.5 times the maximum accuracy of all the images. Columns X, Y, Z show the percentage of images with geolocation errors within the predefined error intervals. The geolocation error is the difference between the initial and computed image positions. Note that the image geolocation errors do not correspond to the accuracy of the observed 3D points.

Geolocation Bias	X	Y	Z
Translation [m]	-0.160128	-2.554208	-0.036490

Bias between image initial and computed geolocation given in output coordinate system.

? Relative Geolocation Variance

Relative Geolocation Error	Images X [%]	Images Y [%]	Images Z [%]
[-1.00, 1.00]	100.00	100.00	100.00
[-2.00, 2.00]	100.00	100.00	100.00
[-3.00, 3.00]	100.00	100.00	100.00
Mean of Geolocation Accuracy [m]	1.189855	1.189855	2.106237
Sigma of Geolocation Accuracy [m]	0.042429	0.042429	0.087615

Images X, Y, Z represent the percentage of images with a relative geolocation error in X, Y, Z.

Geolocation Orientational Variance	RMS [degree]
Omega	4.403
Phi	4.487
Kappa	9.567

Geolocation RMS error of the orientation angles given by the difference between the initial and computed image orientation angles.

Initial Processing Details

System Information

Hardware	CPU: Intel(R) Core(TM) i5-3570 CPU @ 3.40GHz RAM: 8GB GPU: Intel(R) HD Graphics (Driver: 10.18.10.4425), RDPDD Chained DD (Driver: unknown), RDP Encoder Mirror Driver (Driver: unknown), RDP Reflector Display Driver (Driver: unknown)
Operating System	Windows 7 Professional, 64-bit

Coordinate Systems

Image Coordinate System	WGS84 (egm96)
Ground Control Point (GCP) Coordinate System	WGS 84 / UTM zone 22S (egm96)
Output Coordinate System	WGS 84 / UTM zone 22S (egm96)

Processing Options

Detected Template	Ag Multispectral
Keypoints Image Scale	Full, Image Scale: 2
Advanced: Matching Image Pairs	Aerial Grid or Corridor
Advanced: Matching Strategy	Use Geometrically Verified Matching: yes
Advanced: Keypoint Extraction	Targeted Number of Keypoints: Custom, Number of Keypoints: 10000
Advanced: Calibration	Calibration Method: Alternative Internal Parameters Optimization: All External Parameters Optimization: All Rematch: Custom, yes
Rig «Sequoia» processing	optimize relative rotation using a subset of secondary cameras

Point Cloud Densification details

Processing Options

Image Scale	multiscale, 1 (Original image size, Slow)
Point Density	Low (Fast)
Minimum Number of Matches	3
3D Textured Mesh Generation	yes
3D Textured Mesh Settings:	Resolution: Medium Resolution (default) Color Balancing: no
LOD	Generated: no
Advanced: 3D Textured Mesh Settings	Sample Density Divider: 1
Advanced: Image Groups	Green, NIR, Red, Red edge
Advanced: Use Processing Area	yes
Advanced: Use Annotations	yes
Time for Point Cloud Densification	14m:36s
Time for Point Cloud Classification	NA
Time for 3D Textured Mesh Generation	05m:34s

Results

Number of Generated Tiles	1
Number of 3D Densified Points	3155219
Average Density (per m ³)	1.4

DSM, Orthomosaic and Index Details

Processing Options

DSM and Orthomosaic Resolution	1 x GSD (13 [cm/pixel])
DSM Filters	Noise Filtering: yes Surface Smoothing: yes, Type: Sharp
Raster DSM	Generated: yes Method: Inverse Distance Weighting Merge Tiles: yes
Orthomosaic	Generated: yes Merge Tiles: yes GeoTIFF Without Transparency: yes Google Maps Tiles and KML: no
Raster DTM	Generated: yes Merge Tiles: yes
DTM Resolution	5 x GSD (13 [cm/pixel])
Index Calculator: Radiometric Calibration	Generated: yes
Index Calculator: Reflectance Map	Generated: yes Resolution: 1 x GSD (13 [cm/pixel]) Merge Tiles: yes
Index Calculator: Indices	green, nir, red, red_edge, ndvi
Index Calculator: Index Values	Polygon Shapefile [cm/grid]: 400
Time for DSM Generation	05m:46s
Time for Orthomosaic Generation	17m:47s
Time for DTM Generation	01m:09s
Time for Contour Lines Generation	00s
Time for Reflectance Map Generation	48m:14s
Time for Index Map Generation	04m:30s

Camera Radiometric Correction

Camera Name	Band	Radiometric Correction Type
Sequoia_4.0_1280x960	Green	Camera and Sun Irradiance
Sequoia_4.0_1280x960	Red	Camera and Sun Irradiance
Sequoia_4.0_1280x960	Red edge	Camera and Sun Irradiance
Sequoia_4.0_1280x960	NIR	Camera and Sun Irradiance

ANEXO D – Resultado de Análise de Tecido Vegetal

Este anexo contém os resultados da análise de tecido vegetal para as amostras foliares coletadas em campo. A Prancha I corresponde aos diferentes talhões da propriedade, enquanto a Prancha II corresponde as árvores cujo fator de refletância foi auferido pelo espectrorradiômetro.

PRANCHA I

Página 1 de 2 ▼

CURSO DE AGRONOMIA – Laboratório de Nutrição de Plantas

Faculdade de Ciências Agrárias da Unoeste – Rodovia Raposo Tavares, Km 572 – Bairro Limoeiro.
CEP 19067-175 – Presidente Prudente – São Paulo – Fone (18) 3229-2039 / 3229-2073

RESULTADO DE ANÁLISE DE TECIDO VEGETAL

LARANJEIRA VALÊNCIA

Amostras Código	Área	MACRONUTRIENTES						MICRONUTRIENTES				
		N	P	K	Ca	Mg	S	B	Cu	Fe	Mn	Zn
		g kg ⁻¹						g kg ⁻¹				
1056	V-19 (A)	27,2	1,65	13,5	35,3	5,2	2,6	77,5	103,5	26,9	6,7	36,7
1057	B	28,0	1,60	10,4	39,6	5,4	2,7	72,5	135,6	199,8	16,0	59,9
1058	C	28,5	1,43	10,2	41,0	5,4	2,7	70,5	107,2	16,1	25,3	55,7
1059	D	24,9	1,61	14,5	31,3	5,3	2,7	95,0	100,3	18,3	27,2	26,9
1060	V-20 (A)	27,4	1,55	10,5	35,9	5,0	2,6	74,5	111,3	34,2	17,8	66,1
1061	B	26,6	1,51	9,6	45,5	5,6	2,6	93,5	125,2	33,7	6,2	7,7
1062	C	26,1	1,45	10,2	38,8	4,3	2,4	89,0	131,0	17,3	22,9	15,9
1063	D	26,2	1,69	11,0	44,2	5,0	2,7	74,5	115,0	31,7	45,5	31,8
1064	V-22 (A)	26,4	1,46	9,2	31,1	3,8	3,0	94,5	219,8	15,3	58,9	16,3
1065	B	29,1	1,43	13,9	35,2	4,2	3,1	92,0	239,9	52,5	78,7	36,7
1066	C	28,0	1,36	12,4	39,2	3,8	3,0	94,5	186,4	92,6	45,9	11,9
1067	D	30,0	1,32	12,1	27,6	2,7	2,8	108,5	201,0	62,7	27,8	44,0
1068	V-23 (A)	28,4	1,35	14,4	41,2	3,5	3,0	96,5	220,1	101,4	15,6	23,7
1069	B	29,3	1,47	13,3	39,7	3,9	3,2	88,5	263,9	55,5	33,5	32,2
1070	C	28,1	1,40	13,0	44,5	3,8	2,7	82,5	244,6	85,2	9,6	32,5
1071	D	28,9	1,32	13,5	44,0	3,6	2,6	100,5	274,0	92,5	32,9	42,0
1072	V-26 (A)	28,6	1,43	10,4	45,4	4,9	2,7	106,5	178,7	147,8	26,8	17,1
1073	B	30,1	1,41	10,1	31,7	3,3	2,8	116,5	156,8	99,7	59,5	35,1
1074	C	30,0	1,53	6,7	31,3	3,9	3,0	101,5	244,1	128,9	11,6	60,5
1075	D	28,6	1,34	8,5	35,3	3,2	2,6	97,5	265,2	122,4	34,5	47,4
1076	V-27 (A)	26,9	1,39	6,8	26,9	2,9	2,5	135,0	228,1	135,3	44,1	58,3
1077	B	27,5	1,32	10,1	35,1	2,8	2,7	119,0	231,0	119,8	54,5	54,0
1078	C	28,3	1,55	10,9	34,6	3,7	2,9	94,0	205,0	145,6	17,3	47,2
1079	D	28,7	1,39	7,7	29,4	2,8	2,4	111,0	177,1	17,9	16,7	30,7
1080	V-29 (A)	28,3	1,44	10,6	37,4	3,2	2,8	101,5	192,3	64,5	43,5	62,4
1081	B	28,2	1,38	8,7	29,3	3,3	2,6	107,5	126,0	88,9	42,9	47,4
1082	C	25,9	1,76	11,1	37,5	4,6	2,7	83,5	101,1	73,4	38,9	58,3
1083	D	26,8	1,45	8,6	36,4	4,2	2,4	90,5	130,0	11,3	45,0	64,6
1084	V-30 (A)	25,7	1,32	8,5	27,5	2,4	3,0	100,5	194,3	86,8	46,0	65,9
1085	B	27,1	0,33	11,7	38,1	2,9	0,8	93,1	234,6	84,7	69,9	90,1
1086	C	24,4	1,21	7,6	30,0	2,3	1,8	92,5	190,3	14,4	51,5	85,2

1087	D	28,3	1,40	10,1	64,6	4,9	2,8	100,0	180,78	106,9	40,4	46,7
1088	V-34 (A)	25,2	1,35	8,5	40,8	3,9	2,6	88,5	169,6	64,3	40,2	61,7
1089	B	23,5	1,37	7,0	64,7	3,6	2,5	78,0	138,6	45,8	55,2	79,9
1090	C	24,1	1,47	8,6	43,2	4,3	2,6	81,5	152,5	49,5	36,9	47,5
1091	D	25,3	1,31	9,4	43,4	4,1	2,2	85,5	152,6	52,8	38,4	44,3
1092	V-35 (A)	26,4	1,08	11,8	48,7	3,9	1,8	88,5	223,1	61,3	29,4	109,5
1093	B	27,2	1,29	9,9	31,7	2,6	2,8	88,5	188,6	86,9	58,7	47,2
1094	C- S/Am	****	****	****	****	****	****	****	****	****	****	****
1095	D	26,8	1,45	8,8	35,5	4,0	2,4	82,5	145,1	78,3	47,8	149,4
1096	V-36 (A)	26,5	1,39	9,6	31,7	2,8	2,4	90,5	149,1	99,8	55,8	68,2
1097	B	26,8	1,44	11,2	40,3	3,0	3,1	79,5	140,6	89,1	61,2	52,9
1098	C	29,5	1,37	12,0	41,1	3,7	3,0	78,5	156,0	123,5	18,3	45,8
1099	D	29,0	1,37	9,0	35,3	2,9	2,9	88,0	205,5	81,8	52,9	49,9
1100	V-37 (A)	23,2	1,43	11,1	37,0	3,4	2,7	81,0	124,9	61,8	47,7	47,9
1101	B	27,9	1,45	9,0	35,5	4,0	2,5	75,0	112,1	62,9	39,8	94,7
1102	C	26,1	1,55	10,6	30,8	3,5	2,6	66,0	110,5	64,2	22,1	77,4
1103	D	27,6	1,50	10,3	48,9	4,9	2,5	72,5	155,2	91,1	40,8	56,6
1104	V-38 (A)	24,9	1,39	11,8	31,9	3,6	2,4	72,5	152,3	62,3	50,5	43,8
1105	B	25,1	1,46	10,3	40,3	3,5	2,5	76,0	163,4	87,5	57,0	59,4
1106	C	26,1	1,51	8,4	30,6	3,4	2,5	71,0	155,7	73,9	41,8	16,7
1107	D	28,7	1,55	10,3	39,2	3,2	2,7	80,0	157,3	31,4	46,9	58,6
1108	V-39 (A)	25,3	1,49	9,1	31,9	3,3	2,5	84,0	168,1	65,7	41,9	38,4
1109	B	22,9	1,65	14,2	42,3	5,0	2,9	81,0	132,5	91,2	66,3	23,5
1110	C	26,6	1,59	11,5	39,2	4,4	2,4	83,5	171,0	40,2	18,3	37,0
1111	D	27,7	1,40	11,4	38,8	3,8	2,5	95,0	180,8	51,0	45,2	47,7

Metodologia de Análise:

Avaliação do Estado Nutricional das Plantas: Princípios e Aplicações. 2ª edição. Malavolta *et al.* (1997). Potafos.

PRANCHA II

Página 1 de 2 ▼

CURSO DE AGRONOMIA – Laboratório de Nutrição de Plantas

Faculdade de Ciências Agrárias da Unoeste – Rodovia Raposo Tavares, Km 572 – Bairro Limoeiro.
CEP 19067-175 – Presidente Prudente – São Paulo – Fone (18) 3229-2039 / 3229-2073

RESULTADO DE ANÁLISE DE TECIDO VEGETAL

LARANJEIRA VALÊNCIA

Amostras Código	Área	MACRONUTRIENTES						MICRONUTRIENTES			
		N	P	K	Ca	Mg	S	Cu	Fe	Mn	Zn
		g kg ⁻¹						g kg ⁻¹			
1112	VR19(A)	25,0	1,21	17,7	39,9	6,9	2,3	84,4	81,2	48,9	49,1
1113	C	29,8	1,64	19,4	35,8	9,9	2,5	62,8	51,3	23,6	30,2
1114	VR20(A)	26,6	1,42	14,7	78,6	5,0	3,6	98,2	207,3	47,8	51,4
1115	B- S/Am.	****	****	****	****	****	****	****	****	****	****
1116	C	28,1	2,13	14,1	31,2	5,8	1,8	27,8	72,5	22,6	21,0
1117	VR22(A)	34,0	1,89	15,7	47,6	4,3	2,6	80,4	26,2	27,6	41,2
1118	B	26,3	2,02	11,8	28,1	5,8	2,5	25,5	63,6	14,4	16,2
1119	C	29,7	2,21	14,7	25,3	5,0	2,6	43,4	163,7	22,3	18,9
1120	VR23(B)	30,6	2,48	16,5	29,6	5,1	2,8	44,7	66,4	14,4	16,2
1121	C	29,2	2,08	19,5	34,2	5,7	2,5	87,1	95,7	32,9	22,8
1122	D	29,0	2,37	18,6	41,5	7,8	3,0	57,6	134,1	41,7	39,4
1123	A	36,7	2,98	16,3	12,1	4,7	2,1	34,8	50,7	27,8	11,8
1124	VR26(A)	30,2	2,37	14,2	22,6	5,3	2,1	46,3	36,3	16,5	10,9

1125	B	29,7	2,77	15,2	10,7	3,7	2,0	39,4	32,6	14,3	24,8
1126	D	27,3	2,40	17,2	20,5	5,2	2,0	63,8	72,9	25,1	40,8
1127	VR27(B)	28,0	2,68	16,9	30,4	6,1	2,1	48,9	124,8	26,2	20,0
1128	C	34,5	1,80	28,3	18,4	4,2	2,5	66,0	44,4	26,9	25,2
1129	VR34(A)	30,7	2,68	17,0	28,1	5,4	2,3	98,5	59,3	31,3	29,5
1130	D	31,1	1,93	18,0	30,1	4,7	2,2	61,4	75,5	45,9	21,4
1131	B	26,1	1,56	17,8	35,8	6,6	2,2	128,9	147,8	46,7	44,0
1132	C	26,8	1,60	15,2	52,8	5,9	2,5	105,7	125,0	122,1	69,8
1133	VR36(B)	30,4	1,71	18,2	48,9	7,6	2,6	88,3	107,1	51,1	44,4
1134	C	32,9	1,85	19,8	32,8	5,3	2,8	78,7	113,6	44,5	19,5
1135	VR37(A)	31,7	2,58	18,2	26,4	5,6	2,4	61,7	58,8	41,7	21,9
1136	B	33,9	2,40	23,5	34,3	5,3	2,7	97,7	87,3	51,1	22,8
1137	C	32,0	2,04	12,3	22,7	6,6	2,1	93,1	85,6	32,9	23,7
1138	D	27,4	2,32	14,4	19,2	4,0	2,0	95,2	55,9	41,4	17,4
1139	VR38(B)	33,4	2,23	15,6	23,8	5,0	2,6	80,2	101,6	37,8	17,8
1140	C	28,4	2,44	21,4	23,8	5,0	2,3	73,8	68,7	40,3	19,9
1141	D	27,4	2,59	15,8	14,8	3,8	1,8	52,5	81,8	33,3	20,3
1142	A	26,9	1,44	15,2	37,4	4,0	2,4	111,3	111,9	52,5	33,2
1143	VR39(B)	27,9	1,88	21,2	19,9	2,7	2,1	110,9	72,8	30,3	24,3
1144	C	24,0	2,48	12,0	25,8	3,5	1,6	61,4	105,9	38,2	19,0

Metodologia de Análise:

Avaliação do Estado Nutricional das Plantas: Princípios e Aplicações. 2ª edição. Malavolta *et al.* (1997). Potafos.