

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE CIÊNCIAS AGRÁRIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

ALESSANDRO STACHAK

**AVALIAÇÃO DO ESTADO NUTRICIONAL DE NITROGÊNIO E ESTIMATIVA DA
PRODUTIVIDADE DE BIOMASSA DE TRIGO POR MEIO DE MINERAÇÃO DE
DADOS DE SENSORIAMENTO REMOTO**

PONTA GROSSA

2018

ALESSANDRO STACHAK

**AVALIAÇÃO DO ESTADO NUTRICIONAL DE NITROGÊNIO E ESTIMATIVA DA
PRODUTIVIDADE DE BIOMASSA DE TRIGO POR MEIO DE MINERAÇÃO DE
DADOS DE SENSORIAMENTO REMOTO**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, como parte dos requisitos para obtenção do título de Mestre em Computação Aplicada.

Orientador: Prof. Dr. Eduardo Fávero Caires
Coorientadora: Prof.^a Dr.^a Alaine Margarete
Guimarães

PONTA GROSSA

2018

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

S775 Stachak, Alessandro
Avaliação do estado nutricional de nitrogênio e estimativa da produtividade de biomassa de trigo por meio de mineração de dados de sensoriamento remoto/
Alessandro Stachak. Ponta Grossa, 2018.
82f.

Dissertação (Mestrado em Computação Aplicada - Área de Concentração: Computação para Tecnologias em Agricultura), Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Eduardo Fávero Caires.

Coorientadora: Prof^a Dr^a Elaine Margarete Guimarães.

1.Trigo. 2.Biomassa. 3.Nitrogênio. 4.Sensoriamento remoto. 5.GREENSEEKER. I.Caires, Eduardo Fávero. II. Guimarães, Elaine Margarete. III. Universidade Estadual de Ponta Grossa. Mestrado em Computação Aplicada. IV. T.

CDD: 006.312

TERMO DE APROVAÇÃO

Alessandro Stachak

“AVALIAÇÃO DO ESTADO NUTRICIONAL DE NITROGÊNIO E ESTIMATIVA DA PRODUTIVIDADE DE BIOMASSA DE TRIGO POR MEIO DE MINERAÇÃO DE DADOS DE SENSORIAMENTO REMOTO”

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:



Dr. Eduardo Fávero Caires
UEPG



Dr. Claudio Kapp Junior
FUNDAÇÃO ABC/Castro-PR



Dr. José Carlos Ferreira da Rocha
UEPG

Ponta Grossa, 15 de março de 2018.

DEDICATÓRIA

Dedico a minha mãe.

AGRADECIMENTOS

À minha mãe, Ruth, pela paciência, atenção, educação e pelo apoio incondicional.

Ao meu orientador, Prof. Dr. Eduardo Fávero Caires, pelo apoio e orientação para a elaboração dessa pesquisa, pela enorme paciência em explicar assuntos óbvios de agronomia, pela dedicação e empenho pessoal à ciência.

À Prof^a. Dr^a. Elaine Margarete Guimarães, pelo apoio, conversas, orientação durante todos os passos da pesquisa, pela paciência em corrigir tudo aquilo que escrevi, foi uma honra tê-la como coorientadora.

Aos meus colegas do laboratório InfoAgro, Luiz Rodolfo, Pablo Ferreira, Victor Lacerda, Tiago Gerke, Fabio Santos, Giancarlo Rodrigues e, em especial, David Viniski, David Zampier, Rayson Laroca e Jackson Genilson pelo apoio e ajuda nas longas jornadas de trabalho nas áreas experimentais.

Aos colegas do Laboratório de Fertilidade do Solo, Vanderson pela ajuda com amostras e trabalhos na área experimental, Dirce, Felipe e Ângelo pela enorme ajuda e paciência no auxílio para a realização das análises químicas.

A equipe da Fazenda Paiquerê, em especial ao Eng. Agrônomo Allisson José Fornari, por ceder a área, equipamento e dados das colheitas para possibilitar a realização desta pesquisa.

Ao Eng^o. Agrônomo Fabiano Paganella, por ter gentilmente fornecido os dados das imagens obtidas pelo satélite.

Ao meu pai e irmão que mesmo distantes sempre me apoiaram.

Aos colegas de Asamco, Sr. Bruno, Sr. José e Sr. Diego pelas longas conversas pós treino e pelas idas para Carambeí.

Às amigas Bruna Lumiane, Bianca e Tânia, pelo apoio, sempre dizendo para não desistir, sempre me dando força.

À Coordenação de Aperfeiçoamento do Pessoal de Nível Superior pelo apoio financeiro.

EPÍGRAFE

*I've seen things you people wouldn't believe. Attack ships on
fire off the shoulder of Orion. I watched C-beams glitter in the dark
near the Tannhäuser Gate. All those moments will be lost, in time, like
tears in rain.*

(Roy Batty em Blade Runner, 1982)

RESUMO

Estimar a produtividade de biomassa na agricultura é uma ferramenta chave no manejo da lavoura, gerando informações que podem auxiliar a complexa tomada de decisões no campo. O nitrogênio (N), por ser é um nutriente que participa da estrutura e de funções celulares vitais à planta, apresenta estreita correlação com a produtividade de biomassa, principalmente na cultura do trigo (*Triticum aestivum* L.). Uma técnica muito utilizada na estimativa de biomassa e estado nutricional de N é o sensoriamento remoto (SR), que consiste na aquisição de informações de um objeto sem existir contato entre o sensor e o alvo. No SR existem três plataformas de obtenção de dados, sendo elas: orbital, por meio de satélites; aéreo, com aviões, helicópteros e aeronaves remotamente pilotadas (RPA); e terrestre, com sensores óticos e espectraloradiômetros. Na criação de modelos de estimativa de produtividade de biomassa e de teor foliar de N, as três plataformas do SR são empregadas, já existindo produtos comerciais para tais finalidades. Entretanto, existe carência de informações a respeito da eficiência das tais plataformas em um mesmo estudo de campo. Tradicionalmente, os modelos preditivos com dados de SR na agricultura são gerados por técnicas clássicas de estatística, como a regressão linear. No entanto, técnicas da mineração de dados (MD) podem obter resultados mais relevantes. Dentre as técnicas da MD promissoras, a máquina de vetores de suporte para regressão (SVR), devido a sua grande capacidade de generalização e criação de modelos lineares e não lineares, tem sido empregada em dados de SR. Os objetivos deste trabalho foram: (i) avaliar a correlação entre os dados obtidos a partir das três plataformas do SR na estimativa da produtividade de biomassa seca da parte aérea e da concentração de N nas folhas de trigo, e (ii) comparar os resultados obtidos com a técnica clássica de regressão linear em relação aqueles gerados pela SVR. Para isso, plantas de trigo, cultivar TBIO Sinuelo, foram cultivadas em diferentes ambientes envolvendo manejos distintos de adubação nitrogenada. A avaliação da capacidade dos sensores foi abordada de duas formas: (i) com amostras aleatórias em diferentes estádios de desenvolvimento da cultura do trigo dentro de cada tratamento de adubação nitrogenada, verificando a capacidade do sensor em detectar a variabilidade em áreas com um mesmo tratamento, e (ii) com as médias das amostras em cada tratamento, avaliando a capacidade do sensor em detectar as diferenças provocadas por manejos variados de adubação nitrogenada. Os resultados obtidos demonstraram existência de correlação dos dados gerados pelos equipamentos utilizados (sensor terrestre *GREENSEEKER*, satélites *RAPIDEYE* e RPA *EBEE*) com a produtividade de biomassa seca da parte aérea e a concentração de N nas folhas de trigo. A SVR gerou coeficientes de correlação (r) mais expressivos do que a regressão linear sobre os dados obtidos com todos os equipamentos utilizados. Dentre as plataformas, considerando a abordagem com as amostras aleatórias no campo, os dados gerados com a RPA *EBEE* apresentaram correlação mais estreita com a estimativa de biomassa da parte aérea e a concentração foliar de N. Já, quando se consideraram as médias dos tratamentos de adubação nitrogenada, tanto a RPA *EBEE* como os satélites *RAPIDEYE* apresentaram resultados similares na estimativa de produtividade de biomassa da parte aérea. Porém, para a predição do teor foliar de N, a RPA *EBEE* proporcionou resultados superiores em relação aos obtidos com os satélites *RAPIDEYE*. Concluiu-se que a plataforma RPA *EBEE* foi mais eficiente do que as plataformas terrestre (*GREENSEEKER*) e orbital (satélites *RAPIDEYE*) para estimar a produtividade de biomassa da parte aérea e a concentração de N nas folhas de trigo, quando existe maior variabilidade na área de estudo, e que a SVR foi uma técnica mais eficiente do que a regressão linear para análise dos dados das três plataformas: orbital, aérea e terrestre.

Palavras chave: Trigo, biomassa, nitrogênio, sensoriamento remoto, *GREENSEEKER*, *EBEE*, *RAPIDEYE*, mineração de dados, máquina de vetores de suporte.

ABSTRACT

Estimating biomass productivity in agriculture is a key part in crop management, providing information that can help the complex decision making in the field. Nitrogen (N), for being a nutrient that participates in the structure and vital cellular functions to the plant, has a close correlation with biomass productivity, mainly in wheat crop (*Triticum aestivum* L.). Remote sensing (RS), which consists of acquiring information from an object without contact between the sensor and the target, is a widely employed technique in estimating biomass and nutritional status of N. There are three RS platforms for obtaining data: orbital, with satellites; aerial, with aircraft, helicopters and remotely piloted aircraft (RPA); and terrestrial, with optical sensors and spectral radiometers. When determining biomass productivity and N foliar content estimation models, both RS platforms are employed, and commercial products for these purposes already exists. However, there is a lack of information regarding the efficiency of the three platforms in the same experimental area. Traditionally, predictive models with RS data in agriculture are generated by classic statistical techniques, such as linear regression. However, data mining (DM) techniques can provide more relevant results. Due to its generalization capacity and feature of creating linear and nonlinear models, support vector machine for regression (SVR) is a DM technique with intensive use over RS data. The goals of this work were: (i) to evaluate the correlation between data obtained from the three RS platforms for estimating dry biomass productivity and N concentration in wheat leaves, and (ii) to compare the results obtained with a classical linear regression technique against those of the SVR technique. Were cultivated wheat plants, TBIO Sinuelo variety, in different environments involving distinct management of nitrogen fertilization. The sensors evaluation was performed in two ways: (i) with random samples at different wheat crop development stages for each nitrogen fertilization treatment, aiming to verify the sensor ability to detect variability in areas with the same treatment, and (ii) considering the mean value of the samples in each treatment, evaluating the ability of the sensor to detect the differences caused by varied management of nitrogen fertilization. The results showed that data generated by the equipment (*GREENSEEKER* terrestrial sensor, *RAPIDEYE* satellites and *RPA EBEE*) displayed correlation with dry biomass productivity and N concentration in wheat leaves. More expressive correlation coefficients (r) were obtained with SVR against those of linear regression in the data obtained with all equipment used. Considering the approach with the random samples in the field, data generated with the *RPA EBEE* showed a closer correlation with the biomass estimation and the foliar concentration of N. When considering the mean value of nitrogen fertilization treatments, both *RPA EBEE* and *RAPIDEYE* satellites presented similar results for estimating biomass productivity, however, the *RPA EBEE* provided results slightly higher than those obtained with the *RAPIDEYE* satellites for the prediction of N foliar content. It was concluded that, for estimating the biomass productivity and the N concentration in the wheat leaves *RPA EBEE* platform is more efficient than the terrestrial (*GREENSEEKER*) and orbital platforms (*RAPIDEYE* satellites) when there is greater variability in the study area. Also, SVR was a more efficient technique than linear regression for data analysis of the three platforms: orbital, aerial and terrestrial.

Keywords: Wheat, biomass, nitrogen, remote sensing, *GREENSEEKER*, *EBEE*, *RAPIDEYE*, data mining, support vector machine.

LISTA DE FIGURAS

Figura 1 - Sensor ótico <i>GREENSEEKER</i> acoplado a uma semeadora-adubadora.	25
Figura 2 - RPA de asa fixa (à esquerda) e multirrotor (à direita).	27
Figura 3 - Ortofoto capturada com RPA e ortomosaico gerado por um conjunto de ortofotos.	30
Figura 4 - Esquema de sobreposição de imagens aéreas para geração de um ortomosaico, com sobreposição de 60% horizontal e 30% na vertical, observando o sentido do voo.	30
Figura 5 - Diagrama de execução do processo de mosaicagem. (a) o algoritmo encontrou 4 pontos em comum nas duas fotos e (b) a mescla das imagens sobre os pontos em comum. ...	31
Figura 6 - Espectro eletromagnético.	32
Figura 7 - Etapas da descoberta do conhecimento.	35
Figura 8 – Exemplos de gráficos da regressão linear (a) e não linear (b).	36
Figura 9 - Modelo de divisão linear binária em uma SVM.	38
Figura 10 - Demarcação das parcelas na área experimental. Fazenda Paiquerê – Pirai do Sul – PR.	40
Figura 11 - Precipitação pluvial média mensal ocorrida na área experimental durante o período de desenvolvimento da cultura do trigo, em 2016, e precipitação média mensal histórica (30 anos) do município de Pirai do Sul – PR.	41
Figura 12 - Arquivo SHAPFILE do NDVI gerado por satélite visualizado no software QGIS.	43
Figura 13 - RPA modelo <i>EBEE</i> usada no imageamento aéreo.	43
Figura 14 - Câmeras usados no imageamento, (a) Sony EX RGB e (b) Canon S110 NIR.	44
Figura 15 - Sensor <i>GREENSEEKER</i>	45
Figura 16 - Nuvem de pontos com um ponto selecionado	48
Figura 17 - Posições dos GCPs dentro da área experimental.	49
Figura 18 - (a) GCP sem correção e (b) GCP com correção.	49
Figura 19 - a) Ortomosaico com a correção das cores, b) Mapa de refletância sem correção das cores.	50
Figura 20 - Pontos de amostras em campo correspondentes aos meses de agosto (círculos azuis) e de setembro (círculos amarelos) de 2016, dentro da área experimental.	51
Figura 21 - Pontos com polígonos para a extração dos dados de refletância.	51

Figura 22 - Polígono com pontos para extração dos valores de refletância com duas densidades: (a) 100% dos pixels e (b) 50% dos pixels.	52
Figura 23 - Polígonos para extração de dados de refletância baseados na divisão das parcelas.	53
Figura 24 - Pontos regulares sobre as parcelas contendo os tratamentos para a extração dos valores de refletância.	54
Figura 25 - Polígonos utilizados para a validação das bases de satélite.....	55
Figura 26 - Resultado da importação dos dados do <i>GREENSEEKER</i> coletados no mês de outubro para o QGIS.	56

LISTA DE QUADROS

Quadro 1 - Satélites empregados no SR com suas respectivas resoluções espacial, espectral e radiométrica.	23
Quadro 2 - Trabalhos com aplicação de índices de vegetação (IVs) na agricultura em modelos preditivos.	34
Quadro 3 - Trabalhos na agricultura envolvendo o desempenho de culturas de grãos, com as técnicas de regressão empregadas.	36
Quadro 4 - Tratamentos utilizados no estudo, com as doses e as épocas de aplicação de nitrogênio.....	41
Quadro 5 - Datas de imageamento com os satélites <i>RAPIDEYE</i> nos diferentes estádios fenológicos do trigo.....	42
Quadro 6 - Resolução espectral das câmeras usadas no imageamento aéreo com a RPA <i>EBEE</i>	44
Quadro 7 - Data de realização dos voos, câmeras empregadas, resolução espacial, número de fotos obtidas durante o voo, altura de captura das imagens e estágio fenológico da cultura do trigo durante o sensoriamento.....	45
Quadro 8 - Fragmento de base de dados gerada da extração dos valores de refletância para os canais R, G e NIR, utilizando a câmera NIR com resolução espacial de 3,4 cm.....	52
Quadro 9 - Fragmento da base gerada com os dados de satélite.	55
Quadro 10 - Fragmento da base gerada com os dados do <i>GREENSEEKER</i> no mês de outubro de 2016.	56
Quadro 11 - Índices de vegetação gerados com os dados da RPA.....	57
Quadro 12 - Fragmento de código em R referente à aplicação de uma tarefa de mineração de dados.....	58

LISTA DE TABELAS

Tabela 1 - Concentração de nitrogênio nas folhas e produtividade de biomassa da parte aérea do trigo, em diferentes estádios de desenvolvimento da cultura, de acordo com os tratamentos de adubação nitrogenada.	59
Tabela 2 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados com <i>GREENSEEKER</i> para estimar a produtividade de biomassa seca da parte aérea de trigo, considerando todas as amostras e as médias dos tratamentos.	60
Tabela 3 - Coeficientes de correlação (r) obtidos com regressão linear sobre os dados gerados com <i>GREENSEEKER</i> para estimar a produtividade de biomassa seca da parte aérea de trigo, considerando todas as amostras e as médias dos tratamentos.	61
Tabela 4 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados pelo <i>GREENSEEKER</i> para a estimativa da concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.	62
Tabela 5 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados pelo <i>GREENSEEKER</i> para a estimativa da concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.	63
Tabela 6 - Coeficientes de correlação (r) obtidos com SVR sobre os dados gerados com os satélites <i>RAPIDEYE</i> para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando todas as amostras.	64
Tabela 7 - Coeficientes de correlação (r) obtidos com SVR sobre os dados gerados com os satélites <i>RAPIDEYE</i> para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando as médias dos tratamentos.	65
Tabela 8 - Coeficientes de correlação (r) obtidos com regressão linear sobre os dados gerados com os satélites <i>RAPIDEYE</i> para estimar a produtividade de biomassa da parte aérea do trigo, considerando todas as amostras e as médias dos tratamentos.	65
Tabela 9 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados dos satélites <i>RAPIDEYE</i> para estimar a concentração de N nas folhas de trigo, considerando todas as amostras.	66
Tabela 10 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados dos satélites <i>RAPIDEYE</i> para estimar a concentração de N nas folhas de trigo, considerando as médias dos tratamentos.	66
Tabela 11 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados com os satélites <i>RAPIDEYE</i> para estimar a concentração de N nas folhas de trigo considerando todas as amostras e as médias dos tratamentos.	67
Tabela 12 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados com a RPA para estimar a produtividade de biomassa seca da parte aérea utilizando as bandas das câmeras, considerando todas as amostras e as médias dos tratamentos.	68

Tabela 13 - Coeficientes de correlação (r) obtidos com a SVR sobre os IVs gerados a partir dos dados obtidos com a RPA para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando todas as amostras e as médias dos tratamentos.	69
Tabela 14 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados com a RPA para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando todas as amostras e as médias dos tratamentos.....	70
Tabela 15 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados com a RPA para estimar concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.....	70
Tabela 16 - Coeficientes de correlação (r) obtidos com a SVR sobre os IV gerados através dos dados obtidos com a RPA para estimar a concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.....	72
Tabela 17 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados com a RPA para estimar a concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.	72

LISTA DE SIGLAS

ACP	Análise de Componentes Principais
AAT	<i>Automatic Aerial Triangulation</i>
AM	Aprendizado de Máquina
AP	Agricultura de Precisão
DAS	Dias Após Semeadura
DOS	<i>Dark-Object Subtraction</i>
GCS	<i>Ground Control Station</i>
GNSS	<i>Global Navigation Satellite System</i>
IV	Índice de Vegetação
KDD	<i>Knowledge Discovery in Databases</i>
LED	Diodo Emissor de Luz
MCARI	<i>Modified Chlorophyll Absorption Reflectance Index</i>
MD	Mineração de Dados
MSAVI	<i>Modified Soil-Adjusted Vegation index</i>
MTVI	<i>Modified Triangular Vegetation Index</i>
N	Nitrogênio
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
OSAVI	<i>Optimized Soil-Adjusted Vegation index</i>
PLS	<i>Partial Least Square</i>
RBF	<i>Radial Basis Function</i>
RE	<i>Red Edge</i>
REM	Radiação Eletromagnética
RGB	<i>Red Green Blue</i>
RLS	Regressão Linear Simples
RMSE	<i>Root-Mean-Square Error</i>
RNA	Redes Neurais Artificiais
RPA	<i>Remotely Piloted Aircraft</i>
RPAS	<i>Remotely Piloted Aircraft System</i>
SAVI	<i>Soil-Adjusted Vegation index</i>
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machines</i>

SVR *Support Vector Regression*

SWIR *Short Wave Infrared*

SUMÁRIO

1	INTRODUÇÃO	17
2	OBJETIVOS.....	19
2.1	OBJETIVO GERAL	19
2.2	OBJETIVOS ESPECÍFICOS	19
3	REVISÃO DA LITERATURA	20
3.1	SENSORIAMENTO REMOTO	20
3.1.1	Sensoriamento remoto orbital na agricultura	22
3.1.2	Sensoriamento remoto terrestre na agricultura	24
3.1.3	Sensoriamento remoto aéreo na agricultura	26
3.1.4	Ortomosaico.....	29
3.2	ÍNDICES DE VEGETAÇÃO.....	31
3.3	MINERAÇÃO DE DADOS.....	34
3.3.1	Modelos de regressão.....	35
3.3.2	Máquinas de vetores de suporte para regressão	37
4	MATERIAL E MÉTODOS.....	40
4.1	DELINEAMENTO EXPERIMENTAL.....	40
4.2	TRATAMENTOS E CULTURA	40
4.3	COLETA DE DADOS DE SENSORIAMENTO REMOTO.....	42
4.3.1	Sensoriamento Orbital.....	42
4.3.2	Sensoriamento Aéreo com RPA.....	43
4.3.3	Sensoriamento Terrestre com Sensor Ótico	45
4.4	AMOSTRAGEM E PROCESSAMENTO DAS PLANTAS	46
4.4.1	Coletas em campo	46
4.4.2	Massa e altura das plantas	46
4.4.3	Teor de nitrogênio foliar	47
4.5	PÓS-PROCESSAMENTO DOS DADOS OBTIDOS COM A RPA.....	47
4.6	EXTRAÇÃO DE DADOS DE REFLETÂNCIA GERADOS COM A RPA.....	50
4.6.1	Extração dos dados baseada nas amostras	50
4.6.2	Extração dos dados considerando os tratamentos	53
4.7	EXTRAÇÃO DE DADOS DE REFLETÂNCIA GERADOS COM O SATÉLITE	54

4.8	EXTRAÇÃO DE DADOS DE REFLETÂNCIA GERADOS COM O GREENSEEKER.....	56
4.9	ÍNDICES DE VEGETAÇÃO GERADOS COM OS DADOS DE RPA.....	57
4.10	MINERAÇÃO DE DADOS E TESTES ESTATÍSTICOS	57
5	RESULTADOS E DISCUSSÃO	59
5.1	DADOS COLETADOS EM CAMPO.....	59
5.2	SENSOR ÓTICO GREENSEEKER	60
5.2.1	Biomassa da parte área do trigo	60
5.2.2	Nitrogênio nas folhas de trigo	62
5.3	SATÉLITES RAPIDEYE	63
5.3.1	Biomassa da parte aérea do trigo	64
5.3.2	Nitrogênio nas folhas de trigo	65
5.4	RPA EBEE	67
5.4.1	Biomassa da parte aérea do trigo	67
5.4.2	Nitrogênio nas folhas de trigo	70
5.5	ANÁLISE CONJUNTA CONSIDERANDO AS TRÊS PLATAFORMAS DE SENSORIAMENTO REMOTO	72
6	CONCLUSÕES	74
	REFERÊNCIAS	76

1 INTRODUÇÃO

A produção de biomassa da parte aérea das plantas depende de fatores ligados ao solo, ao clima e ao genótipo. Na agricultura, a estimativa da produção de biomassa da parte aérea pode gerar subsídios para a identificação de problemas em áreas cultivadas. Essa identificação pode auxiliar no manejo preventivo, reduzindo ou mesmo eliminando o impacto dos problemas.

Dentre as técnicas utilizadas na obtenção dos dados para geração de modelos de estimativa, o Sensoriamento Remoto (SR) é amplamente utilizado, tendo alcançado resultados significativos na estimativa de biomassa seca em diversas culturas (OERKE et al., 2010). Além disso, o SR tornou-se fundamental no manejo de lavouras, em conjunto com a Agricultura de Precisão (AP), garantindo a aplicação de melhores práticas no gerenciamento do campo (RAY, 2016; SEELAN et al., 2003).

O SR consiste na obtenção de informações sem que haja contato entre o sensor e o objeto alvo, podendo ser realizado com diferentes plataformas: em nível orbital (satélites), aéreo [aviões e aeronaves remotamente pilotadas (RPA – *Remotely Piloted Aircraft*)] e terrestre (sensores óticos e radiômetros). As diferentes plataformas de sensoriamento remoto apresentam vantagens e limitações em termos de resolução espacial, temporal e fatores climáticos. Com isso, não se pode afirmar qual destas plataformas é mais adequada para estimar a produção de biomassa e o estado nutricional das plantas.

Dentre as informações disponibilizadas pelas diferentes tecnologias empregadas no sensoriamento remoto, os índices de vegetação (IVs) podem ser utilizados como variáveis auxiliares na estimativa de biomassa. Os IVs são combinações aritméticas da resposta espectral obtidas pelos sensores embarcados nas plataformas de SR. Segundo Bendig et al. (2015) e Gnyp et al. (2014), alguns IVs caracterizam-se por apresentarem correlações maiores ou menores, dependendo do tipo de cultivo e da finalidade de utilização. Com isso, novos índices podem ser gerados visando o aumento da correlação entre a resposta espectral obtida pelos sensores e o objeto de estudo.

Diversos trabalhos foram realizados visando estimar a produção de biomassa de plantas com a utilização de IVs (ALI et al., 2015; GNYP et al., 2014; HONG et al., 2007). Dentre os dados utilizados na estimativa, muitos deles foram obtidos de sensores hiperespectrais, alcançando resultados significativos nos modelos (GNYP et al., 2014). Além dos dados obtidos pelos sensores hiperespectrais, algumas pesquisas utilizaram dados nos espectros visível (faixas do vermelho, verde e azul, RGB – *Red, Green e Blue*) e do

infravermelho próximo (NIR - *Near Infrared*), conseguindo bons resultados, porém, inferiores se comparados com a estimativa realizada com dados de sensores hiperspectrais (BENDIG et al., 2015).

A produção de biomassa é bastante dependente da nutrição de nitrogênio (N). Isso porque o este elemento é um dos principais nutrientes responsáveis pelo crescimento das plantas, principalmente nas gramíneas, como o trigo (*Triticum aestivum L.*). Baixos teores de N retardam o crescimento das plantas, prejudicando o rendimento de biomassa e de grãos. Algumas pesquisas foram desenvolvidas buscando realizar análise nutricional de N na cultura do trigo por meio de dados de SR (EITEL et al., 2007; KAPP; GUIMARÃES; CAIRES, 2016). Esses trabalhos são importantes na busca de modelos de prescrição de doses ótimas de aplicação de N na cultura do trigo, considerando que as recomendações de adubação nitrogenada, normalmente, não são baseadas em resultados de análises de solo. Como o conteúdo de N no solo se encontra predominantemente na forma orgânica e a mineralização do N no solo depende de vários fatores edafoclimáticos, não há critérios seguros em se fazer recomendações de fertilizantes nitrogenados com base no teor de matéria orgânica do solo.

Para a estimativa da produção de biomassa da parte aérea e da concentração de N foliar na cultura do trigo podem ser utilizadas as plataformas de SR orbital, aéreo e terrestre. Algumas soluções comerciais já foram desenvolvidas para esta finalidade, como é o caso do sensor ótico terrestre *GREENSEEKER*, do satélite *RAPIDEYE* e a RPA *EBEE*. As RPAs têm se destacado no segmento agrícola, devido algumas vantagens sobre as plataformas orbitais, como a obtenção de dados com alta resolução temporal e espacial.

A obtenção de modelos de estimativa de produção de biomassa da parte aérea e do estado nutricional de N na cultura do trigo com dados de SR, e de fatores que afetam a eficiência das plataformas de SR orbital, aéreo e terrestre, podem fornecer informações relevantes para o gerenciamento da lavoura, podendo prover mecanismos automatizados de manejo. A técnica mais empregada na geração de modelos de estimativa é a regressão linear, sendo uma das mais conhecidas técnicas clássicas da mineração de dados (MD). No entanto, poucos trabalhos exploram outras técnicas de MD, como as redes neurais artificiais (RNA) e máquinas de vetores de suporte (SVM - *Support Vector Machines*), as quais podem proporcionar resultados ainda melhores que a regressão linear.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Desenvolver modelos preditivos para estimar a concentração foliar de N e a produtividade de biomassa da parte aérea de plantas de trigo a partir de dados gerados com SR em suas plataformas terrestre, aéreo e orbital, aplicando técnicas de MD.

2.2 OBJETIVOS ESPECÍFICOS

- Verificar qual plataforma de SR (terrestre, aéreo ou orbital) apresenta maior eficiência para estimar a concentração de N foliar e a produtividade de biomassa da parte aérea do trigo.
- Identificar quais IVs e estágio fenológico da cultura trigo têm maior capacidade preditiva para estimar a concentração de N foliar e a produtividade de biomassa da parte aérea do trigo, considerando os dados obtidos pelo sensor óptico ativo e por imagens de RPA e satélite.
- Aplicar técnicas de MD para modelar as estimativas da concentração de N nas folhas e de produtividade de biomassa parte aérea do trigo.
- Identificar qual estágio fenológico da cultura trigo têm maior capacidade preditiva para estimar a concentração de N foliar e a produtividade de biomassa da parte aérea do trigo.
- Comparar os resultados do algoritmo SVM para regressão com a regressão linear.

3 REVISÃO DA LITERATURA

3.1 SENSORIAMENTO REMOTO

O SR é a aquisição de informações sem que haja contato físico com o objeto de estudo (FISCHER; HEMPHILL; KOVER, 1976). Assim, a obtenção dos dados é realizada por meio de dispositivos que estão separados do alvo por alguma distância (HOGG, 1978). Neste sentido, o SR se tornou a mais sucedida técnica para monitoramento dos recursos naturais em nível global (MENESES et al., 2012). Os primeiros estudos sobre SR datam do século XIX, sendo que a primeira fotografia aérea foi creditada a Gépard-Félix em 1858. Utilizando um balão preso ao solo, ele capturou algumas imagens aéreas na França (CAMPBELL; WYNNE., 2011).

No SR, os dados são gerados pela captura das respostas eletromagnéticas emitidas ou refletidas do objeto alvo (LILLESAND; KIEFER; CHIPMAN, 2014). Essas informações são coletadas por sensores, os quais podem ser divididos em duas categorias principais: sensores ativos e sensores passivos. Os sensores ativos emitem radiação artificial e registram a resposta (reflexão) do alvo. Os sensores passivos registram a resposta espectral da energia refletida ou emitida pelo sol, ou ainda a energia gerada pelo próprio objeto (RAY, 2016).

A aquisição de dados por meio do SR pode ocorrer em três diferentes níveis: orbital (satélites e microssatélites), aéreo (aviões e RPAs) e terrestre. Assim, os sensores disponíveis para o SR possuem quatro características principais (MENESES et al., 2012):

- (i) Resolução espacial: Depende da distância do sensor em relação ao objeto. A resolução espacial corresponde ao quanto pode-se identificar um objeto em solo. Por exemplo, com uma resolução de 20 m não se consegue distinguir carros em uma estrada, mas já se observa um estádio de futebol. As resoluções variam entre as plataformas. Os satélites possuem resoluções que variam de 1 m a 250 m, dependendo do sensor. Tais resoluções são consideradas baixas se comparadas com as RPAs, as quais possuem resoluções entre pouco mais que 1 cm até 30 cm. Destaca-se que, no caso das RPAs, o equipamento pode sobrevoar em diferentes altitudes.
- (ii) Resolução espectral: Corresponde aos comprimentos de ondas eletromagnéticas nos quais o sensor registra as respostas espectrais. Essa característica é importante considerando que cada material reage de maneira distinta à radiação eletromagnética (REM). A resolução varia de sensor para sensor, havendo divisões para o espectro visível, com o espectro de onda de 450-760 nm e o espectro do NIR, com o comprimento de onda de 760-1200 nm. O SWIR

correspondente ao infravermelho de ondas curtas, com o comprimento de onda de 1580-1750 nm. Outras variações abrangem mais de um intervalo, como a pancromática que abrange o visível e NIR com a resolução espectral de 450-900 nm.

- (iii) Resolução radiométrica: Corresponde ao quanto cada pixel ou registro consegue determinar as diferenças de refletância. Essa quantificação é gravada por números digitais, sendo que quanto maior for a capacidade maior será a resolução radiométrica. Por exemplo, uma imagem em que cada pixel registra 8 bits será bem superior em nível de detalhes se comparada com outra de 2 bits. Nos sensores acoplados a satélites, a resolução radiométrica varia de 6 a 11 bits, para sensores com câmeras acopladas a RPAs ou aviões pilotados, a resolução radiométrica é de 8 bits para sensores que registram no RGB, 16 bits para o NIR e 10 bits por canal em multiespectrais. Esses valores podem variar de acordo com o equipamento.
- (iv) Resolução temporal: Corresponde ao número de vezes que uma mesma região pode ser monitorada durante um certo período de tempo. A resolução temporal, no caso de sensoriamento orbital, depende do tempo demandado pelo satélite para revisita de um mesmo ponto. Já, no caso de RPAs, essa resolução é mais facilmente administrada pelos profissionais, dependendo apenas de condições climáticas favoráveis, ou seja, ausência de chuvas, nuvens e ventos fortes.

Além das características mencionadas, as quais são relevantes em todos os níveis do SR, para as plataformas de SR orbital tem-se outra importante característica, conhecida como o campo de visada, a qual pode ocorrer no NADIR ou off-NADIR. O NADIR corresponde ao ponto diretamente abaixo do satélite em relação à terra, um ângulo reto; assim, os dados obtidos nessa visada tendem a ser fiéis ao objeto observado (JENSEN, 2013). Os dados off-NADIR estão fora do campo de visão abaixo do satélite, oferecendo a vantagem de maior resolução temporal, no entanto, devido ao comportamento da reflexão das ondas eletromagnéticas, os dados podem não ser fiéis ao objeto alvo (GALVÃO et al., 2001).

Os processos que geram informações providas do SR podem ser divididas em quatro etapas, segundo Campbell e Wynne (2011): (i) conhecer qual o objeto de estudo; (ii) definir o sensor a ser utilizado considerando o objeto de estudo; (iii) extrair as informações dos dados gerados pelo sensor; e (iv) aplicação das informações que pode variar dependendo do objeto de estudo.

O SR possui aplicações em diversas áreas da ciência tais como: ciências de plantas (incluindo a agricultura), ciências da Terra, ciências hidrosféricas, cobertura e uso do solo e observação da Terra (CAMPBELL; WYNNE., 2011). Um dos pioneiros do uso das técnicas de SR na agricultura foi Colwell (1956), o qual avaliou o potencial do uso de imagens no espectro do infravermelho para determinar a severidade de doenças em plantas de trigo, cevada, aveia e centeio.

Atualmente, as técnicas de SR aplicadas na agricultura contribuem significativamente para melhoria da acurácia na tomada de decisões no campo (ATZBERGER, 2013; CHANG et al., 2017; HERWITZ et al., 2004). São várias as soluções para a agricultura empregando técnicas de SR, como a estimativa de produtividade de grãos e de área plantada com dados de satélites (MERCANTE et al., 2010; RIZZI; RUDORFF, 2005), a predição de biomassa usando informações geradas com SR a partir de RPAs (BENDIG et al., 2015) e a automação na aplicação de insumos a taxa variável utilizando radiômetros (ALI et al., 2015). Essas são apenas algumas das soluções utilizando o SR oferecidas aos agricultores no mercado, com a utilização dos diferentes níveis de obtenção dos dados orbital, aéreo e terrestre.

3.1.1 Sensoriamento remoto orbital na agricultura

O SR com satélites teve sua origem junto com a exploração espacial, sendo que o primeiro satélite lançado para fins de observação terrestre foi o *Television and Infrared Observation Satellite (TIROS)*, em abril de 1960 (FRITZ; WEXLER, 1960).

Após o *TIROS*, em 1972, foi a vez do sistema *LANDSAT*, o qual foi o primeiro satélite projetado especificamente para fins de observar a Terra, seus sensores capturavam imagens no espectro do visível e no infravermelho próximo (CAMPBELL; WYNNE, 2011). Com o passar do tempo, surgiram outros satélites específicos para monitoramento da terra: o *IKONOS*, *QuickBird*, *GeoEYE-1* e *WorldView* (YANG, 2012) e o *SPOT* (RAY, 2016), cada um deles oferecendo diferentes tipos de sensores e resoluções. O Quadro 1 apresenta alguns satélites utilizados para o SR e suas especificações básicas.

Quadro 1 - Satélites empregados no SR com suas respectivas resoluções espacial, espectral e radiométrica.

Satélite	Resolução espacial (m)	Resolução espectral	Resolução radiométrica
<i>LANDSAT1</i>	30	Visível 450-760nm NIR 760-1200nm	6 bits por pixel
<i>IKONOS</i>	4 Multiespectral e 1 Pancromática	Visível 450-760nm NIR 757-853nm Pancromática 450-900nm (1m de resolução espacial)	11 bits por pixel
<i>QuickBird</i>	2,4	Visível 450-690nm NIR 760-900nm	11 bits por pixel
<i>WorldView1</i>	0,60	Pancromática 450-900nm	11 bits por pixel
<i>GeoEYE-1</i>	0,41	Visível 450-695nm NIR 760-900nm	11 bits por pixel
<i>SPOT1</i>	2,5 Pancromática, 10 NIR e visível e 20 no SWIR	Pancromática 481-710nm Visível 500-590nm e 610-680nm NIR 780-890nm SWIR 1580-1750nm	8 bits por pixel

Fonte: Adaptado de Lillesand, Kiefer e Chipman (2008), Campbell e Wynne (2011) e Ray (2016).

Na agricultura, a plataforma *LANDSAT* é umas das mais utilizadas, sendo aplicada intensivamente na estimativa de produção (SEELAN et al., 2003). Outros satélites também são usados na estimativa da produção agrícola, como o satélite *HJ-1B*, utilizado na pesquisa de Li et al. (2014) para estimar a produção de arroz na China, determinando a superfície total de plantações de arroz em algumas províncias chinesas. O *HJ-1* uma constelação de minissatélites, composta por três satélites, sendo estes pequenos e de baixo custo, assim como os satélites da constelação alemã *RAPIDEYE* que, por tais características, têm sido estudados como alternativa para obtenção de dados na agricultura (ANTUNES; DEBIASI; SIQUEIRA, 2014; TYC et al., 2005).

A constelação *RAPIDEYE* é um projeto comercial do final da década de 1990, lançado em 2008 pela empresa alemã *RAPIDEYE AG*. Esses satélites foram desenvolvidos com o intuito de oferecer algumas soluções comerciais, dentre as quais duas são para a agricultura: (i) Seguro na agricultura, no auxílio de atualização de mapas de danos em lavouras, com atualizações rápidas para acompanhar as evoluções ocorridas no campo, e (ii) Manejo e

agricultura de precisão, com a geração de informações rápidas para acompanhar o desenvolvimento das culturas no campo, com garantia de atualizações rápidas dos dados (TYC et al., 2005).

A constelação *RAPIDEYE* é composta de cinco satélites que orbitam a aproximados 620 km da Terra. Cada veículo espacial tem massa de 150 kg e é equipado com sensores que registram cinco canais de cores, com as bandas espectrais azul (440-510 nm), verde (520-590 nm), vermelho (630-685 nm), limite do vermelho (690-730 nm) e NIR (760-850 nm), a resolução espacial é de 5 m e a radiométrica é de 12 bits por pixel (TYC et al., 2005).

Mesmo sendo satélites relativamente novos, se comparados com o *LANDSAT*, o *RAPIDEYE* já está presente na literatura com foco em pesquisas na agricultura. Eitel et al. (2007) avaliaram a capacidade de dados adquiridos com a constelação *RAPIDEYE* para determinar a concentração de N foliar no trigo de inverno em Oregon, EUA, com o uso de dois IVs combinados [*Modified Chlorophyll Absorption Reflectance Index* (MCARI) e *Modified Triangular Vegetation Index* (MTVI)]. Os pesquisadores obtiveram resultado expressivos e concluíram que os satélites têm grande potencial para o monitoramento de N em lavouras de trigo. Vizzotto et al. (2013) avaliaram o desempenho de técnicas de classificação para identificar áreas agrícolas por meio de imagens geradas com os satélites *RAPIDEYE*. Já Fritsch et al. (2012) validaram modelos de irrigação em regiões áridas do Azerbaijão, com o uso de imagens multitemporais coletadas com a constelação *RAPIDEYE*.

O índice de área foliar e a produção de biomassa da parte aérea de soja e milho foram estimados com dados dos satélites *RAPIDEYE* por Kross et al. (2015), em Ontario, Canadá. Os autores realizaram o cálculo de IVs a partir dos dados de SR e encontraram resultados expressivos de correlação com a produção de biomassa, obtendo coeficientes de determinação (R^2) de até 0,92. Os autores concluíram que os dados dos satélites *RAPIDEYE* podem ser usados como auxílio no manejo das lavouras de soja e milho, por meio do acompanhando do desenvolvimento das plantas.

3.1.2 Sensoriamento remoto terrestre na agricultura

Uma técnica de SR muito empregada em campo e mais recente que o uso de satélites, é o uso de sensores óticos ativos como o *CROP CIRCLE* e *GREENSEEKER* (CAO et al., 2013). A aplicação de tais sensores tornaram-se um ponto chave no manejo de fertilizantes e predição de produção agrícola (ALI et al., 2014).

Duas grandes vantagens desses sensores na aquisição de medidas acuradas de atributos das plantas sem a necessidade de coleta de amostras e por fornecer os resultados em tempo real,

possibilitando a aplicação de insumos a taxa variável (ALI et al., 2015). Na Figura 1 observa-se um exemplo prático da utilização de um sensor ótico na adubação a taxa variável. O sensor está acoplado a uma semeadora-adubadora, realizando constantemente a leitura referente a resposta espectral e enviando as informações a uma central que analisa e faz a correção da aplicação em tempo real.

Figura 1 - Sensor ótico *GREENSEEKER* acoplado a uma semeadora-adubadora.



Fonte: Pioneer¹

O sensor ótico *GREENSEEKER* é produzido pela empresa Trimble em duas versões, ativa e passiva. A primeira trabalha com dois diodos emissores de luz (LED – *Light-Emitting Diode*), emitindo e recebendo a resposta do objeto alvo, e a segunda trabalha registrando as respostas de reflexão da luz solar. A versão ativa trabalha com duas bandas, a vermelha (650-660 nm) e o NIR (770-785nm). O sensor foi projetado para operar a aproximadamente 100 cm do dossel, com velocidade média de 5 km/h (ERDLE; MISTELE; SCHMIDHALTER, 2011).

Uma das aplicações mais comuns do *GREENSEEKER* é a estimativa de biomassa e, por consequência, a determinação das doses para a adubação nitrogenada a taxa variável. Grohs et al. (2009) avaliaram o potencial produtivo das culturas de trigo e cevada utilizando o *GREENSEEKER*, realizando a estimativa da biomassa da parte aérea com os dados obtidos pelo sensor, para posteriormente determinar o potencial produtivo das culturas. De maneira similar, Bredemeier et al., (2013) correlacionaram o potencial produtivo do trigo com os dados coletados com o sensor *GREENSEEKER*, visando determinar padrões para adubação de N a taxa variável. Kapp, Caires e Guimarães, (2014) realizaram uma abordagem computacional

¹ Disponível em <https://www.pioneer.com/home/site/us/agronomy/library/sensors-to-improve-corn-nitrogen/>

sobre os dados obtidos com o sensor terrestre *GREENSEEKER*, estimando a produtividade de biomassa seca, a extração de N pelas plantas e concentração foliar de N. Nesse estudo, foram empregados RNA para criar os modelos preditivos. Os resultados demonstraram alta capacidade do sensor em estimar a produtividade de biomassa da parte aérea e a extração de N pelas plantas.

3.1.3 Sensoriamento remoto aéreo na agricultura

O uso de balões é o método mais antigo de aquisição de dados de SR aéreo. Com o advento das aeronaves no início do século XX, elas passaram a ser mais empregadas. Junto com a entrada dos aviões, surgiram as RPAs pilotadas remotamente via rádio (COLOMINA; MOLINA, 2014). No início, as RPAs eram empregadas apenas para fins militares. Segundo Jorge e Inamasu (2014), somente no final da década de 1990 as RPAs passaram a coletar dados para fins agrícolas. A tecnologia envolvendo as RPAS tem evoluído com sistemas autônomos de decolagem e aterrissagem que facilitar seu uso, tornando-se uma opção aos dados de SR oriundos de satélites.

Segundo Honkavaara et al. (2013), o SR com RPAs tem algumas vantagens sobre os aviões tripulados e satélites, tais como possibilidade de obtenção de dados com alta resolução espacial e temporal, coleta de dados em condições desfavoráveis de clima e baixo custo operacional. Essas vantagens destacam-se quando se trata de RPAs ultraleves. Já, para Gómez-Candón, De Castro e López-Granados (2014), as maiores vantagens das RPAs em comparação com aeronaves tripuladas são o baixo custo de aquisição das imagens e a possibilidade de voo a baixíssimas altitudes, garantindo altas resoluções espaciais, as quais podem chegar a 2 cm por pixel.

Com o avanço da tecnologia, facilitando o uso com o implemento de sistemas autônomos de pilotagem, aliado ao baixo custo operacional, a utilização das RPAs na agricultura tem crescido substancialmente (JORGE; INAMASU, 2014). Segundo Herwitz et al. (2004), o SR com RPAs tem papel chave nas novas demandas da agricultura, auxiliando na tomada de decisões no campo. Nesse contexto, Honkavaara et al. (2013) e Lelong et al. (2008) também afirmam que um dos maiores campos de aplicação de RPAs em áreas agrícolas é voltado para a AP, visando habilitar o uso eficiente dos recursos materiais e naturais na lavoura.

Existe um grande conjunto de aplicações das RPAs na AP. Dentre elas, tem-se a estimativa de biomassa da parte aérea (BENDIG et al., 2015; PÖLÖNEN et al., 2013), determinação de deficiências nutricionais em plantas (PÖLÖNEN et al., 2013; WANG et al., 2013), estimativa da concentração de N nas folhas (AGÜERA; CARVAJAL; PÉREZ, 2012), o

acompanhamento e manejo do desenvolvimento da culturas (VEGA et al., 2015) e a criação de mapas de aplicação de fertilizantes (GÓMEZ-CANDÓN; DE CASTRO; LÓPEZ-GRANADOS, 2014; KAIIVOSOJA et al., 2013). As RPAs utilizadas na agricultura constituem-se basicamente de dois modelos: as RPAs de asa fixa e os multirotores (Figura 2). As RPAs de asa fixa possuem estrutura similar à dos aviões, enquanto as RPAs multirotores, popularmente conhecidas como *DRONES*, apresentam características similares aos helicópteros.

Figura 2 - RPA de asa fixa (à esquerda) e multirotor (à direita).



Fonte: SenseFly² e Dji³

Os modelos de asa fixa têm algumas vantagens sobre os multirotores, como o seu baixo peso, maior autonomia de voo, capacidade de cobrir grandes áreas em curto período de tempo e estabilidade de voo, garantindo imagens de alta qualidade. Para Honkavaara et al. (2013), as RPAs ultraleves têm maior campo de aplicação em sensoriamento local e de risco a baixas altitudes e com necessidades de rápida e constante coleta de dados.

A geração de informações com SR aplicando RPAs não é uma técnica totalmente consolidada. Vários parâmetros ainda devem ser estudados para determinar um protocolo padrão de sua utilização. Alguns desafios estão relacionados aos problemas de georreferenciamento, ou seja, erros associados aos dados do Sistema de Navegação Global por Satélite (GNSS – *Global Navigation Satellite System*) (MESAS-CARRASCOSA et al., 2015) e correções radiométricas da imagem, as quais visam remover ou amenizar ruídos e interferências provocados ao sensor pelo ambiente, alheios ao alvo observado (DU; TEILLET; CIHLAR, 2002). As correções geométricas e radiométricas são essenciais na geração de ortofotos e ortomosaicos de SR aéreo para garantir resultados fieis à região geográfica de interesse.

² Disponível em: <https://www.sensefly.com/drones/ebee.html>

³ Disponível em: <https://www.dji.com/phantom-3-pro>

3.1.3.1 Correção geométrica

O problema de georreferenciamento consiste no erro das coordenadas geográficas adquiridas pelo receptor GNSS embarcado nas RPAs, esse erro pode variar dependendo do equipamento e das condições atmosféricas (DE AGUIAR; CAMARGO, 2006). O método mais comum para a correção desse problema consiste no uso de pontos de controle em solo (GCP – *Ground Control Points*) (DU; TEILLET; CIHLAR, 2002). Esses pontos de controle são objetos fixados em solo de tamanho suficiente para serem visíveis nas imagens. Para a realização da correção geométrica são coletadas as coordenadas geográficas de cada GCP (com um receptor GNSS de maior acurácia). Assim, essas coordenadas são atribuídas aos pontos visíveis nas imagens. Após a atribuição das coordenadas aferidas em campo são realizados cálculos para ajustar cada pixel da imagem à sua posição mais acurada. Essa correção geralmente é realizada em Sistemas de Informações Geográficas (SIGs) (PERIN et al., 2016).

Segundo Mesas-Carrascosa et al. (2015), não existe um número exato de GCPs a serem posicionados em campo, podendo variar de 4 a 130, por exemplo, dependendo das condições do relevo e também da extensão da área imageada. Liba e Berg-Jürgens (2015) avaliaram a interferência do número de GCPs por meio da raiz quadrada do erro médio quadrático (RMSE – *Root-Mean-Square Error*) em mosaicos gerados usando 5 e 10 GCPs (RMSE de 0,789 e 0,732, respectivamente), e verificaram que a utilização de 10 GCPs melhorou a acurácia do georreferenciamento.

3.1.3.2 Correção radiométrica

No SR com RPAs, muitos fatores devem ser considerados e controlados, como horários e condições atmosféricas propícias (KELCEY; LUCIEER, 2012). No entanto, mesmo assumindo que as condições para o imageamento sejam ideais, a tonalidade (resposta espectral) das imagens pode não representar fielmente a realidade da região imageada (LANGHI; GARCIA, 2008). Com isso, o principal objetivo da correção radiométrica é remover ou compensar todos os efeitos alheios ao objeto em observação, exceto os provocados pela resposta do alvo, fornecendo ao final dados que representem com fidelidade a resposta espectral do alvo (DU; TEILLET; CIHLAR, 2002).

Existem fundamentalmente dois níveis de correção radiométrica, absoluta e relativa (DU; TEILLET; CIHLAR, 2002). A correção absoluta, em sua maioria, utiliza dados coletados em solo e dados temporais da atmosfera como parâmetros para a correção. A aquisição de tais

informações é difícil e, na maioria das vezes, necessita de equipamentos específicos de coleta (YANG; LO, 2000).

Um método de correção absoluta é conhecido como linha empírica e consiste no posicionamento de objetos em solo, nos quais são realizadas leituras de refletância, utilizando sensores óticos. Esses valores de refletância são posteriormente atribuídos aos pontos em que o objeto está visível nas imagens e, assim como na correção geométrica, os demais pixels das imagens são normalizados. Esse método foi empregado por Berni et al. (2009) para a correção de imagens multiespectrais capturadas com RPA. Foram posicionadas duas placas em campo e com o espectrômetro manual ASD aferiram-se os valores de refletância e, após, foram corrigidas as imagens pelo método de linha empírica.

Outra técnica de correção radiométrica absoluta largamente utilizada na correção de imagens adquiridas com SR orbital e aéreo é a subtração do pixel escuro (DOS – *Dark-Object Subtraction*). Essa técnica apresenta a vantagem de não demandar dados coletados em campo. A DOS baseia-se no fato de que em toda imagem de SR existe um pixel completamente escuro, observando que sempre haverá uma região em solo que está totalmente na sombra. Com isso, a técnica procura o pixel com os menores valores de radiância e normaliza o restante da imagem com base neste pixel (CHÁVEZ, 1996). Algumas aplicações de processamento de dados de SR já tem nativamente a DOS implementada, como o software *Pix4DMapper* (PIX4D, 2017). Além da DOS, existem outras técnicas de correção radiométrica, sendo algumas focadas para fins específicos ou para corrigir dados de sensores específicos (EL HAJJ et al., 2008; KELCEY; LUCIEER, 2012; POLIDORIO et al., 2005).


Na correção relativa são usados dados estatísticos empíricos para fins de normalização radiométrica e também informações sobre o sensor, como tempo de abertura e distância focal, sem a necessidade de coleta de parâmetros em campo (PIX4D, 2017). Algumas correções relativas, segundo Du, Teillet e Cihlar (2002), normalizam os valores de refletância das imagens baseando-se em arquivos de datas anteriores, sobre os quais já haviam sido aplicadas correções.

3.1.4 Ortomosaico

As imagens obtidas pelo SR aéreo que possuem coordenadas geográficas são conhecidas como ortofotos. Elas podem ser combinadas, cobrindo uma grande área de interesse. O resultado dessa junção é chamada de ortomosaico e o processo pelo qual se gera é conhecido como mosaicagem (AFEK; BRAND, 1998; JENSEN, 2013). Um exemplo de uma ortofoto e um ortomosaico é apresentado na Figura 3. Observa-se uma ortofoto (a) e um

ortomosaico (b) gerado por um conjunto de ortofotos de uma mesma região (a escala das imagens não é a mesma).


Figura 3 - Ortofoto capturada com RPA e ortomosaico gerado por um conjunto de ortofotos.



Fonte: O Autor, imagens de uma lavoura de trigo da safra 2016, na Fazenda Paiquerê, em Pirai do Sul – PR.

No processo de captura das ortofotos para posterior geração de um ortomosaico, algumas propriedades devem ser consideradas, como a região a ser imageada, a resolução espacial, a qual vai determinar a altitude do voo e o número de fotos, e a sobreposição das imagens que também altera o número de imagens a serem capturadas. A resolução espacial já foi discutida na seção 3.1 e a sobreposição das imagens corresponde ao recobrimento entre uma imagem e as vizinhas. A Figura 4 mostra o exemplo de um esquema de voo para a geração de um ortomosaico onde uma mesma região em solo pode ser registrada por mais de uma imagem.


Figura 4 - Esquema de sobreposição de imagens aéreas para geração de um ortomosaico, com sobreposição de 60% horizontal e 30% na vertical, observando o sentido do voo.



Fonte: Adaptado de Jensen (2000).

Após o processo de captura das imagens, estas podem ser utilizadas na geração de ortomosaicos. Os ortomosaicos agrupam as imagens por meio de definição de pontos em comum presentes em imagens distintas, podendo ser executados de maneira visual ou com softwares automatizados, como o *Pix4DMapper* (PIX4D, 2017). O software *Pix4DMapper*, por exemplo, faz a descoberta automática de pontos similares em diferentes imagens, no entanto, também disponibiliza a opção de defini-los manualmente. Na Figura 5 tem-se um exemplo simples da mescla de duas imagens com quatro pontos em comum.

Figura 5 - Diagrama de execução do processo de mosaicagem. (a) o algoritmo encontrou 4 pontos em comum nas duas fotos e (b) a mescla das imagens sobre os pontos em comum.



Fonte: Adaptado de Afek e Brand (1998).

3.2 ÍNDICES DE VEGETAÇÃO

Com o início da obtenção de dados pelas plataformas orbitais, muitos resultados foram alcançados, em especial nos modelos para estimativa de densidade de vegetação. Isso foi possível graças ao uso de dados de refletância do espectro NIR e vermelho. Segundo Rouse et al. (1973), mesmo com avanço das técnicas, os pesquisadores encontraram limitações no uso dos valores puros de resposta espectral. Com isso, para contornar essas limitações, uma alternativa encontrada foi o uso de IVs, os quais podem ser gerados pela divisão simples entre dois ou mais comprimentos de banda (ROUSE et al., 1973).


Segundo Meneses et al. (2012), os IVs destacam as características do objeto alvo, realçando o contraste entre ele e demais objetos na cena. Os IVs vêm sendo utilizados desde a década de 1960 em diversas campos de pesquisa, como na agricultura (CAMPBELL; WYNNE., 2011). Segundo Gnyp et al., (2014), o uso de IVs é imprescindível na criação de

modelos de estimativa de biomassa, contribuindo para o monitoramento da cultura durante seu desenvolvimento na lavoura.

Os IVs mais utilizados na agricultura foram criados usando dados das bandas do visível e do NIR. Na Figura 6 pode ser observado o espectro eletromagnético, com as divisões mais comuns entre as bandas, cada uma com seu potencial de aplicação na agricultura (JENSEN, 2013). Segundo Colwell (1974) e Hatfield, Asrar e Kanemasu (1984), citados por Huete (1988), os IVs gerados a partir de dados do espectro do infravermelho, combinado com bandas do vermelho têm grande potencial para determinar características das plantas, tais como biomassa, níveis de fotossíntese, produção de sementes e cobertura foliar.

Dentre os IVs utilizados em pesquisas agrícolas, o índice de vegetação da diferença normalizada (NDVI - *Normalized Difference Vegetation Index*) é o mais comum para estimativa de biomassa da parte aérea (BENDIG et al., 2015; CARLSON; RIPLEY, 1997; GNYP et al., 2014; HUETE, 1988; MYNENI et al., 1995). O NDVI já é calculado por alguns equipamentos disponíveis para AP, como é o caso do *GREENSEEKER* (ERDLE; MISTELE; SCHMIDHALTER, 2011).

Figura 6 - Espectro eletromagnético.



Fonte: Adaptado de Jensen (2000).

O NDVI foi desenvolvido na década de 1970 por Rouse et al. (1974), com o objetivo de melhorar o contraste dos IVs existentes na época. Na equação (1) é mostrado o cálculo do

NDVI. O resultado pode variar de -1 a 1, sendo que valores próximos a -1 correspondem à água e valores próximos de 1 à vegetação intensa.

$$NDVI = \frac{NIR - Vermelho}{NIR + Vermelho} \quad (1)$$

Uma variação do NDVI é o NDVI-RE (RE – *RedEdge*) ou NDRE, cujo índice consiste no mesmo cálculo apresentado na Equação (1), porém, sem empregar o NIR e sim o limite do vermelho (SCHUSTER; FÖRSTER; KLEINSCHMIT, 2012). Uma das vantagens dessa mudança é evitar a saturação do NIR com a vegetação muito intensa.

Outro IV aplicado na agricultura foi criado por Huete (1988). Esse autor desenvolveu o índice de vegetação com ajuste de solo (SAVI - *Soil-Adjusted Vegetation index*), com o objetivo de minimizar o ruído causado pela refletância do solo. Na equação (2) é mostrado o cálculo do SAVI, onde L é normalmente definido em 0,5.

$$SAVI = (1 + L) * \frac{NIR - Vermelho}{Nir + Vermelho + L} \quad (2)$$

Outros índices foram criados por meio de modificações no SAVI, como é o caso do índice de vegetação com ajuste de solo otimizado (OSAVI – *Optimized Soil-Adjusted Vegetation index*), desenvolvido por Rondeaux (1996). A diferença entre o OSAVI e o SAVI consiste no valor de L , sendo que para o OSAVI foi fixado em 0,16 (GNYP et al., 2014). Existe ainda uma segunda variação do SAVI que realizou profundas mudanças na obtenção do L . Nessa segunda versão, o índice passou a ser chamado de índice de vegetação com ajuste de solo modificado (MSAVI – *Modified Soil-Adjusted Vegetation index*) e foi desenvolvido por Qi et al., (1994). No trabalho, os pesquisadores desenvolveram alguns métodos alternativos para a definição do valor para o parâmetro L , conforme demonstrado na equação (3).

$$MSAVI_2 = 0,5(2 * NIR + 1 - \sqrt{(2 * NIR)^2 - 8 * (NIR - Vermelho)}) \quad (3)$$

Em comum, os IVs apresentados utilizam o conceito descoberto por Rouse et al. (1973) de normalizar a diferença e usar o espectro do NIR até os comprimentos de onda por volta de 850 nm. Com o emprego desses índices na agricultura, foram obtidos bons resultados em modelos de estimativas de variáveis agrônômicas. No Quadro 2 constam alguns trabalhos que utilizaram esses índices em estimativas na agricultura.

Outros estudos visaram o desenvolvimento de novos IVs, utilizando comprimentos de onda diferentes. Gnyp et al. (2014) criaram o GNYLI, um índice com a diferença normalizada, mas ao invés de se empregar o NIR até o comprimento de onda de 850 nm, utilizou-se a faixa

dos 900 nm a 1.220 nm. Em comparação com outros índices já descritos na literatura, o GNYLI apresentou resultados superiores para a estimativa de biomassa da parte aérea das plantas.

Quadro 2 - Trabalhos com aplicação de índices de vegetação (IVs) na agricultura em modelos preditivos.

IV	Objetivo	Fonte
NDVI	Produtividade, biomassa e índice de cobertura foliar de trigo.	Serrano e Filella, Penuelas (2000)
NDVI	Biomassa e nitrogênio no trigo	Pölönen et al. (2013)
NDVI, SAVI, OSAVI e MSAVI	Biomassa de trigo	Gnyp et al. (2014)
NDVI, SAVI, OSAVI e MSAVI	Biomassa de cevada	Bendig et al. (2015)
NDVI	Potencial produtivo de trigo	Grohs et al. (2009)
NDVI-RE	Biomassa de milho e soja	Kross et al. (2015)
SAVI	Estresse hídrico de plantas	Moran et al. (1994)

Bendig et al. (2015) também avaliaram o GNYLI com dados obtidos por meio de RPA para estimar a produtividade de biomassa da cevada. Assim como no trabalho de Gnyp et al. (2014), os autores obtiveram melhores resultados com o GNYLI, em comparação com os IVs mais comuns descritos na literatura. Um fato relevante nesse estudo é que os dados usados pelo GNYLI foram obtidos por espectrômetros manuais (*ASD FieldSpec3* e *QualitySpec Pro*), o que dificulta o acompanhamento de extensas áreas agrícolas.

3.3 MINERAÇÃO DE DADOS

A MD, segundo Tan, Steinbach e Kumar (2006), é o processo de descoberta de informações sobre os dados, as quais variam de padrões de comportamento a modelos de estimativa e que podem prever um dado futuro baseado no conhecimento atual. A descoberta é executada em dados armazenados, os quais podem ser originados a partir de respostas de questionários até dados obtidos por meio de sensores acoplados em satélites (WITTEN; FRANK, 2005).

A MD é uma parte integral da descoberta de conhecimento em bancos de dados (KDD – *Knowledge Discovery in Databases*), sendo um processo complexo de identificação de novos padrões válidos, úteis e compreensíveis. Esse processo é dividido em três etapas (Figura 7): (i) Pré-Processamento, o qual consiste em transformar os dados brutos de entrada em um formato apropriado para o algoritmo de mineração; (ii) Mineração de Dados, sendo que nessa etapa a base é analisada pelos algoritmos de mineração, e (iii) Pós-processamento, a qual assegura que apenas resultados válidos sejam usados no objetivo, como em sistemas de apoio a decisão (TAN; STEINBACH; KUMAR, 2006).

Figura 7 - Etapas da descoberta do conhecimento.



Fonte: Adaptado de Tan, Steinbach e Kumar (2006).


Na etapa de mineração de dados são executadas tarefas específicas de acordo com o objetivo e tipo de dados estudados. As principais tarefas são: regressão, classificação, agregação e associação (TAN; STEINBACH; KUMAR, 2006). Considerando que o objetivo do presente trabalho envolve a estimativa de biomassa da parte aérea de plantas, a tarefa de interesse é a regressão, a qual visa a estimativa de valores contínuos.

3.3.1 Modelos de regressão

A regressão é uma técnica de modelagem que gera um modelo preditivo, sendo a variável alvo contínua. Tem uma ampla aplicabilidade, dentre elas a agricultura (MUCHERINO; PAPAJOJGI; PARDALOS, 2009; TAN; STEINBACH; KUMAR, 2006; WITTEN; FRANK, 2005) .

A regressão consiste em verificar se existe uma relação de dependência entre uma ou mais variáveis contínuas. Esses relacionamentos são representados por modelos matemáticos que associam uma variável dependente com outra (regressão simples) ou outras (regressão múltipla) independentes. A função de dependência é chamada de *função de regressão*. Quando essa função, o modelo de regressão é linear, caso contrário é chamado de não-linear. Na Figura 8 é possível observar as diferenças dos dois modelos (AFIFI; AZEN, 1972).

Figura 8 – Exemplos de gráficos da regressão linear (a) e não linear (b).



Fonte: SPSS Statistics⁴

Nos trabalhos correlatos que empregam dados de SR para estimativa de variáveis agrícolas, as técnicas de regressão mais aplicadas são a linear simples (RLS), multivariada, não linear e mínimos quadrados parciais (PLS – *Partial Least Square*). No Quadro 3 são apresentados alguns trabalhos relacionados com o desempenho de culturas de grãos, com as respectivas técnicas de regressão utilizadas.

Quadro 3 - Trabalhos na agricultura envolvendo o desempenho de culturas de grãos, com as técnicas de regressão empregadas.

Fonte	Objetivo	Técnica
Serrano e Filella, Penuelas (2000)	Produtividade, biomassa e índice de cobertura foliar do trigo.	RLS
Gnyp et al. (2014)	Biomassa do trigo	RLS
Li et al. (2017)	Biomassa do trigo	PLS
Tilly et al. (2014)	Altura e biomassa do trigo	RLS
Bendig et al. (2015)	Biomassa e altura da cevada	RLS
Grohs et al. (2009)	Potencial produtivo do trigo	Multivariada e não-linear
Kross et al. (2015)	Biomassa do milho e soja	RLS e não-linear

⁴ Disponível em: <https://statistics.laerd.com/spss-tutorials>

Além dos métodos tradicionais de análise de regressão, como os citados no Quadro 3, outras técnicas de regressão, provenientes da MD, podem ser aplicadas. Como exemplo, tem-se o trabalho de Pölönen et al. (2013) em que a MD foi empregada com a aplicação do algoritmo do vizinho mais próximo (KNN – *K nearest neighbour*) para estimar a produção de biomassa da parte aérea e a concentração de N nas plantas.

A aplicação de algoritmos para regressão e técnicas de MD podem apresentar vantagens sobre os modelos tradicionais da estatística em problemas complexos. Kiala et al. (2016) compararam o método estatístico PLS com a técnica utilizada em MD denominada máquina de vetores de suporte para regressão (SVR - *Support Vector Regression*) na criação de modelos de estimativa do índice de área foliar com dados espectrais de SR. Nesse estudo, a SVR mostrou maior acurácia, com coeficiente de determinação (R^2) de 0,902 contra 0,886 da PLS.


3.3.2 Máquinas de vetores de suporte para regressão

A SVR é um método de regressão criado a partir de máquinas de vetores de suporte (SVM – *Support Vector Machines*) cujo desenvolvimento foi realizado por Vapnik (2006). A SVM é uma técnica de aprendizado de máquina (AM) com fundamentos na teoria de aprendizagem estatística, tendo como principais vantagens a capacidade de lidar com dados lineares e não lineares, bem como de alta dimensionalidade (TAN; STEINBACH; KUMAR, 2006).

A SVM foi criada inicialmente para problemas de classificação, principalmente quando envolve reconhecimento de padrões em imagens. No SR, é amplamente utilizada com esse intuito em muitas áreas, tais como na agricultura (MOUNTRAKIS; IM; OGOLE, 2011).

A SVM opera baseada no conceito de hiperplano e margem máxima. Na Figura 9 pode-se observar um exemplo simples de divisão linear binária. Os algoritmos da SVM tentam encontrar a linha que melhor separe os grupos deixando uma margem máxima entre os vetores de suporte (TAN; STEINBACH; KUMAR, 2006). Com o limite entre as classes encontrado, os dados são transformados de forma que o limite possa ser desenhado em um hiperplano. Com isso, as características dos dados transformados podem ser utilizadas para prever a classe de um novo registro.

Figura 9 - Modelo de divisão linear binária em uma SVM



Fonte: Adaptado de Mountrakis, Im e Ogole (2011).

As funções usadas nas transformações dos dados são chamadas de *Kernel*. Existem vários tipos de *kernel* e os mais comuns são o linear, polynomial, função de base radial (RBF – *Radial Basis Function*) Gaussiano, Sigmoid, assim como variação dentro de um mesmo modelo, como o Laplace RBF e Anova RBF (WU; TZENG; LIN, 2009).

Há bibliotecas que implementam e disponibilizam gratuitamente os *kernels*, como a *libSVM*, que contempla tarefas de classificação e regressão. A biblioteca *libSVM* foi desenvolvida por Chang e Lin (2011). Ela pode ser utilizada no desenvolvimento de códigos e também adaptada para outros softwares estatísticos, como o R por meio do pacote *e1071*, desenvolvido por Dimitriadou et al. (2009).

Os *kernels* RBF demonstraram superioridade em aplicações reais quando comparados com outros algoritmos (SCHÖLKOPF et al., 1997). O *Kernel* RBF Gaussiano, segundo Huang e Lin (2016), é o mais comumente usado em tarefas de classificação, tendo demonstrado resultados superiores. Para a regressão, segundo Guo et al. (2012), os *Kernels* RBF têm grande capacidade de aprendizado, reduzindo a complexidade computacional no processo de treinamento, com melhoria na performance da generalização.

A utilização de SVMs para resolução de problemas de regressão foi proposto por Vapnik (1995). Essa técnica, segundo Basak, Pal e Patranabis (2007), implementa o princípio da minimização estrutural de risco. Com isso, a SVR obtém bons resultados na generalização mesmo com um limitado número de padrões disponíveis.

Além do trabalho de Kiala et al. (2016), outros estudos compararam a SVM com outras técnicas, como o de Souza et al. (2014) que comparou as técnicas de SVM, SVR e análise

de componentes principais (ACP) para detecção e diagnóstico de falhas. Os autores concluíram que as técnicas SVM e SVR, mesmo com número limitado de informações, tiveram maior capacidade de predição das falhas do que a ACP. Em outro estudo, Balabin e Lomakina (2011) compararam RNAs, PLSR e SVR para a estimativa de atributos químicos por meio de dados obtidos com espectrômetro. Os autores concluíram que as técnicas de SVR e SVM apresentaram acurácia compatível com as RNAs e que a SVR demonstrou robustez, resultando em maior precisão na estimativa.

Embora as técnicas baseadas em vetores de suporte (SVM e SVR) possuam vantagens, as mesmas também apresentam alta demanda de processamento em bases com elevado número de instâncias. Isso ocorre devido ao seu consumo de tempo de processamento e de memória ser dado pela função l^2 , onde l é o número de instâncias para treinamento (COLLOBERT; WILLIAMSON, 2001).

4 MATERIAL E MÉTODOS

4.1 DELINEAMENTO EXPERIMENTAL

O experimento foi realizado na Fazenda Paiquerê, no município de Pirai do Sul, região Centro-Sul do Paraná ($50^{\circ} 7' 51.70''$ S $24^{\circ} 21' 23.485''$ W, altitude média de 970 m). O clima da região é subtropical úmido, com temperatura média anual nos meses mais frios de 18°C e nos meses mais quentes de 22°C , e precipitação pluvial média anual acima de 1300 mm^5 . O experimento foi instalado em uma área de aproximadamente 7,2 ha, em um Latossolo Vermelho-Amarelo textura argilosa sob plantio direto. A área experimental foi dividida em quatro parcelas (faixas), conforme mostra a Figura 10.

Figura 10 - Demarcação das parcelas na área experimental. Fazenda Paiquerê – Pirai do Sul – PR.



Fonte: O Autor, adaptado do mapa de refletância do voo realizado no mês de outubro.

4.2 TRATAMENTOS E CULTURA

As quatro parcelas (faixas) receberam quatro tratamentos distintos de aplicação de N (Quadro 4). Na semeadura, foram aplicados 200 kg ha^{-1} da formulação 18-36-00 ($\text{N} - \text{P}_2\text{O}_5 - \text{K}_2\text{O}$) em todas as parcelas. Antes da semeadura (pré-semeadura), aplicaram-se 50 kg N ha^{-1} (tratamento 2) e 100 kg N ha^{-1} (tratamento 3), na forma de ureia. Em cobertura, foram aplicados 27 kg N ha^{-1} aos 40 dias após a semeadura (DAS) mais 45 kg N ha^{-1} aos 50 DAS, na forma de ureia, somente no tratamento 4. Também foram aplicados 100 kg ha^{-1} de K_2O , na forma de KCl, em cobertura, em todas as parcelas. Os tratamentos com aplicação de N foram adequados visando obter diferenças no crescimento das plantas, desde o início de seu desenvolvimento.


⁵ Embrapa Boletim de Pesquisa e Desenvolvimento. Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/338503/1/ParanaPirai.pdf>

Quadro 4 - Tratamentos utilizados no estudo, com as doses e as épocas de aplicação de nitrogênio

Tratamento	Dose de N e época de aplicação (DAS – Dias após semeadura)
01	36 kg N ha ⁻¹ na semeadura
02	36 kg N ha ⁻¹ na semeadura + 50 kg N ha ⁻¹ em pré-semeadura
03	36 kg N ha ⁻¹ na semeadura + 100 kg N ha ⁻¹ em pré-semeadura
04	36 kg N ha ⁻¹ na semeadura + 27 kg N ha ⁻¹ 40 DAS + 45 kg ha ⁻¹ 50 DAS

O trigo, cultivar *TBIO SINUELO*, foi semeado em 28 de junho de 2016, após a colheita da cultura da soja, com espaçamento entre as linhas de 0,17 m e densidade de 70 sementes por metro. O cultivar de trigo utilizado é de ciclo médio-tardio (130-140 dias). As condições climáticas foram favoráveis ao desenvolvimento da cultura do trigo no campo. A precipitação pluvial ocorrida durante os meses de junho a novembro foi de 685 mm, a qual esteve um pouco acima da precipitação pluvial histórica (30 anos) da região de Pirai do Sul para o mesmo período (618 mm) (Figura 11). Destaca-se que durante o mês de agosto de 2016 a precipitação pluvial foi maior do que o dobro da média histórica da região, enquanto que o contrário ocorreu no mês de setembro de 2016, conforme apresentado na Figura 11.

Figura 11 - Precipitação pluvial média mensal ocorrida na área experimental durante o período de desenvolvimento da cultura do trigo, em 2016, e precipitação média mensal histórica (30 anos) do município de Pirai do Sul – PR.



Fonte: O autor e Jornal do Tempo⁶.

⁶ Informações disponíveis em: <http://jornaldotempo.uol.com.br/climatologia.html/PiraidoSul-PR/>

Os dias de coleta de dados em campo o clima foi de sol, com nuvens no período da tarde, vale destacar que durante os voos da RPA, sempre realizados próximos as 12 horas (meio dia) os raios solares eram predominantes, não havendo interferências aparente de nuvens.

4.3 COLETA DE DADOS DE SENSORIAMENTO REMOTO

A coleta de dados foi realizada utilizando as três diferentes plataformas de SR: sensoriamento orbital com microssatélites, sensoriamento aéreo com aeronave remotamente pilotada e sensoriamento terrestre com sensor ótico ativo.

4.3.1 Sensoriamento Orbital

Os dados de sensoriamento remoto orbital foram adquiridos da constelação *RAPIDEYE*, fornecidos pela empresa de agricultura de precisão GeoAgro⁷ (Rosario, Argentina). Os satélites *RAPIDEYE* aplicados no sensoriamento da área realizaram varreduras com resolução espacial de 5 m, em cinco bandas espectrais, sendo elas: azul (440-510 nm), verde (520-590 nm), vermelho (630-685 nm), limite do vermelho (690-730 nm) e infravermelho próximo (760-850 nm). Os imageamentos ocorreram em um ângulo de 65° do *NADIR*, dentro da visada vertical do satélite, para a área em questão.

Mesmo com o satélite capturando a resposta espectral em 5 bandas do espectro eletromagnético, a empresa não tem acesso aos valores de refletância das bandas. Assim, os dados fornecidos pela mesma foram os índices de vegetação NDVI e NDVI-RE, gerados para cada imageamento.

A área de estudo foi sobrevoada em quatro datas distintas, entre os meses de julho e outubro de 2016, correspondendo a diferentes estádios fenológicos da cultura do trigo, conforme apresentado no Quadro 5.

Quadro 5 - Datas de imageamento com os satélites *RAPIDEYE* nos diferentes estádios fenológicos do trigo.


Data	Estádio fenológico da cultura
25/07/2016	Plântula
01/09/2016	Perfilhamento
24/09/2016	Emborrachamento
10/10/2016	Florescimento

Os dados fornecidos pela empresa são apresentados no formato ESRI SHAPEFILE (.shp), contendo informações geográficas e dados dos IVs gerados pelos satélites. Ao todo, a empresa forneceu oito arquivos com os IVs, dois para cada data de sensoriamento, um com o

⁷ Informações disponível em <http://site.geoagro.com/es/producto/soluci%C3%B3n-sat-hd>

NDVI e outro com o NDVI-RE. Na Figura 12 pode-se observar a imagem de um dos arquivos, correspondente ao NDVI obtido em 10/10/2016, acessado por meio do software QGIS.

Figura 12 - Arquivo SHAPEFILE do NDVI gerado por satélite visualizado no software QGIS.



Fonte: O autor.

4.3.2 Sensoriamento Aéreo com RPA

A RPA utilizada no imageamento aéreo foi o modelo *EBEE*, fabricado pela empresa suíça SenseFly (Parrot Company). A RPA *EBEE* é uma aeronave de asa fixa com propulsão de motor elétrico, autonomia média de voo de 40 minutos e teto de voo máximo de 1000 m de altura⁸ (Figura 13).

Figura 13 - RPA modelo *EBEE* usada no imageamento aéreo.



Fonte: SenseFly⁸.

⁸ Informações disponíveis em: <https://www.sensefly.com/drones/ebec.html>

A aeronave possibilita o acompanhamento da área de interesse de forma automatizada, pela tecnologia embarcada no equipamento, fazendo o uso dos sensores e receptores de altitude, altura, velocidade do vento, sistema inercial e receptor GPS acoplados na aeronave.

A RPA *EBEE* suporta diversos tipos de sensores no imageamento⁷. No presente trabalho foram usados dois modelos de câmeras digitais, a Sony WX RGB (Figura 14a) de 18,2 megapixel de resolução e a Canon S110 NIR (Figura 14b) de 12 megapixel de resolução.

Figura 14 - Câmeras usados no imageamento, (a) Sony EX RGB e (b) Canon S110 NIR.



Fonte: SenseFly⁸.

O modelo Sony WX RGB captura imagens no espectro visível, enquanto a Canon S110 NIR captura no infravermelho próximo. No

Quadro 6 são apresentados os valores da resolução espectral correspondente para cada câmera utilizada no estudo.

Quadro 6 - Resolução espectral das câmeras usadas no imageamento aéreo com a RPA *EBEE*.

Câmera	Vermelho	Verde	Azul	NIR
Canon S110 NIR	625 nm	550 nm	-	850 nm
Sony WX RGB	625 nm	550 nm	450 nm	-

Fonte: SenseFly⁸.

Para realizar o imageamento aéreo com a RPA *EBEE* foi utilizado o software *eMotion* 2, versão 2.4.13, fornecido pelo fabricante do equipamento. Neste software se define a região a ser imageada, sobreposição de fotos, resolução espacial desejada e região de pouso da aeronave. Com isso, o software cria o plano de voo, gerando informações como o tempo de voo, altitude e as coordenadas para tomada das imagens. O software *eMotion* permite também o acompanhamento do voo, sendo possível realizar alterações no plano de voo e executar ações de segurança em tempo real.

Foram realizados, no total, 16 voos com a RPA na área experimental, entre os meses de julho e outubro de 2016, conforme Quadro 7. A sobreposição das imagens foi de 60% lateral e 75% longitudinal.

Quadro 7 - Data de realização dos voos, câmeras empregadas, resolução espacial, número de fotos obtidas durante o voo, altura de captura das imagens e estágio fenológico da cultura do trigo durante o sensoriamento.

Data	Resolução espacial	Câmera	Número de fotos	Altura de captura das imagens	Estádio fenológico
28/07/2016	3,4 cm	NIR	192	97m	Plântula
	3,4 cm	RGB	154	120m	
28/08/2016	3,4 cm	NIR	158	97m	Perfilhamento
	3,4 cm	RGB	126	120m	
27/09/2016	3,4 cm	NIR	158	97m	Emborrachamento
	3,4 cm	RGB	126	120m	
10/10/2016	3,4 cm	NIR	146	97m	Florescimento
	3,4 cm	RGB	120	120m	

4.3.3 Sensoriamento Terrestre com Sensor Ótico

O sensoriamento terrestre foi feito com o sensor ótico de mão, denominado *GREENSEEKER*, produzido pela empresa Trimble (NTech Industries Incorporation, EUA). A versão empregada foi a ativa, que utiliza diodos emissores de luz (LEDs), emitindo e lendo a resposta espectral das plantas. Esse equipamento realiza leituras com dois LEDs, um no espectro visível do vermelho (650 nm) e outro no espectro do infravermelho próximo (770 nm) (ERDLE; MISTELE; SCHMIDHALTER, 2011). Os dados capturados são armazenados e processados em um computador de mão acoplado ao equipamento.

Os principais componentes do equipamento são o sensor (Figura 15 a) e o computador de mão (Figura 15 b) usado para controlar e receber os dados do sensor.

Figura 15 - Sensor *GREENSEEKER*



Fonte: Trimble⁹.

⁹ Informações disponíveis em <https://agriculture.trimble.com/precision-ag/products/greenseeker/>

O computador utilizado em conjunto com o sensor já realiza o cálculo do NDVI das leituras, fornecendo um arquivo de texto no formato CSV (campos separados por vírgula), e cada linha do arquivo contém informações geográficas de latitude, longitude, altitude, hora do GPS e a refletância das bandas.

As coletas de dados com o *GREENSEEKER* foram realizadas nos mesmos dias em que foram realizados os voos com a RPA (Quadro 7). Na coleta, o sensor foi posicionado a uma distância de aproximadamente 100 cm acima do dossel das plantas e a leitura foi executada a uma velocidade aproximada de 5 km h⁻¹. No mês de julho de 2016, a leitura foi realizada baseada na parcela, sem o uso do receptor GNSS interno do equipamento, devido a problemas técnicos. Nas demais leituras, o receptor GNSS GPS foi habilitado, adicionando na leitura as coordenadas geográficas de cada ponto. No mês de julho de 2016, houve problema na geração dos arquivos, invalidando os dados gerados nessa coleta, não sendo utilizado nos processos posteriores.

4.4 AMOSTRAGEM E PROCESSAMENTO DAS PLANTAS

4.4.1 Coletas em campo

A amostragem de plantas foi realizada visando distribuir as amostras uniformemente dentro de cada parcela, garantindo assim a coleta da variabilidade dentro de cada tratamento. Elas foram efetuadas nas mesmas datas dos voos da RPA (Quadro 7), cobrindo quatro estádios distintos de desenvolvimento das plantas. A coleta das amostras consistiu no corte de 3 m contínuos de plantas por amostra rente ao solo, retirando-se somente a parte aérea. Foram coletadas 10 amostras por tratamento em cada uma das datas, com exceção do mês de agosto de 2016 em que foram retiradas somente cinco amostras por tratamento devido a problemas técnicos de campo. No dia 10 de outubro de 2016, por ocasião do florescimento das plantas, além das amostras da parte aérea das plantas, foram coletadas 30 folhas-bandeira em volta de cada ponto de amostra, para posterior análise de concentração de N. Todas as amostras foram georreferenciadas com o receptor de GNSS ProXT da Trimble (NTech Industries Incorporation, EUA). Em cada uma das coletas de amostras foi evitado coletar plantas nos mesmos locais das datas anteriores.

4.4.2 Massa e altura das plantas

As plantas coletadas no campo foram levadas ao laboratório onde foram selecionadas, ao acaso, 10 plantas de cada amostra para medir a altura em mm. Em cada planta selecionada,

com o uso de um trena, a altura foi medida da base da planta até o maior comprimento das folhas. Para avaliar a biomassa seca da parte aérea, as amostras foram colocadas para secar em estufa com circulação forçada de ar a 60°C até atingir a massa constante e, em seguida, determinou-se a massa, em gramas, com auxílio de uma balança digital.

4.4.3 Teor de nitrogênio foliar

Para determinar o teor N foliar, as amostras de folha-bandeira foram lavadas com água deionizada, colocadas para secar em estufa com circulação de ar forçada a 60 °C até obter massa constante, e moídas. Os teores de N foram analisados por meio de digestão sulfúrica e determinação pelo método Kjeldahl (MALAVOLTA et al., 1997).


4.5 PÓS-PROCESSAMENTO DOS DADOS OBTIDOS COM A RPA

Logo após a realização dos voos, as imagens geradas foram georreferenciadas no software *eMotion*, utilizando arquivo de LOG gerado durante o imageamento. Conectando o *EBEE* ao computador, o software processa as imagens geradas pelas câmeras, adicionando informações de coordenadas do receptor de GNSS presente na RPA. As imagens da câmera RGB são geradas no formato JPEG (*Joint Photographic Experts Group*), o qual possui 8 bits por canal de cor. Na câmera NIR, o *eMotion* converte o formato CR2 (*Canon Raw Version 2*) para TIFF, o qual contém mais dados por canal de cor (16 bits). Esse formato também é o utilizado para a geração de ortomosaicos (PIX4D, 2017). Os valores digitais que cada pixel pode conter variam de 0 a 65536 para o formato TIFF e de 0 a 255 para o formato JPEG.

Após as imagens terem sido processadas no software *eMotion*, elas foram exportadas para o software *Pix4Dmapper* (PIX4D SA, EPFL Innovation Park, Prédio F, 1015, Lausane, Suíça), responsável por gerar os ortomosaicos e os mapas de refletância.

Para gerar as informações necessárias para criar os ortomosaicos e os mapas de refletância, o software PIX4D cria nuvens de pontos 3D, calculando a orientação das imagens automaticamente através de triangulação aérea (AAT – *Automatic Aerial Triangulation*) e ajuste feito em blocos (BBA – *Bundle Block Adjustment*). A Figura 16 mostra uma nuvem de pontos em comum nas imagens, encontrados pelo software *Pix4Dmapper*. Como exemplo, foi selecionado um ponto e por consequência mostrou as imagens o qual o software *Pix4Dmapper* havia identificado o ponto em comum, essas imagens serão mescladas durante o processo de mosaicagem (PIX4D, 2017) conforme foi destacado na seção 3.1.4.

Figura 16 - Nuvem de pontos com um ponto selecionado



Fonte: O Autor (Gerado pelo *Pix4Dmapper*)

Maiores detalhamentos a respeito dos cálculos e sobreposição das imagens baseadas nos pontos em comum podem ser vistos no trabalho de Afek e Brand (1998). Nesse trabalho é explicado, etapa por etapa, o funcionamento de um algoritmo de ortorretificação de imagens aéreas, bem similar ao processo executado dentro do *Pix4Dmapper*.

Durante o processo de mosaicagem, o *Pix4Dmapper* realiza a correção radiométrica relativa, a qual considera valores do sensor obtidos durante o voo como tempo de abertura e sensibilidade, e a absoluta, aplicando a DOS (PIX4D, 2017) nas imagens.

Além da correção radiométrica, existe a correção geométrica que objetiva maior precisão no processo de mosaicagem (GÓMEZ-CANDÓN; DE CASTRO; LÓPEZ-GRANADOS, 2014). A correção sobre o ortomosaico já concluído foi realizada por meio do uso do software QGIS.

Na correção geométrica é necessário o uso de pontos de controle em solo (GCP - *Ground Control Points*). Considerando a resolução espacial, foram confeccionadas placas de 60×60 cm de diâmetro, na cor branca, com um “X” na cor preta desenhado nelas. Essas placas foram posicionadas ao longo do delineamento experimental, totalizando 11 pontos. Esse número foi definido considerando as recomendações de PIX4D (2017), o qual afirma que o número mínimo de GCPs é 5, e que 5 a 10 pontos normalmente são suficientes para a correção geométrica. Na Figura 17 são mostradas as posições de cada placa na área experimental.

Figura 17 - Posições dos GCPs dentro da área experimental.




Fonte: O autor.

Para a obtenção das coordenadas de cada GCP foi utilizado um receptor GNSS geodésico, o GPS Trimble R4 (NTech Industries Incorporation, EUA). As coordenadas foram adquiridas em campo e pós processadas com base nas estações da Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS. As estações utilizadas foram as da UFPR - Curitiba-PR e de Maringá-PR.

O processo de correção geométrica dentro do software QGIS é relativamente simples. Com o ortomosaico aberto, se localiza os GCPs e atribui a coordenada obtida em campo para cada um deles. O método de transformação utilizado foi o polinomial e de reamostragem foi vizinho mais próximo, após esse processo, gera-se uma nova projeção do ortomosaico. Na Figura 18a tem-se uma região ampliada do ortomosaico com um GCP não corrigido, sendo que o ponto verde deslocado corresponde ao valor do GCP obtido em campo; na Figura 18b tem-se a mesma região ampliada com a correção geométrica.

Figura 18 - (a) GCP sem correção e (b) GCP com correção.




Fonte: O autor.

Após a execução de todos os processos, foram obtidos os ortomosaicos da área experimental, assim como os mapas de refletância, todos em formato TIFF. Os ortomosaicos e os mapas de refletância contém 3 canais de cores.

O software *Pix4Dmapper* realiza balanceamento das cores no ortomosaico, ajustando os valores digitais dos pixels para que, ao final, as cores aparentem ter maior combinação no

resultado final (PIX4D, 2017). No presente estudo, não foram utilizados os ortomosaicos para a extração dos valores de resposta da cultura, e sim os mapas de refletância que, basicamente, consistem em ortomosaicos sem as correções de cor, mantendo o valor fiel de resposta espectral capturada nos voos. A diferença entre o ortomosaico e o mapa de refletância é visível, conforme pode ser observado na Figura 19 pela comparação do ortomosaico com a correção de cores aplicada pelo *Pix4Dmapper* (Figura 19a) e do mapa de refletância no qual não existe correção de cor (Figura 19b).

Figura 19 - a) Ortomosaico com a correção das cores, b) Mapa de refletância sem correção das cores.




Fonte: O autor.

4.6 EXTRAÇÃO DE DADOS DE REFLETÂNCIA GERADOS COM A RPA

4.6.1 Extração dos dados baseada nas amostras

A primeira extração dos dados de refletância foi realizada considerando a posição das coletas de amostras no campo. Na Figura 20 são apresentados os pontos correspondentes a duas leituras realizadas nos meses de agosto (pontos azuis) e de setembro (pontos amarelos) de 2016. Nota-se que evitou-se fazer a coleta no mesmo local entre as amostragens e que procurou-se fazer a coleta com distribuição uniforme dentro de cada tratamento, assegurando a presença da variabilidade de cada parcela para as amostras coletadas.

Figura 20 - Pontos de amostras em campo correspondentes aos meses de agosto (círculos azuis) e de setembro (círculos amarelos) de 2016, dentro da área experimental.




Fonte: O autor.

Os pontos coletados em campo foram importados para o software QGIS, em torno dos quais foram extraídos dados de refletância espectral. Os processos de coleta dos dados de refletância foram executados separadamente para cada data de leitura no campo.

Para definir o tamanho ideal do polígono para a captura dos dados em cada ponto, foi realizado um teste envolvendo polígonos (quadrados) com quatro medidas diferentes de lado: 5, 10, 15 e 20 m. Um exemplo de como foram criados os polígonos é mostrado na Figura 21. O ortomosaico empregado no teste foi com resolução espacial de 20 cm nos canais de cor RGB. Assim, foram extraídos os valores de todos os pixels que se encontravam dentro do polígono, para cada tamanho. O teste revelou que o polígono de 5 m foi o que ocasionou o menor erro e, por isso, esse foi o tamanho do polígono escolhido para a extração dos dados em cada ponto.

Figura 21 - Pontos com polígonos para a extração dos dados de refletância.




Fonte: O autor.

Após a definição do tamanho do polígono, foram gerados pontos regulares dentro de cada polígono para a extração dos valores de refletância. Para descobrir a quantidade ideal de pontos visando a obtenção de melhores resultados, um outro teste foi realizado com várias bases de diferentes densidades de pontos a partir de um mesmo mapa de refletância. No total, foram geradas seis bases de dados, coletando-se 1, 5, 10, 20, 50 e 100% do total de pixels dentro dos polígonos. O algoritmo de aprendizado de máquina aplicado foi a SVR, com o *kernel* RBF. Na Figura 22 é mostrado um exemplo de duas densidades de pontos dentro de um mesmo polígono: (a) com densidade de 100% e (b) com densidade de 50%, sobre o ortomosaico com resolução

espacial de 20 cm nos canais de cores RGB. Esse teste revelou que 20% do total de pixels foi o resultado mais satisfatório para a realização do estudo, considerando o tempo de execução do algoritmo. Destaca-se que, nos testes, só foi utilizado um ortomosaico com resolução espacial de 20 cm devido ao tempo de processamento da SVR.

Figura 22 - Polígono com pontos para extração dos valores de refletância com duas densidades: (a) 100% dos pixels e (b) 50% dos pixels.



Fonte: O autor.

Para extrair os valores dos canais de cores foi utilizado o plugin *pointing sample tool* presente na biblioteca do QGIS. Um exemplo de como a base é gerada pelo plugin pode ser observado no Quadro 8. A primeira coluna (Amostra) representa o identificador de qual tratamento e amostra a linha corresponde; N corresponde ao tratamento e A indica a amostra. As colunas com as finais NIR, R, G ou B indicam qual é o canal de cor para aquela coluna. As câmeras usadas no presente estudo sempre geram três canais, R, G e B para a câmera Sony WX RGB, e R, G e NIR para a Canon S110 NIR.

Quadro 8 - Fragmento de base de dados gerada da extração dos valores de refletância para os canais R, G e NIR, utilizando a câmera NIR com resolução espacial de 3,4 cm.


Amostra	Canal R	Canal G	Canal NIR
N1A9	17875.53711	20474.84961	53746.57813
N1A9	17685.99805	20499.8457	51752.18359
N1A9	18785.45313	21248.60352	51318.16406
N1A9	20057.04688	23131.25586	54469.17578
N1A9	17763.86523	20663.36914	56112.39453
N1A9	20891.41016	24448.24414	55571.50391
N1A9	19621.17383	22852.13672	54824.38281

Baseado no identificador da amostra, foram adicionados ao final das linhas os valores coletados em campo de biomassa seca da parte aérea, altura da planta e concentração de N. Esse processo foi repetido para todas as leituras no campo, gerando uma base de dados para cada época de avaliação. No total, foram geradas quatro bases (paiquere_julho, paiquere_agosto, paiquere_setembro, paiquere_outubro), com 171.962 instâncias e 10 atributos cada, sendo seis atributos de valores de refletância: Canal R, G e B (câmera RGB) e Canal R, G e NIR (câmera NIR), três atributos de desempenho das plantas: biomassa da parte aérea, altura da planta e concentração foliar de N; e um atributo referente ao identificador de amostra.

4.6.2 Extração dos dados considerando os tratamentos

Primeiramente foram calculados os valores médios de biomassa seca da parte aérea, altura da planta e concentração foliar de N nas amostras coletadas em cada tratamento de adubação nitrogenada. Em seguida, foram criados quatro polígonos, evitando as bordas dos tratamentos, sendo dois com as dimensões de 15 m $\times$ 763 m, um com 15 m $\times$ 743 m e um último com 15 m $\times$ 665 m. Na Figura 23 é mostrado o resultado final dos polígonos, sendo as linhas vermelhas correspondentes à divisão das parcelas (faixas) com os devidos tratamentos, e os retângulos amarelos, os polígonos criados.


Figura 23 - Polígonos para extração de dados de refletância baseados na divisão das parcelas.



Fonte: O autor.

Na geração dos pontos para a extração dos valores de refletância em cada tratamento foi aplicada uma técnica diferente da utilizada na seção 4.6.1. Aqui não foi validada a quantidade de pontos. Ao invés disso, foram pegos os pontos regulares gerados pelos dados de satélite para que as bases de satélite e da RPA tivessem o mesmo número de instâncias. Com isso, foram geradas bases com 1858 instâncias. Na Figura 24 é possível observar o resultado dos pontos gerados dentro dos polígonos. Nota-se que os pontos ficaram bem distribuídos dentro de cada parcela, sempre obedecendo os limites dos tratamentos.

Figura 24 - Pontos regulares sobre as parcelas contendo os tratamentos para a extração dos valores de refletância.




Fonte: O autor.

4.7 EXTRAÇÃO DE DADOS DE REFLETÂNCIA GERADOS COM O SATÉLITE

A extração de dados de refletância gerados com o satélite foi similar à da RPA. Porém, nesse caso, foram utilizados todos os pontos disponíveis, já que as imagens de satélite empregadas no estudo tinham resolução espacial de 5 m, inferior aos 3,4 cm da RPA, implicando que cada pixel do satélite cobriu uma área de 25 m², enquanto cada pixel da RPA cobriu uma área menor, de apenas 0,11m².

De forma semelhante ao que foi feito para a RPA, um teste foi realizado para definir o tamanho ideal do polígono para a captura dos dados do satélite em cada ponto. Para isso, foram utilizados polígonos de 5, 10, 15 e 20 m, com lados iguais, e um outro com 22 m × 30 m (22 m de lado foi para respeitar o limite das parcelas de 24 m de largura), como pode ser visualizado na Figura 25. O algoritmo de aprendizado de máquina aplicado foi a SVR, com o *kernel* RBF, com os parâmetros *cost*=1, *gamma*=0,33 e *epsilon*=1. O índice utilizado para o teste foi o NDVI mais a altura das plantas. Diferente do método aplicado nos dados da RPA, aqui todas as leituras foram avaliadas, pois a resolução espacial dos dados de satélite é bem inferior à da RPA, possibilitando o processamento de todas as leituras em tempo hábil. Baseando-se nas correlações obtidas, optou-se pela escolha dos polígonos com 10 m para o mês de julho, de 15 m para os meses de agosto e outubro, e de 20 m para o mês de setembro de 2016.

Figura 25 - Polígonos utilizados para a validação das bases de satélite.



Fonte: O Autor.

Assim como foi feito com os dados de RPA, dois conjuntos de dados foram gerados, sendo um considerando as amostras coletadas nas parcelas e outro considerando os tratamentos. Os dados extraídos foram os índices NDVI e NDVI-RE, e os mesmos índices normalizados em uma escala de 0 a 100, conforme informações passadas pela *GeoAgro* que utiliza essa normalização para comparar com outros dados de campo e que também são normalizados neste mesmo intervalo. O Quadro 9 apresenta um fragmento de uma das bases, nela se observa como os dados vêm das imagens. A primeira coluna (Amostra) é o identificador da amostra no respectivo tratamento; a coluna Ndv09 indica as leituras realizadas no início do mês de setembro (01/09/2016) e a segunda coluna mostra os dados da leitura realizada no fim do mês de setembro (24/09/2016).

Quadro 9 - Fragmento da base gerada com os dados de satélite.


Amostra	Ndv09	Ndv0924
N1A9	0,8	0,7

Foram geradas quatro bases considerando as amostras coletadas, sendo uma para cada leitura em campo: SAT_julho, SAT_agosto, SAT_setembro e SAT_outubro, cada uma com os atributos; amostra, NDVI, NDRE, NDVI Normalizado, NDRE Normalizado, altura da planta e biomassa seca. As outras quatro bases, considerando os tratamentos, foram geradas como demonstrado na criação dos pontos regulares da Figura 24, extraindo todos os valores dos pixels que estavam dentro dos polígonos.

4.8 EXTRAÇÃO DE DADOS DE REFLETÂNCIA GERADOS COM O *GREENSEEKER*

Os dados do *GREENSEEKER* são gerados no formato .CSV. Esse arquivo pode ser importado para dentro da ferramenta QGIS. Na Figura 26 pode ser observado como esses dados são interpretados pelo software QGIS. As diferenças na coloração correspondem a diferentes valores de NDVI, sendo a cor vermelha indicativa de valores mais baixos e a cor verde indicativa de valores mais altos.

Figura 26 - Resultado da importação dos dados do *GREENSEEKER* coletados no mês de outubro para o QGIS.



Fonte: O autor.

A coleta dos dados de refletância gerados com o *GREENSEEKER* foi realizada por meio de um método diferente daquele aplicado para o satélite e as imagens de RPA. Como as leituras geraram um número limitado de pontos, todos os pontos foram utilizados, obedecendo sempre a divisão dos tratamentos. Outra informação corresponde à leitura realizada em julho, em que os dados foram perdidos devido a problemas na criação dos arquivos pelo equipamento, gerando a cada nova leitura um mesmo arquivo com os mesmos valores de resposta espectral. Com isso, foram geradas três bases, correspondentes às leituras realizadas em agosto, setembro e outubro de 2016. No Quadro 10 é mostrado um fragmento da base gerada pelo *GREENSEEKER*. A coluna *NDVI* é calculada pelo equipamento, considerando os valores fornecidos nas colunas *REDrefc* e *NIRrefc*. O cálculo manual também foi realizado, constatando-se que o valor fornecido pelo equipamento estava correto.

Quadro 10 - Fragmento da base gerada com os dados do *GREENSEEKER* no mês de outubro de 2016.

GPS Time	Latitude	Longitude	NDVI	REDrefc	NIRrefc
17:30:33.000	-24.356.558	-50.130.408	0.84600	0.03290	0.39450
17:31:05.000	-24.356.628	-50.130.193	0.81202	0.04839	0.47230
17:31:41.000	-24.356.942	-50.130.285	0.81077	0.04202	0.40325
17:31:52.000	-24.357.062	-50.130.322	0.82213	0.05215	0.53597

4.9 ÍNDICES DE VEGETAÇÃO GERADOS COM OS DADOS DE RPA

Os IVs selecionados foram baseados na literatura, considerando a possibilidade de gerá-los a partir dos dados obtidos com a RPA. Com isso, foram utilizados quatro IVs, sendo eles: NDVI, SAVI, MSAVI e OSAVI, cujas fórmulas estão detalhadas na seção 0, e podem ser visualizadas no Quadro 11.

Quadro 11 - Índices de vegetação gerados com os dados da RPA.

Fórmula do Índice de Vegetação	Fonte
$NDVI = \frac{NIR - Vermelho}{NIR + Vermelho}$	Rouse et al. (1973)
$SAVI = (1 + 0,5) * \frac{NIR - Vermelho}{NIR + Vermelho + 0,5}$	Huete (1988)
$MSAVI_2 = 0,5 \left(2 * NIR + 1 - \sqrt{(2 * NIR)^2 - 8 * (NIR - Vermelho)} \right)$	Qi et al. (1994)
$OSAVI = (1 + 0,16) * \frac{NIR - Vermelho}{NIR + Vermelho + 0,16}$	Rondeaux, Steven e Baret (1996)

Para aplicar as fórmulas nas bases empregou-se a ferramenta gratuita de edição de planilhas Apache OpenOffice CALC¹⁰, na versão 4.1.3. Os IVs foram calculados nas bases geradas pela RPA EBEE, nas duas divisões, por amostras e por tratamento.

4.10 MINERAÇÃO DE DADOS E TESTES ESTATÍSTICOS

Considerando que a SVR tem grande capacidade de generalização, mesmo com um número reduzido de instâncias, optou-se pela utilização desta técnica na criação dos modelos de estimativa, os quais foram comparados com os resultados obtidos usando regressão linear.

O *Kernel* selecionado para a SVR foi o RBF. Essa escolha foi motivada pelo seu potencial em modelos de regressão, tratando-se de um algoritmo popular dentro do aprendizado de máquina (WU; TZENG; LIN, 2009) e pela carência de pesquisas relacionadas a esse algoritmo em modelos de estimativas baseados em dados de SR.

A ferramenta empregada na aplicação do algoritmo SVR foi o software R, na versão 3.3.3. A escolha desse software foi baseada na sua popularidade na literatura e por ser um software de código aberto para uso gratuito (R CORE TEAM, 2015) que possibilita o uso de SVR com o *kernel* RBF, através do pacote *e1071* (DIMITRIADOU et al., 2009). Na equação (4) é mostrada a fórmula do *kernel* RBF presente no pacote *e1071*.

¹⁰ Download disponível em: <http://www.openoffice.org/pt/download/>

$$RBF : k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (4)$$

onde: x_i e x_j são os vetores de espaço de entrada e γ deve ser maior que zero ($\gamma > 0$) (DIMITRIADOU et al., 2009; MEYER et al., 2014).

A SVR com o *kernel* RBF tem parâmetros de otimização, tendo sido utilizados os valores padrão sendo: *cost* de 1, *épsilon* em 0,1 e o *gamma* é determinado através da divisão de 1 pela dimensão da base.

O ambiente *R* não implementa interface gráfica e toda a execução da aplicação deve ser realizada por comando em linguagem *Rscript* (.R). No Quadro 12 é apresentado um fragmento do código correspondente a uma chamada para executar o processo de mineração de dados.

Quadro 12 - Fragmento de código em R referente à aplicação de uma tarefa de mineração de dados.

Linha	Comando (Rscript)
1	<code>EBEE_agosto <- read.csv(paste(diretorio, 'EBEE_agosto.csv', sep=''), header = TRUE)</code>
2	<code>base<-'SAVI3408 + altura'</code>
3	<code>meta<-'MASSA'</code>
4	<code>model2<-svm(massa ~ SAVI3408 + altura, cross = 10, EBEE_agosto)</code>
5	<code>x<-data.frame(r=model2\$scorrcoeff, rmse=rmse(model2\$residuals), mae=mae(model2\$residuals), imagem=base, meta=meta)</code>
6	<code>write.csv(x, "EBEE_agostoIV.csv")</code>

Nota: Na linha 1 é carregada a base de dados; as linhas 2 e 3 são valores para identificar no arquivo de saída o que foi executado; a linha 4 é o comando para executar a mineração; a linha 5 é a geração da variável com os resultados e erros; e a linha 6 corresponde à gravação do arquivo de saída com os resultados.

Para a validação das tarefas de mineração foi utilizada a técnica validação cruzada com 10 folds (*cross-validation 10 folders*) por ser um método consagrado de validação de modelos, conforme proposto por Witten e Frank (2005).

5 RESULTADOS E DISCUSSÃO

5.1 DADOS COLETADOS EM CAMPO

Os tratamentos de adubação nitrogenada proporcionaram diferentes concentrações de N nas folhas e acúmulo distinto de biomassa seca da parte aérea do trigo, em diferentes estádios de desenvolvimento da cultura, como era pretendido no estudo (Tabela 1). Nota-se que o tratamento 3, no qual foi aplicada a maior dose de N (100 kg N ha^{-1} em pré-semeadura + 36 kg N ha^{-1} na semeadura), foi o que proporcionou maior concentração de N e maior produtividade de biomassa seca da parte aérea, nos diferentes estádios de desenvolvimento da cultura do trigo. A performance da nutrição de N e do acúmulo de biomassa seca da parte aérea foi superior no tratamento 2 (50 kg N ha^{-1} em pré-semeadura + 36 kg N ha^{-1} na semeadura) em relação aos tratamentos 1 (36 kg N ha^{-1} na semeadura) e 4 (36 kg N ha^{-1} na semeadura + 27 kg N ha^{-1} aos 40 DAS + 45 kg N ha^{-1} aos 50 DAS). Esperava-se obter resultados melhores com o tratamento 4 que recebeu uma dose total de N (108 kg ha^{-1}) maior que o tratamento 2 (86 kg ha^{-1}), e ainda de forma parcelada. Destaca-se, porém, que as duas coberturas com N realizadas aos 40 e 50 DAS, no tratamento 4, ocorreram em uma época muito chuvosa (Figura 11), o que deve ter favorecido as perdas de nitrato (NO_3^-) por lixiviação. Outro aspecto importante que deve ser destacado é que a performance de desenvolvimento das plantas de trigo foi bem satisfatória no tratamento 1 que recebeu apenas 36 kg N ha^{-1} na semeadura. Isso deve ter acontecido por se tratar de área há longo período no sistema plantio direto e com alto estoque de matéria orgânica. Além disso, o trigo foi cultivado após a cultura da soja, cujos resíduos possuem baixa relação C/N, favorecendo a mineralização e o aproveitamento de N do sistema. De qualquer forma, os tratamentos de adubação nitrogenada proporcionaram alterações na concentração foliar de N e no acúmulo de biomassa da parte aérea do trigo, o que era fundamental para a captura dos dados de refletância pelo SR.

Tabela 1 - Concentração de nitrogênio nas folhas e produtividade de biomassa da parte aérea do trigo, em diferentes estádios de desenvolvimento da cultura, de acordo com os tratamentos de adubação nitrogenada.

Tratamento	N nas folhas	Produtividade de biomassa seca da parte aérea do trigo			
		Plântula	Perfilhamento	Emborrachamento	Florescimento
	g kg^{-1}^*	kg ha^{-1}^*			
1	$33,88 \pm 2,80$	$306,27 \pm 49,88$	$982,35 \pm 3,85$	$6302,74 \pm 416,30$	$7919,21 \pm 727,81$
2	$35,84 \pm 3,83$	$317,06 \pm 75,08$	$1047,84 \pm 5,87$	$6692,35 \pm 377,78$	$8678,82 \pm 889,10$
3	$38,92 \pm 3,11$	$327,65 \pm 45,45$	$1127,45 \pm 11,24$	$6795,88 \pm 594,03$	$8951,17 \pm 625,77$
4	$33,04 \pm 2,76$	$325,10 \pm 44,96$	$920,78 \pm 3,34$	$6233,13 \pm 717,51$	$8166,70 \pm 698,05$

*Valores médios seguidos dos respectivos desvios padrão.

5.2 SENSOR ÓTICO *GREENSEEKER*

Com as bases geradas foram executados os algoritmos de mineração de dados para regressão linear e SVR. A execução foi repetida quatro vezes, com as seguintes combinações de atributos preditores: Bandas (NIR + Vermelho), Bandas + altura, NDVI e NDVI + altura. A execução contemplou individualmente cada um dos atributos meta (biomassa seca e concentração foliar de N) em ambas as divisões (por amostra: considerando todas as amostras coletadas em cada tratamento, e por tratamento: considerando as médias das amostras coletadas nos tratamentos).

5.2.1 Biomassa da parte área do trigo

Os coeficientes de correlação obtidos com a SVR estão apresentados na Tabela 2. Destaca-se que os maiores coeficientes de correlação foram obtidos quando se consideraram as médias das amostras por tratamento. Dentre os resultados de correlação obtidos sem o uso da altura, nenhum deles teve resultados superiores aos de Erdle, Mistele e Schmidhalter (2011). Esses autores correlacionaram a biomassa seca do trigo com as bandas no *GREENSEEKER* e o NDVI, obtendo coeficientes de correlação (r) de 0,75 a 0,91, os quais são superiores aos observados no presente estudo, considerando ambas as abordagens (todas as amostras e média dos tratamentos). Kapp, Caires e Guimarães, (2014) empregou técnicas de AM com RNA na estimativa de biomassa seca do trigo usando dados do *GREENSEEKER* e os valores de r obtidos ficaram dentro de 0,55 a 0,66, os quais foram similares aos obtidos no presente estudo com a SVR, considerando a média dos tratamentos.

Tabela 2 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados com *GREENSEEKER* para estimar a produtividade de biomassa seca da parte aérea de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	NDVI	NDVI+Alt	Bandas	Bandas+Alt	NDVI	NDVI+Alt	Bandas	Bandas+Alt
Perfilha.	0,03	0,80	0,08	0,80	0,27	0,99	0,37	0,99
Embor.	0,28	0,57	0,30	0,59	0,60	0,99	0,65	0,99
Flores.	0,37	0,60	0,43	0,60	0,63	0,99	0,68	0,99

Quando foi adicionada a altura na divisão baseada em amostras, os resultados se aproximaram dos encontrados na literatura, obtendo-se valor r de 0,80 para o estágio fenológico de perfilhamento usando o NDVI e Bandas (Tabela 2). Esse resultado foi similar aos encontrados por Erdle, Mistele e Schmidhalter (2011) e Grohs et al., (2009), e superior aos obtidos por Kapp, Caires e Guimarães, (2014).

Um aspecto a ser destacado nos trabalhos da literatura se refere ao modo como foram realizadas as leituras, sendo sempre em parcelas com distintos tratamentos e repetições. No presente trabalho, foram realizadas duas comparações, considerando todas as amostras e as médias das amostras nos tratamentos. Nas amostras, avaliou-se a capacidade do equipamento em detectar a variabilidade dentro de um mesmo tratamento e, nos tratamentos, a capacidade do equipamento em verificar diferenças entre as aplicações de N. Quando foi aplicada a técnica de mineração com a divisão por tratamento, os resultados melhoraram expressivamente, mesmo sem a inserção da altura na criação dos modelos preditivos, obtendo-se valores de correlação próximos daqueles encontrados na literatura. Com a inserção da altura das plantas ao modelo, os valores foram bem superiores aos da literatura, com r de 0,99. Esse resultado já era esperado, visto que a altura das plantas tem correlação com a produção de biomassa (TILLY et al., 2014). Relativo ao uso das bandas ou do NDVI, os resultados se mantiveram com poucas diferenças nos coeficientes de correlação. Com isso, o uso do NDVI acabou sendo mais oportuno, por reduzir um atributo na criação dos modelos. A pouca expressividade na diferença dos resultados obtidos com o uso das bandas *versus* o NDVI também foi observada no trabalho de Erdle, Mistele e Schmidhalter, (2011).

Dentre os estádios fenológicos, na divisão por amostras, o perfilhamento apresentou os melhores resultados, com os outros estádios também obtendo resultados expressivos e semelhantes (0,59 e 0,60 com atributos Bandas + altura). Porém quando utilizado apenas as respostas espectrais registradas pelo *GREENSEEKER*, a leitura de outubro, que contemplou o estádio fenológico do florescimento, obteve o melhor r (0,43 para as Bandas). Esse resultado se repetiu para a divisão por tratamentos, com o florescimento apresentando o melhor resultado de r (0,68).

Quando executada a regressão linear aos dados, todos os resultados foram inferiores aos obtidos com a SVR, como pode ser observado na Tabela 3. Mesmo com a utilização da altura das plantas na divisão por tratamento, alguns valores de r ficaram abaixo de 0,90 e foram inferiores aos obtidos com a SVR (Tabela 2) em todos os casos. Esses resultados demonstram que a SVR teve desempenho superior ao modelo de regressão linear clássico na estimativa da produtividade de biomassa da parte aérea de trigo.

Tabela 3 - Coeficientes de correlação (r) obtidos com regressão linear sobre os dados gerados com *GREENSEEKER* para estimar a produtividade de biomassa seca da parte aérea de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	NDVI	NDVI+Alt	Bandas	Bandas+Alt	NDVI	NDVI+Alt	Bandas	Bandas+Alt
Perfilha.	0,02	0,74	0,07	0,74	0,19	0,94	0,22	0,95
Embor.	0,24	0,46	0,19	0,46	0,58	0,87	0,56	0,89

Flores.	0,01	0,44	0,22	0,45	0,57	0,97	0,64	0,97
---------	------	------	------	------	------	------	------	------

Cabe destacar que, como resultado, além do coeficiente de correlação, o algoritmo de regressão linear deixa explícito o modelo de estimativa gerado uma equação matemática, a qual permite verificar a contribuição de cada variável de previsão na estimativa do atributo meta. Diferentemente, o modelo gerado pela SVR com o *kernel* RBF não corresponde a uma equação e sim a um modelo de vetores, sendo necessário, para novas estimativas, que esse modelo seja executado no próprio software R, ou seja incorporado em outros softwares.

5.2.2 Nitrogênio nas folhas de trigo

Para os modelos criados de predição de N foliar, sempre foram estimados os valores aferidos no mês de outubro de 2016, na época do florescimento da cultura do trigo. Na Tabela 4 estão apresentados os resultados obtidos para a concentração de N nas folhas. Mesmo com a adição da altura das plantas, os valores de r variaram de 0,59 a 0,61 na divisão por amostras. Esses valores foram inferiores aos obtidos por Ali et al. (2015), os quais obtiveram r de 0,81 para as bandas e 0,82 para o NDVI. Erdle, Mistele e Schmidhalter (2011) também encontraram correlação maior, com r de 0,90 tanto para o NDVI como para as bandas. Por outro lado, Kapp, Caires e Guimarães, (2014) obteve coeficientes de correlação (r) que variaram de 0,20 a 0,38, cujos valores foram semelhantes aos obtidos neste trabalho. Com a inserção da altura das plantas, os resultados obtidos foram melhores que os observados por Kapp, Caires e Guimarães, (2014) sem a adição desse parâmetro.

Tabela 4 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados pelo *GREENSEEKER* para a estimativa da concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	NDVI	NDVI+Alt	Bandas	Bandas+Alt	NDVI	NDVI+Alt	Bandas	Bandas+Alt
Embor.	0,27	0,61	0,32	0,60	0,75	0,99	0,76	0,99
Flores.	0,29	0,59	0,35	0,58	0,52	0,99	0,54	0,99

Com a divisão baseada nas médias dos tratamentos, as correlações foram maiores, se aproximando mais dos valores encontrados na literatura, com r de 0,76 próximo ao obtido por Ali et al. (2015) de 0,81, sem a utilização da altura da plantas. Quando a altura das plantas foi adicionada na predição de N, os resultados passaram a ser superiores aos da literatura, tendo-se obtido r de 0,99 (Tabela 4).

A melhoria do modelo de predição de N foliar com a inserção da altura das plantas pode estar relacionada ao fato de que as plantas mais bem nutridas em N também apresentam

maior crescimento, exibindo maior estatura. Tilly et al. (2014) comprovaram a correlação (r de 0,92) da altura da planta com a biomassa seca e, por consequência, a concentração de N. De acordo com Grohs et al. (2009), quanto maior a disponibilidade de N maior será o acúmulo de biomassa.

Cabe destacar também que diferenças expressivas foram observadas nos trabalhos de Ali et al. (2015), Erdle, Mistele e Schmidhalter (2011) e Grohs et al. (2009), apesar de as metodologias empregadas terem sido semelhantes, com ambos utilizando *GREENSEEKER* para estimar biomassa da parte aérea e a concentração de N nas folhas de trigo. No estudo de Erdle, Mistele e Schmidhalter (2011) que durou dois anos com diversas leituras em campo, foram obtidos vários resultados com coeficientes distintos (R^2 variando de 0,57 a 0,83) para o mesmo objetivo. Esses resultados sugerem que o *GREENSEEKER*, apesar de ser um sensor ativo, pode apresentar interferências de fatores ambientais.

Dentre os estádios fenológicos sem considerar o atributo altura, na divisão por amostras, não foi observado uma diferença expressiva nos resultados. Considerando a divisão por tratamento, o emborrachamento obteve resultado superior, de (r) 0,76 para 0,54 (Bandas) atingido na leitura realizada em outubro no estágio fenológico de florescimento.

Os resultados dos modelos criados pela regressão linear para predição de N foliar (Tabela 5), assim como observado para a produtividade de biomassa da parte aérea, foram inferiores aos obtidos com a SVR.

Tabela 5 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados pelo *GREENSEEKER* para a estimativa da concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	NDVI	NDVI+Alt	Bandas	Bandas+Alt	NDVI	NDVI+Alt	Bandas	Bandas+Alt
Embor.	0,27	0,58	0,31	0,58	0,66	0,87	0,70	0,89
Flores.	0,02	0,40	0,18	0,41	0,46	0,87	0,51	0,87

5.3 SATÉLITES *RAPIDEYE*

Para os dados obtidos com os satélites *RAPIDEYE*, a execução dos algoritmos de mineração de dados SVR e regressão linear foi repetida oito vezes por base, com as seguintes combinações de atributos preditores: NDVI, NDVI + altura, NorVI (NDVI Normalizado), NorVI + Altura, NDRE, NDRE + Altura, NorRE (NDRE Normalizado) e NorRE + Altura. A execução contemplou individualmente cada um dos atributos meta (produtividade de biomassa seca da parte aérea e concentração de N nas folhas de trigo), em ambas as divisões (por amostra:

considerando todas as amostras, e por tratamento: considerando as médias das amostras nos tratamentos).

5.3.1 Biomassa da parte aérea do trigo

Os resultados de predição de produtividade de biomassa da parte aérea do trigo com a SVR, considerando todas as amostras sem a inserção da altura das plantas, estão apresentados na Tabela 6. Destaca-se os resultados obtidos no estágio fenológico de perfilhamento, apresentado resultados superiores aos demais estádios com ou sem o atributo altura na criação dos modelos. De modo geral, os coeficientes de correlação obtidos foram relativamente baixos. Na literatura, foram encontrados resultados melhores, como em Kross et al. (2015) que avaliaram os dados provenientes do satélite *RAPIDEYE* para estimar a biomassa da parte aérea e o índice de área foliar nas culturas de soja e milho. Esses pesquisadores obtiveram bons resultados na estimativa de biomassa seca da parte aérea, obtendo r de 0,60 a 0,97 para a soja e de 0,85 a 0,98 para o milho, cujos valores são superiores aos observados no presente trabalho. Quando a altura foi inserida aos modelos, os resultados de correlação se aproximaram dos obtidos por Kross et al. (2015). Destaca-se o resultado obtido no estágio de perfilhamento do trigo, com r de 0,82. Vale salientar que Kross et al. (2015) utilizaram todas as bandas espectrais disponíveis pelo satélite. Consequentemente, um número maior de IVs foi gerado. Outro ponto relevante é o fato de os autores terem analisado a área de interesse durante três anos (2011 a 2013), garantindo um conjunto maior de dados para análise. Por fim, na pesquisa de Kross et al. (2015), as culturas estudadas (soja e milho) diferem da utilizada nesse trabalho (trigo). Isso também pode acarretar em resultados distintos, pois no trabalho de Kross et al. (2015) foram obtidos diferentes resultados para cada cultura estudada.

Tabela 6 - Coeficientes de correlação (r) obtidos com SVR sobre os dados gerados com os satélites *RAPIDEYE* para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando todas as amostras.

Estádio	NDVI	NDVI+Alt	NDRE	NDRE +Alt	NorVI	NorVI+Alt	NorRE	NorRE+Alt
Plânt.	0,19	0,40	0,13	0,26	0,24	0,37	0,16	0,30
Perfilh.	0,42	0,82	0,37	0,74	0,48	0,82	0,43	0,77
Embor.	0,15	0,59	0,13	0,56	0,49	0,63	0,22	0,62
Flores.	0,42	0,59	0,16	0,57	0,49	0,67	0,27	0,62

Para a divisão feita com a média dos tratamentos, os resultados obtidos com a SVR passaram a ser mais representativos e, em muitos casos, as correlações foram maiores que as reportadas da literatura (Tabela 7). Destaca-se o resultado obtido no estágio fenológico de florescimento da cultura, com r de 0,90 para o NDVI, sem o uso da altura das plantas na criação do modelo. Outro resultado interessante foi o incremento do valor de r com passar do tempo

para o NDVI. Nota-se que em julho de 2016 (estádio de plântula), o r sem o uso da altura das plantas foi de 0,14 e, em outubro de 2016 (estádio de florescimento), foi de 0,90, tanto para o NDVI como para o NorVI (NDVI normalizado). Isso indica que o NDVI gerado pelo satélite aumentou a capacidade preditiva na medida em que as plantas estavam mais desenvolvidas no campo, alcançando melhor predição no estágio de florescimento do trigo. Com a adição da altura das plantas ao modelo, os resultados passaram a ser melhores que os da literatura, obtendo-se r de 0,99, decorrente da forte correlação entre altura das plantas e a produtividade de biomassa da parte aérea.

Tabela 7 - Coeficientes de correlação (r) obtidos com SVR sobre os dados gerados com os satélites *RAPIDEYE* para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando as médias dos tratamentos.

Estádio	NDVI	NDVI+Alt	NDRE	NDRE +Alt	NorVI	NorVI+Alt	NorRE	NorRE+Alt
Plânt.	0,14	0,98	0,14	0,98	0,42	0,97	0,68	0,97
Perfilh.	0,61	0,99	0,30	0,99	0,64	0,99	0,30	0,99
Embor.	0,73	0,99	0,31	0,99	0,76	0,99	0,32	0,99
Flores.	0,90	0,99	0,34	0,99	0,90	0,99	0,37	0,99

Para os resultados de estimativa da produtividade de biomassa da parte aérea do trigo usando a regressão linear, os coeficientes de correlação foram inferiores aos da SVR (Tabela 8), de forma semelhante ao que já havia sido observado com os dados do *GREENSEEKER*. Mesmo com resultados inferiores aos obtidos com a SVR, a regressão linear resultou em r de 0,83 para a divisão baseada em tratamentos com o NorVI (NIDVI normalizado), valor próximo dos obtidos por Kross et al. (2015).

Tabela 8 - Coeficientes de correlação (r) obtidos com regressão linear sobre os dados gerados com os satélites *RAPIDEYE* para estimar a produtividade de biomassa da parte aérea do trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	NDVI	NDVI+Alt	NDRE	NDRE +Alt	NorVI	NorVI+Alt	NorRE	NorRE+Alt
Amostras								
Plânt.	0,04	0,09	0,01	0,08	0,02	0,08	0,04	0,09
Perfilh.	0,19	0,67	0,42	0,70	0,20	0,67	0,40	0,69
Embor.	0,15	0,50	0,13	0,50	0,44	0,51	0,20	0,50
Flores.	0,42	0,48	0,16	0,44	0,48	0,50	0,25	0,45
Tratamentos								
Plânt.	0,12	0,69	0,11	0,76	0,13	0,69	0,11	0,76
Perfilh.	0,58	0,94	0,27	0,94	0,59	0,94	0,27	0,94
Embor.	0,68	0,86	0,32	0,86	0,69	0,86	0,33	0,86
Flores.	0,82	0,98	0,38	0,97	0,83	0,98	0,69	0,97

5.3.2 Nitrogênio nas folhas de trigo

Os modelos de estimativa para a concentração de N nas folhas de trigo com a SVR, considerando todas as amostras sem o uso da altura das plantas (Tabela 9). Destaque-se os resultados obtidos no estágio fenológico de florescimento, obtendo os resultados mais

expressivos com ou sem o uso da altura no desenvolvimento dos modelos preditivos. De modo geral os resultados foram pouco expressivos se comparados com o da literatura. Eitel et al. (2007) obtiveram coeficiente de correlação (r) de 0,82 com a combinação dos IVs MCARI com MTVI para estimar a concentração de N nas folhas de trigo com dados gerados dos satélites *RAPIDEYE*. Esse resultado é superior ao obtido no presente estudo. Entretanto, quando se analisam os resultados obtidos apenas com o NDVI, os resultados obtidos por Eitel et al. (2007) foram inferiores (não ultrapassando r de 0,30) aos observados neste trabalho. Com a adição da altura das plantas, os valores de r ficaram próximos a 0,70, enquanto sem a altura das plantas, o melhor resultado foi com r de 0,43 em outubro de 2016 no NorVI (NDVI Normalizado). O NDRE nunca obteve coeficiente de correlação superior ao do NDVI. Esse resultado está relacionado com os comprimentos de onda, sendo que os índices gerados com o espectro NIR realizam estimativas para o N mais precisas do que os índices que utilizam o espectro *RedEdge* (ERDLE; MISTELE; SCHMIDHALTER, 2011).

Tabela 9 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados dos satélites *RAPIDEYE* para estimar a concentração de N nas folhas de trigo, considerando todas as amostras.

Estádio	NDVI	NDVI+Alt	NDRE	NDRE+Alt	NorVI	NorVI+Alt	NorRE	NorRE+Alt
Plânt.	0,10	0,14	0,32	0,51	0,15	0,48	0,35	0,53
Perfilh.	0,04	0,56	0,13	0,57	0,33	0,68	0,17	0,63
Embor.	0,30	0,59	0,15	0,56	0,30	0,59	0,22	0,53
Flores.	0,33	0,61	0,10	0,55	0,43	0,67	0,26	0,55

Para os modelos criados para predição de N foliar com a SVR baseados na média dos tratamentos (Tabela 10), os resultados foram bem melhores, como também aconteceu com os modelos de produtividade de biomassa da parte aérea. O valor de r para o NDVI normalizado foi de 0,83 no estágio fenológico de florescimento e sem a utilização da altura das plantas, cujo resultado foi muito semelhante ao obtido por Eitel et al. (2007), de 0,82, com a combinação de IVs. Aqui se repete o mesmo incremento observado para a produtividade de biomassa seca da parte aérea, em que a cada imageamento com o satélite, no decorrer do ciclo de desenvolvimento da cultura do trigo, o valor de r foi incrementado, ficando os dados obtidos em outubro de 2016 (estádio fenológico de florescimento da cultura) com o melhor resultado de correlação. A inserção da altura das plantas aos modelos aumentou o valor de r para 0,99 em quase todos os índices e leituras.

Tabela 10 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados dos satélites *RAPIDEYE* para estimar a concentração de N nas folhas de trigo, considerando as médias dos tratamentos.

Estádio	NDVI	NDVI+Alt	NDRE	NDRE+Alt	NorVI	NorVI+Alt	NorRE	NorRE+Alt
Plânt.	0,42	0,96	0,68	0,96	0,45	0,97	0,68	0,96
Perfilh.	0,61	0,99	0,27	0,99	0,65	0,99	0,29	0,99
Embor.	0,76	0,99	0,33	0,99	0,78	0,99	0,34	0,99

Flores.	0,81	0,99	0,29	0,99	0,83	0,99	0,31	0,99
---------	------	------	------	------	------	------	------	------

Os coeficientes de correlação obtidos com os modelos gerados com a regressão linear (Tabela 11) novamente foram inferiores aos obtidos com a SVR, tanto quando se considerou todas as amostras como na média dos tratamentos. Destacam-se os resultados baseados na média dos tratamentos para o NorVI pois, mesmo sem a adição da altura das plantas, os valores de r se mantiveram próximos dos obtidos por Eitel et al. (2007).

Tabela 11 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados com os satélites *RAPIDEYE* para estimar a concentração de N nas folhas de trigo considerando todas as amostras e as médias dos tratamentos.

Estádio	NDVI	NDVI+Alt	NDRE	NDRE +Alt	NorVI	NorVI+Alt	NorRE	NorRE+Alt
Amostras								
Plânt.	0,15	0,41	0,27	0,43	0,07	0,41	0,30	0,44
Perfilh.	0,01	0,41	0,13	0,41	0,29	0,41	0,09	0,40
Embor.	0,30	0,44	0,14	0,41	0,43	0,47	0,23	0,43
Flores.	0,33	0,42	0,01	0,41	0,37	0,42	0,11	0,40
Tratamentos								
Plânt.	0,45	0,60	0,62	0,71	0,45	0,64	0,68	0,74
Perfilh.	0,06	0,97	0,18	0,97	0,60	0,97	0,28	0,97
Embor.	0,42	0,87	0,23	0,87	0,71	0,87	0,36	0,87
Flores.	0,71	0,88	0,22	0,88	0,73	0,88	0,22	0,88

5.4 RPA EBEE

Com as informações coletadas com a RPA, a produtividade de biomassa seca da parte aérea e a concentração de N nas folhas de trigo foram estimadas de duas formas, utilizando as bandas extraídas das imagens e os índices de vegetação gerados a partir dos valores das bandas.

Para os modelos gerados utilizando as bandas, a execução do algoritmo SVR e a regressão linear foram repetidos quatro vezes por base, contemplando individualmente cada uma das câmeras (RGB, NIR, RGB + altura e NIR + altura). Esse processo foi executado individualmente para cada um dos atributos meta (produtividade de biomassa seca da parte aérea e concentração de N nas folhas) em ambas as divisões (por amostra e por tratamento).

5.4.1 Biomassa da parte aérea do trigo

Na Tabela 12 são apresentados os resultados obtidos com a SVR sobre as bandas, com destaque para as correlações encontradas no estágio fenológico de perfilhamento da cultura, baseadas na divisão por amostras, com r de 0,95 para os canais de cores RGB e de 0,92 para os canais de cores NIR. Esses resultados foram superiores aos encontrados por Bendig et al. (2015) em um estudo similar, utilizando uma RPA multirrotor para estimar a biomassa seca da parte aérea da cevada. Esses autores combinaram dados espectrais gerados pela RPA com a altura

das plantas e obtiveram r de 0,88, inferior ao r de 0,95 obtido neste trabalho no canal de cor RGB no estágio fenológico de perfilhamento da cultura. Outros resultados obtidos no presente estudo para a câmera NIR, com valores de r de 0,88 e 0,87 e 0,92 (estádios de florescimento, emborrachamento e perfilhamento, respectivamente) na combinação de bandas com a altura das plantas, foram similares e superiores aos obtidos por Bendig et al. (2015).

Usando apenas os valores das bandas obtidas com a RPA, os resultados de Bendig et al. (2015) foram pouco superiores, com valor de r de 0,76 em comparação com r de 0,73 obtido no mês de agosto (perfilhamento) de 2016 nos canais de cores RGB. Pölönen et al. (2013) também utilizaram uma RPA (modelo similar a um helicóptero) para estimar a biomassa seca da parte aérea de trigo e cevada e obtiveram r de 0,63 a 0,81, dependendo do IV e da técnica utilizada, apenas com os dados da RPA, sem o uso da altura das plantas. Os resultados obtidos estágio fenológico de perfilhamento, com a câmera RGB, e em outubro de 2016 com a câmera NIR, sem o uso da altura das plantas, ficaram dentro do intervalo observado por Pölönen et al. (2013).

Tabela 12 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados com a RPA para estimar a produtividade de biomassa seca da parte aérea utilizando as bandas das câmeras, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	RGB	RGB+Alt	NIR	NIR+Alt	RGB	RGB+Alt	NIR	NIR+Alt
Plânt.	0,37	0,60	0,54	0,73	0,47	0,99	0,33	0,99
Perfilh.	0,73	0,95	0,62	0,92	0,55	0,99	0,28	0,99
Embor.	0,58	0,77	0,59	0,88	0,84	0,99	0,59	0,99
Flores.	0,64	0,81	0,71	0,87	0,90	0,99	0,63	0,99

Considerando as médias dos tratamentos, os resultados melhoram significativamente quando combinados com altura das plantas (r de 0,99), para todas as leituras (Tabela 12). Destacam-se os resultados obtidos sem o uso da altura das plantas para a câmera RGB, no emborrachamento (r de 0,84) e no florescimento (r de 0,90), cujas correlações foram, respectivamente, similar e superior às obtidas por Pölönen et al. (2013), e superiores às observadas por Bendig et al. (2015).

Mesmo com a câmera RGB obtendo o melhor resultado de correlação (r de 0,95), na divisão baseada em amostras com a altura das plantas, o NIR apresentou maior consistência nos resultados, com vários coeficientes de correlação acima de 0,85 e, ainda, um acima de 0,90 (Tabela 12). Esses resultados são decorrentes do fato de o espectro NIR estar relacionado com a estrutura celular das plantas e a pigmentação das folhas, com isso, a sua resposta espectral apresenta forte correlação com a biomassa da parte aérea das plantas (ERDLE; MISTELE; SCHMIDHALTER, 2011; GNYP et al., 2014). Entretanto, quando se observa os resultados na

média dos tratamentos, os dados dos canais de cores RGB destacam-se sobre os do NIR, sem o uso da altura das plantas, alcançando os melhores resultados. Esse fenômeno pode ser explicado pelo fato de que randomicamente bons resultados podem ser gerados com os canais de cores RGB. Isso também foi observado por Bendig et al. (2015) que também obtiveram resultados expressivos com dados providos dos canais de cores RGB.

Utilizando dados gerados por um sensor multiespectral (*QualitySpec Pro*) para estimar a biomassa da parte aérea do trigo, Gnyp et al. (2014) obtiveram o melhor resultado com r de 0,93. Este valor consiste em um dos melhores encontrados na literatura, envolvendo o uso de dados de SR para estimar a biomassa da parte aérea do trigo. Cabe destacar que esse valor foi bem próximo do obtido no presente estudo para a divisão baseada em tratamentos, com o r de 0,90 para o RGB, em outubro de 2016 (Tabela 12). Sendo assim, pode-se inferir que mesmo com o uso de sensores mais simples e de menor custo, como as câmeras utilizadas nesse estudo, é possível obter resultados tão expressivos quanto os alcançados por sensores mais complexos.

Na Tabela 13 estão apresentados os resultados de correlação obtidos com a SRV sobre os IVs gerados a partir dos dados da RPA para estimar a produtividade de biomassa da parte aérea do trigo. De modo geral, os resultados foram inferiores aos obtidos com as bandas. As correlações somente foram melhoradas com a inserção da altura das plantas. Nesse caso, altos coeficientes de correlação foram obtidos (r de 0,99) quando se consideraram as médias dos tratamentos, em todas as épocas de avaliação.

Tabela 13 - Coeficientes de correlação (r) obtidos com a SVR sobre os IVs gerados a partir dos dados obtidos com a RPA para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	SAVI	SAVI+Alt	MSAVI	MSAVI+Alt	OSAVI	OSAVI+Alt	NDVI	NDVI+Alt
Amostras								
Plânt.	0,32	0,45	0,32	0,45	0,32	0,45	0,32	0,45
Perfilh.	0,28	0,79	0,28	0,79	0,28	0,79	0,28	0,79
Embor.	0,32	0,67	0,26	0,67	0,26	0,67	0,26	0,67
Flores.	0,26	0,72	0,26	0,72	0,26	0,72	0,26	0,72
Tratamentos								
Plânt.	0,15	0,99	0,16	0,99	0,15	0,99	0,17	0,99
Perfilh.	0,05	0,99	0,05	0,99	0,05	0,99	0,05	0,99
Embor.	0,26	0,99	0,25	0,99	0,26	0,99	0,26	0,99
Flores.	0,18	0,99	0,18	0,99	0,18	0,99	0,18	0,99

Nos trabalhos de Gnyp et al. (2014) e Bendig et al. (2015) foram obtidos diferentes coeficientes de correlação entre os IVs nas estimativas de biomassa da parte aérea de trigo e cevada. No presente estudo, não foram encontradas grandes variações entre os diferentes IVs. Essa discrepância entre os resultados obtidos nesse estudo com os da literatura é justificada

pelo uso de diferentes comprimentos de onda para cada índice, enquanto neste trabalho foram utilizados os mesmos para todos os índices.

Para os modelos lineares gerados com os dados obtidos com a RPA, utilizaram-se apenas as bandas. Essa escolha foi motivada pelo fato de os resultados com os IVs terem sido, de modo geral, menos expressivos quando comparados com os obtidos com as bandas. Na Tabela 14 são apresentados os resultados obtidos com a regressão linear. Assim como observado para o *GREENSEEKER* e o *RAPIDEYE*, os resultados foram inferiores aos obtidos com a SVR. Destaca-se que, na divisão por amostras, o melhor valor de r obtido com a regressão foi de 0,74 (Tabela 14) e com a SVR foi de 0,95 (Tabela 12), em agosto de 2016.

Tabela 14 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados com a RPA para estimar a produtividade de biomassa seca da parte aérea do trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	RGB	RGB+Alt	NIR	NIR+Alt	RGB	RGB+Alt	NIR	NIR+Alt
Plânt.	0,30	0,32	0,34	0,34	0,19	0,66	0,13	0,66
Perfilh.	0,55	0,74	0,50	0,76	0,49	0,94	0,16	0,94
Embor.	0,45	0,52	0,43	0,55	0,74	0,87	0,36	0,87
Flores.	0,46	0,56	0,46	0,56	0,82	0,98	0,43	0,97

5.4.2 Nitrogênio nas folhas de trigo

Para os modelos visando estimar a concentração de N nas folhas de trigo, os resultados obtidos com a SVR, destacando os resultados obtidos no estágio fenológico do florescimento, sem considerar a altura das plantas e considerando as amostras, ficaram dentro dos encontrados na literatura (Tabela 15). Pölönen et al. (2013) obtiveram r variando de 0,55 a 0,72 e, no presente estudo, obteve-se r de 0,62 para a câmera NIR no mês de outubro de 2016. Quando foi inserida a altura das plantas ao modelo, alguns resultados com a câmera RGB e todos os resultados com a câmera NIR foram superiores aos encontrados por Pölönen et al. (2013), com destaque nos resultados obtidos no estágio de florescimento da cultura, com r de 0,87.

Considerando os resultados baseados na divisão por tratamentos, as correlações obtidas sem a altura das plantas foram melhores com a câmera RGB em relação à predição realizada com todas as amostras (Tabela 15). Destaca-se que alguns resultados no espectro RGB foram bem superiores aos encontrados por Pölönen et al. (2013), com r de 0,86 e 0,88, para os estádios fenológicos de emborrachamento e florescimento da cultura, respectivamente.

Tabela 15 - Coeficientes de correlação (r) obtidos com a SVR sobre os dados gerados com a RPA para estimar concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	RGB	RGB+Alt	NIR	NIR+Alt	RGB	RGB+Alt	NIR	NIR+Alt

Plânt.	0,48	0,68	0,46	0,78	0,66	0,99	0,44	0,99
Perfilh.	0,31	0,65	0,41	0,75	0,56	0,99	0,29	0,99
Embor.	0,60	0,75	0,60	0,81	0,86	0,99	0,59	0,99
Flores.	0,62	0,75	0,62	0,87	0,88	0,99	0,60	0,99

Resultados similares aos do presente trabalho também foram obtidos em outros estudos que visaram a estimativa do teor foliar de N. Por exemplo, Zhu et al. (2009) determinaram as correlações entre técnicas de segmentação de imagens adquiridas com RPA e concentração de N foliar na cultura do arroz, obtendo r de 0,47 a 0,87. Em outro trabalho, Agüera, Carvajal e Pérez (2012) usaram dados espectrais obtidos com uma RPA para estimar a concentração de N em girassol e obtiveram valor r de 0,87, no melhor caso.

Os resultados obtidos por meio dos dados do espectro NIR para as amostras, sem a utilização da altura das plantas, revelaram correlações com N um pouco mais estáveis em comparação aos obtidos com os dados do espectro RGB (Tabela 15). Esses resultados podem ser justificados pela correlação existente entre absorção de clorofila e a resposta espectral no NIR, o que resulta em correlação com a concentração de N, pois esse nutriente é usado na síntese de compostos celulares nas plantas (DENUIT et al., 2002; WOLFF; FLOSS, 2008). No entanto, quando a divisão foi baseada nas médias dos tratamentos, esse comportamento não foi observado, sendo que as correlações obtidas com os dados do espectro RGB superaram as encontradas pelo espectro do NIR. Bendig et al. (2015) também obtiveram elevados coeficientes de correlação para os dados dos canais de cores RGB, porém, os autores destacaram que esses resultados devem analisados com cautela, devido a sua variação. Esse fenômeno também foi observado nos modelos de estimativa de produtividade de biomassa da parte aérea, nos quais os resultados mais consistentes, na divisão por amostras, foram obtidos com dados do espectro NIR, porém, na divisão por tratamentos, os dados espectrais RGB apresentaram melhor desempenho (Tabela 12).

Nas correlações resultantes da utilização dos IVs gerados com os valores das bandas com a SRV para a predição de N foliar na cultura do trigo, sem considerar a altura das plantas, os resultados não foram satisfatórios (Tabela 16). Resultados similares já haviam sido observados com os modelos de predição de biomassa seca da parte aérea (Tabela 13). Nota-se que, mesmo quando a estimativa foi baseada nas médias dos tratamentos, os resultados se mantiveram pouco expressivos (Tabela 16) se comparados com os executados pelas bandas (Tabela 15). As correlações melhoraram substancialmente quando foi inserida a altura das plantas ao modelo, obtendo-se r de 0,99 nas médias dos tratamentos, em todos os meses e IVs utilizados (Tabela 16).

Tabela 16 - Coeficientes de correlação (r) obtidos com a SVR sobre os IV gerados através dos dados obtidos com a RPA para estimar a concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	SAVI	SAVI+Alt	MSAVI	MSAVI+Alt	OSAVI	OSAVI+Alt	NDVI	NDVI+Alt
Amostras								
Plânt.	0,22	0,59	0,22	0,59	0,22	0,59	0,22	0,60
Perfilh.	0,23	0,62	0,62	0,23	0,23	0,62	0,23	0,62
Embor.	0,28	0,63	0,29	0,63	0,28	0,63	0,28	0,63
Flores.	0,25	0,64	0,25	0,64	0,25	0,64	0,25	0,64
Tratamentos								
Plânt.	0,27	0,99	0,28	0,99	0,28	0,99	0,28	0,99
Perfilh.	0,06	0,99	0,06	0,99	0,06	0,99	0,06	0,99
Embor.	0,20	0,99	0,20	0,99	0,20	0,99	0,20	0,99
Flores.	0,19	0,99	0,20	0,99	0,20	0,99	0,20	0,99

Como as correlações atingidas utilizando os IVs foram inferiores às obtidas com as bandas, a comparação entre regressão linear e SVR foi reservada aos resultados obtidos com os dados das bandas. Os resultados obtidos com a regressão linear são apresentados na Tabela 17. As correlações encontradas na divisão por parcelas para o espectro RGB ficaram dentro das encontradas por Pölönen et al. (2013). Já, em comparação com a SVR, os coeficientes (r) da regressão linear foram inferiores. Destacam-se as diferenças observadas entre os resultados de outubro de 2016 com câmera NIR sem o uso da altura para a divisão por amostras, com a SVR o r foi 0,62 (Tabela 15) e, com a regressão linear, o r foi 0,10 (Tabela 17).

Tabela 17 - Coeficientes de correlação (r) obtidos com a regressão linear sobre os dados gerados com a RPA para estimar a concentração de N nas folhas de trigo, considerando todas as amostras e as médias dos tratamentos.

Estádio	Amostras				Tratamentos			
	RGB	RGB+Alt	NIR	NIR+Alt	RGB	RGB+Alt	NIR	NIR+Alt
Plânt.	0,42	0,48	0,28	0,45	0,47	0,87	0,29	0,88
Perfilh.	0,21	0,42	0,12	0,40	0,50	0,88	0,18	0,87
Embor.	0,53	0,53	0,26	0,42	0,75	0,87	0,40	0,87
Flores.	0,53	0,54	0,10	0,39	0,77	0,88	0,39	0,88

5.5 ANÁLISE CONJUNTA CONSIDERANDO AS TRÊS PLATAFORMAS DE SENSORIAMENTO REMOTO

Nos modelos de estimativa de produtividade de biomassa seca da parte aérea do trigo baseados na divisão por amostras, os melhores resultados foram obtidos com a RPA *EBEE*. Destaca-se que, no mês de agosto de 2016, obtiveram-se valores de r de 0,95 nos canais de cores RGB com a RPA *EBEE* (Tabela 12), de 0,80 usando bandas ou NDVI do sensor *GREENSEEKER* (Tabela 2) e de 0,82 utilizando o NDVI com os dados do *RAPIDEYE* (Tabela 6). Outra evidência de destaque para os resultados do *EBEE* foram os coeficientes de correlação obtidos com o espectro NIR, em que houve maior consistência nos resultados em comparação

com os do espectro visível do RGB, tendo-se alcançado altos coeficientes de correlação (r) com o NIR, os quais foram de 0,92, 0,88 e 0,87 para as leituras realizadas em agosto, setembro e outubro de 2016, respectivamente (Tabela 12).

Comportamento semelhante aos modelos preditores de biomassa da parte aérea foi observado nos resultados para a estimativa de concentração de N nas folhas de trigo. Com base na divisão por amostras, os resultados de maior expressividade foram encontrados com os dados da RPA *EBEE*, tendo-se obtido coeficientes de correlação (r) acima de 0,80 para os modelos de setembro e outubro de 2016 (Tabela 15), os quais foram superiores aos observados com o *GREENSEEKER* e o *RAPIDEYE*. Os melhores resultados obtidos com a RPA podem ser atribuídos à alta resolução espacial, possibilitando que pequenas alterações provocadas pela espacialidade dentro das amostras pudessem ser detectadas com as imagens geradas. Esse comportamento também foi destacado no trabalho Bendig et al. (2014), os quais atribuíram os bons resultados na estimativa de biomassa da parte aérea à alta resolução espacial, de 1 cm², obtida com uma RPA ultraleve, conseguindo identificar pequenas mudanças nas cobertura das plantas.

Considerando a divisão baseada em tratamentos, os resultados entre a RPA *EBEE* e os satélites *RAPIDEYE* passaram a ser semelhantes. Sem o uso da altura das plantas, ambas as plataformas de SR obtiveram valor r de 0,90 (Tabela 7 e Tabela 12) para a estimativa de biomassa seca da parte aérea do trigo, cujos resultados foram superiores aos obtidos com o *GREENSEEKER* (Tabela 2).

Para as estimativas de concentração de N nas folhas de trigo, os dados gerados pela RPA e pelos satélites resultaram em valores de r acima de 0,80 (Tabela 10 e Tabela 15). Nesse caso, a correlação obtida com a RPA (r de 0,88) foi um pouco superior à observada com os satélites *RAPIDEYE* (r de 0,83). Os resultados dos modelos gerados com os dados do *GREENSEEKER* foram melhores para predição de N foliar do que para a de produtividade de biomassa da parte aérea, porém tais resultados foram inferiores aos obtidos com a RPA *EBEE* e os satélites *RAPIDEYE*.

6 CONCLUSÕES

Os diferentes tratamentos de adubação nitrogenada proporcionaram respostas distintas de concentração de N nas folhas e de produtividade de biomassa da parte aérea de trigo. O emprego da maior dose de N em pré-semeadura proporcionou maior teor foliar de N e maior produtividade de biomassa da parte aérea durante todo o desenvolvimento da cultura do trigo.

Os dados gerados pelas plataformas de SR terrestre (sensor ótico ativo *GREENSEEKER*), orbital (satélites *RAPIDEYE*) e aéreo (RPA *EBEE*) se correlacionaram com a produtividade de biomassa da parte aérea e a concentração de N nas folhas de trigo.

A plataforma aérea de SR (RPA *EBEE*) apresentou melhores resultados do que a terrestre (sensor ótico ativo *GREENSEEKER*) e a orbital (satélites *RAPIDEYE*), proporcionando estreitas correlações com a produtividade de biomassa da parte aérea e a concentração de N nas folhas de trigo, considerando a variabilidade de todas as amostras avaliadas. A RPA *EBEE* demonstrou maior capacidade de identificar alterações provocadas pela espacialidade dentro de um mesmo tratamento. Quando a variabilidade foi diminuída por meio da análise das médias dos tratamentos, as plataformas aérea (RPA *EBEE*) e orbital (satélites *RAPIDEYE*) obtiveram os resultados semelhantes na estimativa de biomassa da parte aérea e de concentração de N nas folhas de trigo.

A SVR apresentou resultados superiores aos do modelo clássico de regressão linear, com grande diferença em algumas tarefas. Os resultados da SVR ainda podem ser melhorados, observando que neste trabalho os parâmetros do *Kernel* foram deixados em seus valores padrão, não sendo otimizados, o que poderia acarretar em melhores resultados.

Os resultados obtidos com as bandas e IVs, gerados pelo sensor ótico *GREENSEEKER*, não apresentaram diferença expressiva, com isso o uso da NDVI tornou-se mais vantajoso, por ter um atributo na criação dos modelos preditivos. Entre os resultados observados com os IVs NDVI e NDRE provenientes dos satélites *RAPIDEYE*, o NDVI proporcionou melhores correlações sobre o NDRE, demonstrando ser o mais indicado na geração de modelos de estimativa de biomassa e concentração de N foliar do trigo. Os IVs gerados com os dados adquiridos com a RPA *EBEE* proporcionaram resultados inferiores aos alcançados com as bandas cruas, demonstrando que para análises dessa natureza (estimativas de biomassa e concentração foliar de N) com RPA seria mais apropriado utilizar os valores crus das bandas do que os IVs.

Entre os resultados obtidos com o sensor *GREENSEEKER*, sem considerar a altura da planta, os dados gerados no florescimento obtiveram os melhores coeficientes na estimativa de

biomassa em ambas as divisões, por amostras e tratamentos. Para a estimativa da concentração de N, nas divisões por amostras não foi observado diferença expressiva entre os resultados e na divisão por tratamentos o emborrachamento demonstrou resultados superiores. Nos satélites *RAPIDEYE* para estimar a biomassa os dados gerados no estágio de perfilhamento obtiveram melhores resultados para a divisão por amostras e o florescimento foi o mais expressivo para os tratamentos. Na estimativa de concentração foliar de N os dados gerados no estágio fenológico do florescimento obtiveram os melhores resultados em ambas as abordagens, tratamentos e amostras. Para a RPA, na estimativa de biomassa, os dados gerados no perfilhamento atingiram o melhor resultado na divisão por amostras e os resultados obtidos no florescimento foram mais expressivos na divisão por tratamentos. Na concentração de N foliar os dados gerados no estágio fenológico do florescimento foram os mais expressivos em ambas as abordagens, por amostras e tratamentos.

REFERÊNCIAS

- AFEK, Y.; BRAND, A. Mosaicking of orthorectified aerial images. **Photogrammetric Engineering and Remote Sensing**, v. 64, n. 2, p. 115–125, 1998.
- AFIFI, A. A.; AZEN, S. P. **Statistical Analysis. A Computer Oriented Approach**. 1. ed. Califórnia: Elsevier Inc, Academic Press Inc, 1972.
- AGÜERA, F.; CARVAJAL, F.; PÉREZ, M. Measuring Sunflower Nitrogen Status From an Unmanned Aerial Vehicle-Based System and an on the Ground Device. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVIII-1/, p. 33–37, 2012.
- ALI, A. M. et al. Prediction of dry direct-seeded rice yields using chlorophyll meter, leaf color chart and GreenSeeker optical sensor in northwestern India. **Field Crops Research**, v. 161, p. 11–15, 2014.
- ALI, A. M. et al. A framework for refining nitrogen management in dry direct-seeded rice using GreenSeeker optical sensor. **Computers and Electronics in Agriculture**, v. 110, p. 114–120, 2015.
- ANTUNES, M. A. H.; DEBIASI, P.; SIQUEIRA, J. C. DOS S. Avaliação espectral e geométrica das imagens Rapideye e seu potencial para o mapeamento e monitoramento agrícola e ambiental. **Revista Brasileira de Cartografia**, v. 66, n. 1, p. 105–113, 2014.
- ATZBERGER, C. **Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs** Remote Sensing, 2013.
- BALABIN, R. M.; LOMAKINA, E. I. Support vector machine regression (SVR/LS-SVM)—an alternative to neural networks (ANN) for analytical chemistry? Comparison of nonlinear methods on near infrared (NIR) spectroscopy data. **The Royal Society of Chemistry**, v. 136, p. 1703–1712, 2011.
- BARRETT, E. C. **Introduction to environmental remote sensing**. 1. ed. [s.l.] John Wiley & Sons, 1978. v. 3
- BASAK, D.; PAL, S.; PATRANABIS, D. C. Support Vector Regression. **Neuronal Information Processing - Letters and Reviews**, v. 11, n. 10, p. 203–224, 2007.
- BENDIG, J. et al. Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. **Remote Sensing**, v. 6, n. 11, p. 10395–10412, 2014.
- BENDIG, J. et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79–87, 2015.
- BERNI, J. A. J. et al. Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring From an Unmanned Aerial Vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, 2009.
- BREDEMEIER, C. et al. Estimativa do potencial produtivo em trigo utilizando sensor óptico ativo para adubação nitrogenada em taxa variável. **Ciência Rural**, v. 43, n. 7, p. 1147–1154,

2013.

CAMPBELL, J. B.; WYNNE., R. H. **Introduction to Remote Sensing**. 5^a ed. New York: Guilford Press, 2011. v. XXXIII

CAO, Q. et al. Non-destructive estimation of rice plant nitrogen status with Crop Circle multispectral active canopy sensor. **Field Crops Research**, v. 154, p. 133–144, 2013.

CARLSON, T. N.; RIPLEY, D. A. On the relation between NDVI, fractional vegetation cover, and leaf area index. **Remote sensing of Environment**, v. 62, n. 3, p. 241–252, 1997.

CHANG, A. et al. Crop height monitoring with digital imagery from Unmanned Aerial System (UAS). **Computers and Electronics in Agriculture**, v. 141, p. 232–237, 2017.

CHANG, C.; LIN, C. LIBSVM : A Library for Support Vector Machines. **ACM Transactions on Intelligent Systems and Technology (TIST)**, v. 2, p. 1–39, 2011.

CHÁVEZ, P. S. J. Image-based atmospheric corrections - revisited and improved. **Photogrammetric Engineering and Remote Sensing**, v. 62, n. 9, p. 1025–1036, 1996.

COLLOBERT, R.; WILLIAMSON, R. C. SVMtorch: Support Vector Machines for Large-Scale Regression Problems. **Journal of Machine Learning Research**, v. 1, p. 143–160, 2001.

COLOMINA, I.; MOLINA, P. **Unmanned aerial systems for photogrammetry and remote sensing: A review** ISPRS Journal of Photogrammetry and Remote Sensing, 2014.

COLWELL, J. E. Vegetation canopy reflectance. **Remote Sensing of Environment**, v. 3, n. 3, p. 175–183, 1974.

COLWELL, R. N. Determining the prevalence of certain cereal crop diseases by means of aerial photography. **Hilgardia**, v. 26, n. 5, p. 223–286, nov. 1956.

DE AGUIAR, C. R.; CAMARGO, P. D. O. MODELAGEM EM TEMPO REAL DO ERRO SISTEMÁTICO DAS OBSERVÁVEIS GPS DEVIDO À IONOSFERA. **Boletim de Ciencias Geodesicas**, v. 12, n. 1, p. 101–120, 2006.

DENUIT, J.-P. et al. Management of nitrogen fertilization of winter wheat and potato crops using the chlorophyll meter for crop nitrogen status assessment. **Agronomie**, v. 22, n. 7–8, p. 847–853, 2002.

DIMITRIADOU, E. et al. **Package ‘e1071’ R Software package, available at <http://cran.rproject.org/web/packages/e1071/index.html>**. Viena. Disponível em: <<https://cran.r-project.org/web/packages/e1071/e1071.pdf>>.

DU, Y.; TEILLET, P. M.; CIHLAR, J. Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection. **Remote Sensing of Environment**, v. 82, n. 1, p. 123–134, 2002.

EITEL, J. U. H. et al. Using in-situ measurements to evaluate the new RapidEyeTM satellite series for prediction of wheat nitrogen status. **International Journal of Remote Sensing**, v. 28, n. 18, p. 4183–4190, 2007.

EL HAJJ, M. et al. Relative radiometric normalization and atmospheric correction of a SPOT 5 time series. **Sensors**, v. 8, n. 4, p. 2774–2791, 2008.

ERDLE, K.; MISTELE, B.; SCHMIDHALTER, U. Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. **Field Crops Research**, v. 124, n. 1, p. 74–84, 2011.

FISCHER, W. A.; HEMPHILL, W. R.; KOVER, A. Progress in remote sensing (1972-1976). **Photogrammetria**, v. 32, n. 2, p. 33–72, 1976.

FRITSCH, S. et al. Validation of the collection 5 MODIS FPAR product in a heterogeneous agricultural landscape in arid Uzbekistan using multitemporal RapidEye imagery. **International Journal of Remote Sensing**, v. 33, n. 21, p. 6818–6837, 10 nov. 2012.

FRITZ, S.; WEXLER, H. CLOUD PICTURES FROM SATELLITE TIROS I. **Monthly Weather Review**, v. 88, n. 3, p. 79–87, 1960.

GALVÃO, L. S. et al. Efeitos da Geometria de Visada sobre a Determinação de Índices de Vegetação. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 10, p. 1403–1409, 2001.

GNYP, M. L. et al. Development and implementation of a multiscale biomass model using hyperspectral vegetation indices for winter wheat in the North China Plain. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, p. 232–242, 2014.

GÓMEZ-CANDÓN, D.; DE CASTRO, A. I.; LÓPEZ-GRANADOS, F. Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. **Precision Agriculture**, v. 15, n. 1, p. 44–56, 2014.

GROHS, D. S. et al. Modelo para estimativa do potencial produtivo em trigo e cevada por meio do sensor GreenSeeker. **Engenharia Agrícola**, v. 29, n. 1, p. 101–112, 2009.

GUO, Y. et al. Time Series Prediction Method Based on LS-SVR with Modified Gaussian RBF. **ICONIP 2012, Part II LNCS**, v. 7664, p. 9–17, 2012.

HATFIELD, J. L.; ASRAR, G.; KANEMASU, E. T. Intercepted photosynthetically active radiation estimated by spectral reflectance. **Remote Sensing of Environment**, v. 14, n. 1–3, p. 65–75, 1984.

HERWITZ, S. R. et al. Imaging from an unmanned aerial vehicle: Agricultural surveillance and decision support. **Computers and Electronics in Agriculture**, v. 44, n. 1, p. 49–61, 2004.

HONG, S. D. et al. Comparison of ground-based remote sensors for evaluation of corn biomass affected by nitrogen stress. **Communications in Soil Science and Plant Analysis**, v. 38, n. 15–16, p. 2209–2226, 2007.

HONKAVAARA, E. et al. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, v. 5, n. 10, p. 5006–5039, 2013.

HUANG, H.-Y.; LIN, C.-J. Linear and Kernel Classification: When to Use Which? **Proceedings of the 2016 SIAM International Conference on Data Mining**, p. 216–224, 2016.

HUETE, A. A soil-adjusted vegetation index. **Remote Sensing of Environment**, 1988.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective**. 2. ed. Pearson Education Limited, 2013. v. 1.

JORGE, L. A. DE C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. **Agricultura de Precisão. Resultados de um Novo Olhar.**, Embrapa, 2014.

KAIVOSOJA, J. et al. **A case study of a precision fertilizer application task generation for wheat based on classified hyperspectral data from UAV combined with farm history data**. SPIE Remote Sensing. **Anais...**2013.

KAPP, J. C.; CAIRES, E. F.; GUIMARÃES, A. M. Discriminating Biomass and Nitrogen Status in Wheat Crop by Spectral Reflectance Using Artificial Neural Networks. **International Journal of Agricultural and Environmental Information Systems**, v. 5, n. 2, p. 38–49, 2014.

KAPP, J. C.; GUIMARÃES, A. M.; CAIRES, E. F. Use of active canopy sensors to discriminate wheat response to nitrogen fertilization under no-tillage. **Engenharia Agrícola**, v. 36, n. 5, p. 886–894, 2016.

KELCEY, J.; LUCIEER, A. Sensor Correction and Radiometric Calibration of a 6-Band Multispectral Imaging Sensor for Uav Remote Sensing. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXIX-B1, n. September, p. 393–398, 2012.

KIALA, Z. et al. Comparison of partial least squares and support vector regressions for predicting leaf area index on a tropical grassland using hyperspectral data. **Journal of Applied Remote Sensing**, v. 10, n. 3, p. 36015, 2016.

KROSS, A. et al. 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, n. 1, p. 235–248, 2015.

L. DE SOUZA, D. et al. Fault Detection and Diagnosis Using Support Vector Machines - A SVC and SVR Comparison. **Journal of Safety Engineering**, v. 3, n. 1, p. 18–29, 2014.

LANGHI, P.; GARCIA, A. M. Correção radiométrica de imagens aéreas digitais por meio de ajuste polinomial. **II Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, p. 0, 2008.

LELONG, C. C. D. et al. Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots. **Sensors**, v. 8, n. 5, p. 3557–3585, 2008.

LI, Q. et al. County-level rice area estimation in southern China using remote sensing data. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 083657, 2014.

LI, Y. et al. Hyper-spectral estimation of wheat biomass after alleviating of soil effects on spectra by non-negative matrix factorization. **European Journal of Agronomy**, v. 84, p. 58–66, 2017.

LIBA, N.; BERG-JÜRGENS, J. Accuracy of Orthomosaic Generated by Different Methods in

Example of UAV Platform MUST Q. **IOP Conference Series: Materials Science and Engineering**, v. 96, p. 012041, 2015.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 7. ed. John Wiley & Sons, 2014. v. 1

MALAVOLTA, E. **Avaliação do estado nutricional das plantas: princípios e aplicações**. 2. ed. Piracicaba: Potáfos, 1997.

MENESES, P. R. et al. INTRODUÇÃO AO PROCESSAMENTO DE IMAGENS DE SENSORIAMENTO REMOTO. **Embrapa Cerrados-Livros técnicos**, v. 1, p. 276, 2012.

MERCANTE, E. et al. Modelos de regressão lineares para estimativa de produtividade da soja no Oeste do Paraná, utilizando dados espectrais. **Engenharia Agrícola**, 2010.

MESAS-CARRASCOSA, F.-J. et al. Assessing Optimal Flight Parameters for Generating Accurate Multispectral Orthomosaicks by UAV to Support Site-Specific Crop Management. **Remote Sensing**, v. 7, n. 10, p. 12793–12814, 2015.

MEYER, D. et al. **Misc functions of the Department of Statistics (e1071), TU Wien R package version 1.6-2**, 2014. Disponível em: <<http://hosho.ees.hokudai.ac.jp/~kubo/Rdoc/library/e1071/html/00Index.html>>

MORAN, M. S. et al. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. **Remote Sensing of Environment**, v. 49, n. 3, p. 246–263, 1994.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **{ISPRS} Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247–259, 2011.

MUCHERINO, A.; PAPAJORGJI, P. J.; PARDALOS, P. M. **Data mining in agriculture**. [s.l.] Springer Science & Business Media, 2009. v. 34

MYNENI, R. B. et al. Interpretation of spectral vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 481–486, 1995.

OERKE, E.-C. et al. **Precision Crop Protection-The challenge and use of heterogeneity**. [s.l.] Springer, 2010. v. 5

PERIN, G. et al. Análise de Acurácia de Georreferenciamento de Mosaicos de Imagens Obtidas por RPA. **Anais do EATI - Encontro Anual de Tecnologia da Informação e STIN – Simpósio de Tecnologia da Informação da Região Noroeste do RS 193**, p. 193–199, 2016.

PIX4D. **Pix4D Software Manual**. Disponível em: <<https://support.pix4d.com/hc/en-us/articles/204272989-Offline-Getting-Started-and-Manual-pdf-#gsc.tab=0>>.

POLIDORIO, A. M. et al. Correção Radiométrica de imagens multiespectrais CBERS e Landsat ETM usando atributos de reflectância e de cor. **Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, v. 12, p. 4241–4248, 2005.

PÖLÖNEN, I. et al. **Hyperspectral imaging based biomass and nitrogen content estimations from light-weight UAV**. SPIE Remote Sensing. **Anais...**2013

QI, J. et al. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119–126, 1994.

R CORE TEAM. **R Core TeamR: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org/>, 2015. Disponível em: <<http://www.mendeley.com/research/r-language-environment-statistical-computing-96/%255Cnpapers2://publication/uuid/A1207DAB-22D3-4A04-82FB-D4DD5AD57C28>>

RAY, A. S. Remote Sensing in Agriculture. **International Journal of Environment, Agriculture and Biotechnology**, v. 1, n. 3, p. 2456–1878, 2016.

RIZZI, R.; RUDORFF, B. F. T. Estimativa da área de soja no rio grande do sul por meio de imagens landsat. **Revista Brasileira de Cartografia**, v. 57, n. 3, p. 226–234, 2005.

RONDEAUX, G. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95–107, 1996.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95–107, 1996.

ROUSE et al. Monitoring vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351, p. 309, 1974.

ROUSE, J. W. et al. Monitoring Vegetation Systems in the Great Okains with ERTS. **Third Earth Resources Technology Satellite-1 Symposium**, v. 1, p. 325–333, 1973.

SCHÖLKOPF, B. et al. Comparing support vector machines with gaussian kernels to radial basis function classifiers. **IEEE Transactions on Signal Processing**, v. 45, n. 11, p. 2758–2765, 1997.

SCHUSTER, C.; FÖRSTER, M.; KLEINSCHMIT, B. Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5583–5599, 2012.

SEELAN, S. K. et al. **Remote sensing applications for precision agriculture: A learning community approach** **Remote Sensing of Environment**, 2003.

SERRANO, L.; FILELLA, I.; PENUELAS, J. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. **Crop Science**, v. 40, n. 3, p. 723–731, 2000.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. **Introduction to data mining**. 2. ed. Minnesota: Pearson Education, 2006.

TILLY, N. et al. Multitemporal crop surface models: accurate plant height measurement and biomass estimation with terrestrial laser scanning in paddy rice. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 83671, 2014.

TYC, G. et al. **The RapidEye mission design**. Acta Astronautica. **Anais...**2005

VAPNIK, V. **Estimation of dependences based on empirical data**. 1982. ed. New York: Springer Science & Business Media, 2006.

- VAPNIK, V. N. The Nature of Statistical Learning Theory. **Springer**, v. 8, n. 6, p. 187, 1995.
- VEGA, F. A. et al. Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. **Biosystems Engineering**, v. 132, p. 19–27, 2015.
- VIZZOTTO, E. C. C. et al. Desempenho de algoritmos de classificação supervisionada para imagens dos satélites RapidEye. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, v. 1, p. 6, 2013.
- WANG, Y. et al. Estimating nitrogen status of rice using the image segmentation of G-R thresholding method. **Field Crops Research**, v. 149, p. 33–39, 2013.
- WITTEN, I. H.; FRANK, E. **Data Mining: Practical machine learning tools and techniques**. 3. ed. Boston: Morgan Kaufmann, 2005.
- WOLFF, W. M.; FLOSS, E. L. Correlação entre teores de nitrogênio e de clorofila na folha com o rendimento de grãos de aveia branca. **Ciência Rural**, v. 38, n. 6, p. 1510–1515, 2008.
- WU, C.-H.; TZENG, G.-H.; LIN, R.-H. A Novel hybrid genetic algorithm for kernel function and parameter optimization in support vector regression. **Expert Systems with Applications**, v. 36, n. 3, p. 4725–4735, 2009.
- YANG, C. A high-resolution airborne four-camera imaging system for agricultural remote sensing. **Computers and Electronics in Agriculture**, v. 88, p. 13–24, 1 out. 2012.
- YANG, X.; LO, C. P. Relative radiometric normalization performance for change detection from multi-date satellite images. **Photogrammetric Engineering and Remote Sensing**, v. 66, n. August, p. 967–980, 2000.
- ZHU, J. et al. **Quantifying nitrogen status of rice using low altitude UAV-mounted system and object-oriented segmentation methodology**. ASME 2009 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference. **Anais...**2009.