

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

ESTIMATIVA DO ÍNDICE DE SEVERIDADE DE FERRUGEM ASIÁTICA NA
CULTURA DA SOJA POR MEIO DE IMAGENS OBTIDAS COM AERONAVE
REMOTAMENTE PILOTADA

VICTOR SCHNEPPER LACERDA

PONTA GROSSA
2016

VICTOR SCHNEPPER LACERDA

ESTIMATIVA DO ÍNDICE DE SEVERIDADE DE FERRUGEM ASIÁTICA NA
CULTURA DA SOJA POR MEIO DE IMAGENS OBTIDAS COM AERONAVE
REMOTAMENTE PILOTADA

Dissertação apresentada ao Programa de
Pós-Graduação em Computação Aplicada
Universidade Estadual de Ponta Grossa,
como requisito parcial para obtenção do
título de Mestre.

Orientação: Prof. Dr. Marcelo Giovanetti
Canteri

Coorientação: Prof.^a Dr.^a Alaine Margarete
Guimarães

PONTA GROSSA
2016

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

L131 Lacerda, Victor Schnepper
 Estimativa do índice de severidade de
 ferrugem asiática na cultura da soja por
 meio de imagens obtidas com aeronave
 remotamente pilotada/ Victor Schnepper
 Lacerda. Ponta Grossa, 2016.
 60f.

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

 Orientador: Prof. Dr. Marcelo
Giovanetti Canteri.

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

 1.Veículos aéreos não tripulados.
2.Drone. 3.Sensoriamento remoto.
4.Processamento digital de imagens.
5.Mineração de dados. I.Canteri, Marcelo
Giovanetti. II. Guimarães, Elaine
Margarete. III. Universidade Estadual de
Ponta Grossa. Mestrado em Computação

CDD: 006.3


TERMO DE APROVAÇÃO


Victor Schnepfer Lacerda


**“ESTIMATIVA DO ÍNDICE DE SEVERIDADE DE FERRUGEM
ASIÁTICA NA CULTURA DA SOJA POR MEIO DE IMAGENS OBTIDAS
COM AERONAVE REMOTAMENTE PILOTADA”.**

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:

Orientador:


Dr. Marcelo Giovanetti Canferi
UEL


Dr.ª Maristella Dalla Pria
UEPG


Dr. José Eduardo Gonçalves
SIMEPAR

Ponta Grossa, 02 de fevereiro de 2017.

“Há poesia real no mundo real. A ciência é a poesia da realidade.”
Richard Dawkins

AGRADECIMENTOS

Agradeço primeiramente a meus pais e minha irmã pelo apoio incondicional, não somente durante o mestrado mas como em todos os períodos importantes da minha vida.

Ao meu orientador Prof. Dr. Marcelo Giovanetti Canteri e em especial a minha coorientadora Prof^a. Dr^a. Alaine Margarete Guimarães, a quem tenho grande estima por toda ajuda durante o mestrado e também pelo seu exemplo como pessoa.

A Gislaine Gabardo por disponibilizar os dados da sua tese de doutorado, me ajudar com a parte agrônômica da minha dissertação e também por ter monitorado a área acompanhada.

Ao meu colega e amigo Rayson Laroca, pelas manhãs ensolaradas em que fizemos o acompanhamento da área e por todo empenho e dedicação colocados nessa pesquisa.

Ao meu colega e amigo Tiago Gerke pela colaboração nesse projeto, principalmente na área de processamento e extração de dados das imagens.

A todos os meus colegas do laboratório InfoAgro pela contribuição nos projetos realizados e momentos divididos, especialmente aos meus amigos Luiz, Gustavo, Jackson, Pablo, Alessandro, David Viniski e David Zampier.

Aos meus amigos de longa data Matheus, Cedulio e Wellington pela amizade e ajuda em diversos momentos.

Agradeço à CAPES pelo apoio financeiro e pela disponibilização de artigos por meio do portal de periódicos, tornando possível a realização desse trabalho.

RESUMO

O cultivo da soja (*Glycine max*) é importante para a economia brasileira, sendo que um dos principais obstáculos à alta produtividade na lavoura é a ferrugem asiática, causada pelo fungo *Phakopsora pachyrhizi*.

O principal fator para o controle de danos causados por essa doença é a aplicação de fungicidas em momento apropriado, porém o maior obstáculo para uso dessa medida é a difícil detecção da ferrugem asiática em estágios iniciais.

Nesse sentido, o sensoriamento remoto aliado ao uso de veículos aéreos remotamente pilotados apresenta potencial para detecção da doença, principalmente por fornecer informação de difícil acesso aos meios tradicionais e pelas vantagens de qualidade e custo dessa tecnologia.

O presente trabalho explora o uso de veículos aéreos remotamente pilotados para detecção e predição de severidade da ferrugem asiática da soja, associados a técnicas de processamento digital de imagens e de mineração de dados, visando a obtenção de modelos preditivos de severidade nos diferentes estágios de desenvolvimento da soja.

Os modelos obtidos demonstraram potencial para a detecção da ferrugem asiática, e uma boa correlação da severidade da doença com o espectro visível (câmera RGB), ao passo que foi possível obter coeficientes de correlação maiores que 93% utilizando o algoritmo SMOREG após o estágio R5 de desenvolvimento da cultura da soja.

Palavras-chave: Veículos aéreos não tripulados, drone, sensoriamento remoto, processamento digital de imagens, mineração de dados.

ABSTRACT

Soybean cultivation is of great importance to the Brazilian economy, and one of the major obstacles to its high productivity is the Asian soybean rust, a disease caused by the fungus *Phakopsora pachyrhizi*.

The main measure to control the damage caused by this disease is the application of fungicides at the appropriate time, but the biggest obstacle to its implementation is the difficult detection of Asian rust in its early stages.

In this sense, remote sensing combined with the use of unmanned aerial vehicles (UAVs) has potential for disease detection, especially for providing information that is hard to assess by traditional means, and for the advantages of quality and cost of this technology.

The present work explores the use of unmanned aerial vehicles to detect and predict the severity of Asian soybean rust by use of digital image processing and data mining techniques for retrieval of predictive models of severity in different development stages.

The models obtained showed satisfactory potential for Asian rust detection, and a high correlation between disease severity and the visible spectrum (RGB camera), as it was possible to obtain correlation coefficients greater than 93% after the R5 development stage of the soybean crop.

Keywords: Unmanned aerial vehicles, Drone, Remote sensing, Digital image processing, Data Mining.

LISTA DE FIGURAS

Figura 1 - Sintomas / sinais da ferrugem asiática em folíolos de soja.....	13
Figura 2 - Desfolha causada pela ferrugem asiática da soja em plantas da parcela testemunha (sem a aplicação de fungicida)	14
Figura 3 - Escala diagramática de severidade da ferrugem asiática da soja (<i>Glycine max</i>)	16
Figura 4 - Espectro eletromagnético.....	21
Figura 5 - Resultados da classificação de folhas de beterraba inoculadas com os diferentes patógenos dependendo da severidade da doença.....	27
Figura 6 – Imagem do local de realização do experimento para controle da ferrugem asiática da soja na safra 2015/2016 na fazenda escola da Universidade estadual de Ponta Grossa	30
Figura 7 – Equipamento RPA eBee utilizado nos voos da cultura da soja (<i>Glycine max</i>) Ponta Grossa – PR, 2016	33
Figura 8 - Câmeras utilizadas nos voos da cultura da soja (<i>Glycine max</i>) Ponta Grossa – PR, 2016; (a) Sony Cyber-shot WX RGB (b) Canon S110 NIR.....	33
Figura 9 - Comprimentos de onda filtrados pelas câmeras RGB e NIR.....	34
Figura 10 - Marcador GCP utilizado no estudo de georreferenciamento.....	36
Figura 11– GPS Trimble R4. (a) Disposição dos GCPs na área do estudo de georreferenciamento (b)	37
Figura 12 - Demonstração do erro de georreferenciamento (tratamento PIX0).....	39
Figura 13 - Comparação entre os ortomosaicos e os mapas de reflectância gerados pelo PIX4D. Mosaico RGB (a), Mapa de reflectância RGB (b), Mosaico NIR (c), Mapa de reflectância (d).....	41
Figura 14 - Pontos utilizados para a correção geométrica.....	43
Figura 15 - Polígonos definidos para representação de cada parcela	44

LISTA DE TABELAS

Tabela 1 - Comparação de resolução espacial entre satélites	18
Tabela 2 - Datas de realização de voos na área experimental e câmeras utilizadas	31
Tabela 3 - Datas de medição da severidade da ferrugem asiática na área experimental com cultura da soja na fazenda escola da Universidade Estadual de Ponta Grossa	32
Tabela 4 - Relação de datas de coleta para criação das bases de dados	32
Tabela 5 - Distâncias dos GCPs em relação a coordenada exata, em metros (m) e RMSE para cada mosaico	39
Tabela 6 - Resultados do Teste de Tukey 5% para os diferentes tratamentos	39
Tabela 7 - Distância dos pontos em relação a base após a imagem ser corrigida geometricamente	43
Tabela 8 - Relação entre área e número de pontos por parcela para os blocos 1 e 2 da área experimental	45
Tabela 9 - Coeficientes de correlação entre as bandas e o NDVI com a severidade da ferrugem asiática da soja para o algoritmo SMOREG	47
Tabela 10 - Equações onde a correlação foi maior que 0,9 para o algoritmo SMOREG	49
Tabela 11 - Coeficientes de correlação entre as bandas e o NDVI com a severidade da ferrugem asiática da soja para o algoritmo M5Rules	50
Tabela 12 - Duas primeiras regras do modelo da base de 20% para o algoritmo M5Rules	51

SUMÁRIO

1. INTRODUÇÃO.....	10
1.1. Objetivos gerais	11
1.2. Objetivos específicos	11
1.3. Estrutura do trabalho.....	11
2. REVISÃO DE LITERATURA	12
2.1. Importância econômica da cultura da soja.....	12
2.2. Ferrugem asiática da soja.....	13
2.3. Fitopatometria	15
2.4. Sensoriamento remoto	16
2.5. Processamento digital de imagens e índices de vegetação	20
2.6. Correção radiométrica.....	23
2.7. Mineração de dados	25
3. MATERIAIS E MÉTODOS.....	29
3.1. Área experimental e planejamento das missões de voo.....	29
3.2. Descrição do equipamento utilizado.....	32
3.3. Georreferenciamento das imagens obtidas	35
3.4. Pós-processamento das imagens coletadas, geração do mapa de reflectância e correções	40
3.5. Extração e criação das bases de dados	44
3.6. Mineração dos dados extraídos das imagens	46
4. RESULTADOS E DISCUSSÃO	47
4.1. Mineração de dados e criação dos modelos preditivos.....	47
5. CONCLUSÃO	54
REFERÊNCIAS	55

1. INTRODUÇÃO

Um dos obstáculos para alta produtividade na cultura da soja (*Glycine max* L. Merrill) é a ferrugem asiática, doença causada pelo fungo *Phakopsora pachyrhizi* Syd. & P. Syd., sendo a rápida propagação um dos fatores mais preocupantes sobre essa doença. A constatação dos primeiros sintomas torna-se indispensável o controle da doença, prática que demanda o suporte de um especialista e uso de métodos de estimativa de severidade para avaliar os danos à cultura.

O desenvolvimento tecnológico recente na área de sensoriamento remoto oferece alternativas para facilitar o processo de quantificação de danos na cultura da soja, além de oferecer baixo custo financeiro e operacional. Esses avanços, que englobam tanto os sensores como também os equipamentos onde os mesmos são acoplados, resultam da popularização de ferramentas e equipamentos como as aeronaves remotamente pilotadas (RPAs – do inglês *remotely piloted aircraft*), também conhecidas como VANT (veículo aéreo não tripulado) ou drone (zangão em inglês). A denominação RPA para esses equipamentos foi adotada a partir de novembro de 2015, de acordo com a nova regulamentação do Departamento de Controle do Espaço Aéreo (DECEA) e a Instrução do Comando da Aeronáutica (ICA) 100-40 (DECEA, 2015).

O uso de RPAs na agricultura tem sido um amplo campo de pesquisa para as mais diversas finalidades, como o processamento de imagens digitais e índices de vegetação para monitoramento do desenvolvimento de culturas (CARLSON; RIPLEY, 1997; BERNI et al., 2009; CALDERÓN et al., 2013; CÓRCOLES et al., 2013; GARCIA-RUIZ et al., 2013; KOGA; CANTERI; GODOY, 2007; MYNENI, 1995; ZARCO-TEJADA et al., 2013; SUGIURA et al., 2016).

Bandas espectrais e índices de vegetação são utilizados amplamente dentro da agricultura para estimativa do estado fisiológico de plantas, devido aos avanços em estudos de sensoriamento remoto. Assim possuem potencial para estimativa de doenças.

O uso dos índices de vegetação obtidos por imagens de satélite e aviões é uma prática comum, entretanto o uso de RPAs permite aplicações em um nível diferente, principalmente pelas vantagens em relação a alta resolução espacial, menor custo financeiro, baixa resolução temporal e customização de equipamento.

Em face dos fatos apresentados, a possibilidade do uso de sensoriamento remoto acoplado a RPAs pode ser viável para facilitar a quantificação de severidade da ferrugem asiática da soja.

1.1. Objetivos gerais

O objetivo geral deste trabalho é construir um modelo para estimativa de severidade da ferrugem asiática da soja a partir de dados de imagens obtidas por RPAs.

1.2. Objetivos específicos

- Processar as imagens obtidas por RPA para correção de erros, extração de valores de reflectância e cálculo de índice de vegetação.
- Analisar correlações entre os índices de vegetação escolhidos para o trabalho e os diferentes níveis de severidade da doença produzidos nas áreas experimentais, visando estimar a severidade da doença mediante imagens.

1.3. Estrutura do trabalho

A seção 2 descreve a revisão de literatura, demonstrando a importância da cultura da soja, o impacto da ferrugem asiática na produtividade dessa cultura, o procedimento de medição de danos causados pela doença, as aplicações de RPAs na agricultura para detecção de doenças, o método de processamento digital de imagens aéreas, correções radiométricas e conceitos de mineração de dados.

A seção 3 descreve os materiais e métodos utilizados para o desenvolvimento do trabalho, sendo dividido em 6 subseções. A primeira e a segunda seções descrevem, respectivamente, a área experimental acompanhada e o equipamento utilizado, a terceira apresenta um estudo realizado sobre o georreferenciamento das imagens fornecidas pelo equipamento, a quarta descreve o tipo de correção radiométrica utilizado, a quinta descreve o processo de criação das bases de dados e a sexta descreve os algoritmos de mineração de dados utilizados.

Os resultados obtidos e discussões são expostos na seção 4, que descreve os modelos obtidos através das técnicas de mineração de dados utilizadas.

Na seção 5 são descritas as conclusões do trabalho.

2. REVISÃO DE LITERATURA

2.1. Importância econômica da cultura da soja

A soja, *Glycine max* (L.) Merrill, é uma leguminosa anual da família *Fabaceae*, e constitui um dos principais cultivos da agricultura mundial. É, também, considerada o grão de maior importância econômica no mundo, devido ao seu potencial produtivo, composição química, e valor nutritivo. Possui várias aplicações na alimentação humana e animal, com relevante papel socioeconômico, além de ser matéria-prima indispensável para impulsionar diversos complexos agroindustriais (STRECK et al. 2008; MAUD et al. 2010; MAPA, 2014).

A produção mundial de soja para o ano de 2016 foi estimada em torno de 333,22 milhões de toneladas. O maior produtor de soja no mundo são os Estados Unidos, com uma produção de 116,18 milhões de toneladas, sendo o Brasil o segundo maior produtor desta oleaginosa com uma produção de 102 milhões de toneladas (USDA, 2016).

Estima-se que a área plantada no Brasil em 2016 foi de 58,5 milhões de hectares, dos quais a soja é responsável por 56,8% da produção total de grãos. Na safra 2016/2017 foi plantada uma área de aproximadamente 33,9 milhões de há, e haverá uma produção em torno de 102,5 milhões de toneladas de soja. Dentro do país, o Estado com maior área de soja plantada e maior perspectiva de produção é o estado do Mato Grosso, com 9,2 milhões de ha e 28,8 milhões de toneladas, respectivamente (CONAB, 2016).

Com o passar dos anos, é possível observar a crescente participação do Brasil no complexo mundial de soja, devida ao aumento de sua produtividade em todo o país. Porém, para manter ou aumentar a produtividade é necessário o manejo de doenças, um dos principais fatores limitantes para incremento na produtividade (YORINORI, 2006).

Atualmente, aproximadamente 40 doenças causadas por fungos, bactérias, nematóides e vírus já foram identificadas no Brasil. Os danos anuais de produção são estimados entre 15 a 20%, entretanto, algumas doenças podem causar quase 100% de dano (HENNING et al. 2014), e entre elas está a ferrugem asiática (*Phakospora pachyrhizi* Syd. & P. Syd.), a principal doença da cultura da soja, que causa desfolha antecipada da cultura acarretando em danos consideráveis de rendimento (HARTMAN; WANG; SHANMUGASUNDARAM, 1994; EMBRAPA 2016).

2.2. Ferrugem asiática da soja

O agente causal da ferrugem asiática é o fungo *P. pachyrhizi*, que está presente na maioria dos países que cultivam soja. O fungo foi detectado no Brasil e Paraguai a partir da safra 2000/2001. Após o primeiro aparecimento no Paraguai e no Estado do Paraná, a ferrugem asiática se espalhou rapidamente por todas as regiões produtoras do Brasil, Paraguai, Bolívia e partes da Argentina, representando grande ameaça para os países do continente americano. No Brasil, observa-se a incidência dessa doença em lavouras de soja cada vez mais precocemente (YORINORI, 2006).

O fungo é um Basidiomycota da ordem Uredinales, é um parasita obrigatório (não consegue viver independentemente do seu hospedeiro), e forma micélio intercelular. Os uredósporos atacam o tecido vegetal pela formação de apressório e se nutrem dos tecidos das plantas por meio de haustórios (PUTZEK: PUTZEK, 1998). A doença é classificada como policíclica, pois o patógeno completa vários ciclos durante o desenvolvimento da cultura (BALARDIN et al., 2006). A disseminação dos esporos ocorre pelo vento e o ciclo tem duração entre seis e sete dias, realizando diversos ciclos durante o ciclo da cultura (YORINORI, 2006).

Os sintomas causados pela ferrugem da soja são denominados de “lesões”, e não de pústulas, como nas demais ferrugens, porque ocorre a necrose do tecido foliar e cada lesão pode apresentar várias pústulas (Figura 1). O tamanho das lesões é em torno de 0,5 mm e tende a aumentar e escurecer à medida que envelhecem (REIS; BRESOLIN; CARMONA, 2006).



Figura 1 - Sintomas / sinais da ferrugem asiática em folíolos de soja

Fonte: Reis, Bresolin, Carmona (2006)

O amarelecimento prematuro e a abscisão foliar podem ocorrer em função do aumento de densidade de lesões. O estágio final da epidemia da ferrugem da soja (Figura 2) em uma lavoura se caracteriza pelo amarelecimento geral da folhagem com intensa desfolha (REIS; BRESOLIN; CARMONA, 2006).



Figura 2 - Desfolha causada pela ferrugem asiática da soja em plantas da parcela testemunha (sem a aplicação de fungicida)
Fonte: Reis, Bresolin, Carmona (2006)

Segundo Reis, Bresolin e Carmona (2006), a ocorrência da ferrugem asiática não está atrelada ao estágio fenológico da cultura, pois em algumas regiões do Centro-Oeste pode ocorrer nos primeiros estádios vegetativos. As variáveis que mais influenciam no rápido desenvolvimento da ferrugem asiática são altas temperaturas e longo período de molhamento foliar.

Os registros da disseminação da ferrugem asiática no mundo mostram que a doença acompanhou a expansão da cultura conforme a soja se expandiu do Oriente para o Ocidente. As grandes extensões territoriais, juntamente com a monocultura, dificultam o controle da doença. Outros aspectos agravantes são o aparecimento de diferentes isolados/raças do patógeno; atraso na época de semeadura; utilização de alta população de plantas; falhas nas aplicações de fungicidas e sobrevivência do patógeno em plantas voluntárias de soja ou em outras espécies hospedeiras na entressafra (YORINORI; NUNES JUNIOR, 2006).

O fungo promove uma redução na atividade fotossintética, pois destrói o tecido foliar, seguido de desfolha precoce da planta de soja e assim causa danos significativos

no rendimento por afetar o enchimento de grãos (JULIATTI, 2005). A ferrugem asiática da soja, é uma das doenças mais severas que incide na cultura, comprometendo de 10% a 90% do tecido vegetal (SINCLAIR; HARTMAN, 1999; YORINORI et al. 2005).

Considerando que a ferrugem asiática é uma doença altamente destrutiva, uma das alternativas de manejo mais utilizada é a aplicação de fungicidas, que deve ser feita de forma racional para não inviabilizar a cultura e agredir o ambiente de forma indiscriminada (GODOY; CANTERI, 2004). Aplicações calendarizadas de fungicidas em soja, iniciando no estágio de florescimento e se repetindo em intervalos de 14 a 21 dias, podem promover uma adequada supressão da doença, embora ignorem fatores que influenciam as epidemias, podendo resultar em aplicações desnecessárias (GODOY et al., 2009) quando não ocorre o monitoramento da cultura.

Para uma boa orientação e adoção de medidas de controle, a identificação de patógenos constitui requisito fundamental, tendo em vista as particularidades de cada região e de cada cultura (ROESE et al., 2001). Nesse sentido, o grande desafio do produtor de soja no manejo da ferrugem asiática é a identificação das áreas de plantas com um baixo índice de severidade da doença para que o agricultor possa entrar o mais cedo possível com o controle, evitando sua expansão.

2.3. Fitopatometria

A fitopatometria é uma área da ciência que tem por objetivo medir e quantificar os danos causados por doenças em plantas. De acordo com Amorim, Resende e Filho (2011), a quantificação de uma variável que expresse a intensidade de doença pode ser medida por incidência (porcentagem ou frequência de plantas doentes ou partes de plantas doentes em uma amostra ou população) ou por severidade (porcentagem de área ou do volume de tecido coberto por sintomas). Os autores afirmam que a variável severidade é mais apropriada para quantificar doenças foliares como ferrugens. A quantificação da severidade é um processo laborioso, sendo feita com o uso de escalas diagramáticas. Essas escalas são representações ilustradas de uma série de plantas ou partes de plantas com sintomas em diferentes níveis de severidade que servem como base para correta identificação do nível de severidade pelo avaliador (Figura 3).




Figura 3 - Escala diagramática de severidade da ferrugem asiática da soja (*Glycine max*)
 Fonte: Godoy, Koga e Canteri . (2006)

Existem ainda ferramentas computacionais que utilizam imagens de amostras de folhas para quantificação de severidade de doenças, que possuem vantagens por não estarem sujeitas aos problemas da visão humana, que gera quantificações subjetivas da severidade (AMORIM; RESENDE; FILHO, 2011).

2.4. Sensoriamento remoto

O conceito principal de sensoriamento remoto se baseia na obtenção e coleta de dados com o uso de sensores sem contato direto com o alvo. Uma aplicação comum de sensoriamento remoto é o uso de imagens para processamento digital.

A Tecnologia de Informação (TI) utiliza dados de sensoriamento remoto para apoio a tomada de decisão. Os critérios para um sistema com sensoriamento remoto de sucesso devem incluir rapidez na obtenção dos dados, confiabilidade e baixo custo. Uma alternativa de tecnologia de sensoriamento remoto que cumpre esses critérios e é bastante utilizada são as Aeronaves Remotamente Pilotadas (RPAs - do inglês *Remotely Piloted Aircraft*), também conhecidas como Veículos Aéreos Não Tripulados (VANTs) ou ainda como drones (termo em inglês que significa zangão). Imagens adquiridas a partir de RPAs contém diversas informações que são úteis por possuírem alta resolução espacial e temporal (XIANG; TIAN, 2011).

De acordo com Campbell e Wynne (2011), imagens possuem propriedades especiais que oferecem vantagens únicas no estudo da superfície da terra permitindo monitorar mudanças ao longo do tempo, medir tamanhos, áreas, profundidades e alturas e, em geral, adquirir informação de difícil aquisição por outros meios. Inclui-se dentro

deste contexto, o uso de imagens do espectro ótico fora do espectro luminoso visível ao olho humano.

O processamento digital de imagens (PDI) aliado ao sensoriamento remoto é uma ferramenta que permite a extração de informações através de técnicas não inatas à capacidade humana, principalmente na utilização de imagens multiespectrais (CAMPBELL: WYNNE, 2011). Assim, o sensoriamento remoto e PDI possuem aplicação na agricultura, onde decisões devem ser tomadas com precisão de acordo com os eventos que ocorrem frequentemente na lavoura.

Em meados da década de 80, a obtenção de imagens através de satélites para monitoramento de lavouras era muito comum no Brasil. Na época, o mais utilizado era o satélite LANDSAT 5 (MOTTA, 2002). Esse satélite possui sete bandas óticas: três na região visível do espectro eletromagnético (azul, verde, vermelho); três na região do infravermelho (infravermelho próximo, médio e distante), com resolução espacial de 30 metros; e uma banda no infravermelho termal, esta com resolução espacial de 120 metros. Existem outros satélites, como o IKONOS, que captura quatro canais de dados multiespectrais com a resolução espacial de 4 m, o QuickBird, que oferece quatro canais de dados multiespectrais em resoluções espaciais de 2,4 m (no nadir¹, na vertical em relação à superfície) ou 2,8 m (fora do nadir), o GeoEye-1, que captura quatro bandas espectrais em resolução de 1,65 m, e o satélite WorldView 2, que captura oito bandas espectrais em resolução de 1,8 m (YANG, 2012).

Nos satélites atuais a diferença em relação à resolução espacial é menor, um exemplo disso é o satélite WorldView 4, lançado em 2016, que apesar de conseguir capturar imagens em resoluções de até 31 cm com sua câmera pancromática em nadir (espectro visível), captura imagens na resolução de até 1,24 m com sua câmera multiespectral (NIR), também em nadir (SATELLITE IMAGING CORP, 2017).

A Tabela 1 compara os satélites citados.

¹ Segundo a perspectiva de um observador na superfície do planeta, nadir é a projeção do alinhamento vertical que está sob os pés do observador. É o oposto de zênite.

Tabela 1 - Comparação de resolução espacial entre satélites

Satélite	Resolução espacial	Ano de lançamento
LANDSAT 5	30 m / 120 m	1984
IKONOS	4 m	1999
QuickBird	2,4 m / 2,8 m	2001
GeoEye-1	1,65 m	2008
WorldView 2	1,8 m	2009
WorldView 4	0,31 m / 1,24 m	2016

Fonte: do autor

Apesar da disponibilidade e capacidade de sensores de satélite de alta resolução, sistemas de imagem aerotransportados ainda oferecem algumas vantagens, incluindo a disponibilidade imediata para avaliação em tempo real e a flexibilidade necessária para alterar os filtros de comprimentos de onda desejados e larguras de banda (YANG, 2012).

RPAs apresentam vantagens em relação a satélites em termo de resolução espacial e temporal. As principais vantagens desse tipo de equipamento são sua mobilidade, baixo custo, alta resolução e alto poder de escolha e customização dos equipamentos sensores, desde que se respeite o limite de peso que o modelo de RPA em questão suporte.

Na agricultura, o estudo do uso de RPAs é cada vez mais frequente e em diferentes aplicações, como por exemplo, no trabalho de Gómez-Candón, De Castro e López-Granados (2013) na área de agricultura de precisão, onde foram estudados os parâmetros necessários de voo e resolução para discriminar ervas daninhas de plantas de trigo no início de desenvolvimento da cultura.

Outros trabalhos que apresentam o uso de RPAs na agricultura são os trabalhos de Berni et al. (2009), Córcoles et al. (2013), Zarco- Tejada et al. (2013), Garcia-Ruiz et al. (2013), Calderón et al. (2013) e Sugiura et al. (2016).

Em Berni et al. (2009), a partir de imagens obtidas com câmeras termais e multiespectrais, foram calculados índices de vegetação para estimar parâmetros biofísicos das plantas. O principal objetivo desse trabalho foi demonstrar a capacidade de gerar produtos quantitativos de sensoriamento remoto por meio de um RPA do tipo helicóptero equipada com sensores de imagens térmicas e multiespectrais de baixo custo. Como resultado foi demonstrado que sistemas de RPA de baixo custo oferecem

boas estimativas, possivelmente melhores que sistemas tradicionais, como sensores acoplados a aviões.

Também utilizando imagens multiespectrais e termais, Calderón et al. (2013) estudaram a identificação preventiva de murcha-de-*Verticillium* (doença que ataca o sistema vascular e tem por sintoma o estresse hídrico), em oliveiras utilizando fluorescência, temperatura e bandas de alta frequência dos índices espectrais. Calderón et al. (2013) utilizaram três tipos de sensores: multiespectral, termal e hiperespectral. O sensor multiespectral consiste em uma câmera multiespectral equipada com seis sensores independentes nas bandas 450, 490, 530, 570, 670 e 800 nm e lente com 25 mm e filtros de diâmetro de 10 nm de largura total. O gerador de imagens hiperespectral contempla 260 bandas em 1,85 nm / pixel de 12 bits em resolução radiométrica. Nesse trabalho, foram obtidos coeficientes de determinação de 0,83 ($P < 0,001$) para estágios iniciais da doença, utilizando um índice de detecção de estresse hídrico. Também foram obtidas outras correlações significativas para detecção dos sintomas da doença em estágios iniciais com a banda G ($R^2 = 0,76$, $P < 0,002$) e o índice PRI570 ($R^2 = 0,51$, $P < 0,032$).

No trabalho de Córcoles et al. (2013) o objetivo foi avaliar um método não destrutivo para medir a cobertura do dossel em uma plantação de cebolas usando um RPA. Para alcançar esse objetivo foi utilizado o índice de área foliar (LAI - do inglês *Leaf Area Index*), que possui uma correlação com cobertura de dossel e estrutura de culturas. Como resultado obteve-se um coeficiente de determinação de 0,83 entre o índice de área foliar e a cobertura de dossel, utilizando um modelo linear.

Zarco-Tejada et al. (2013), estudaram o progresso de técnicas para estimativa de clorofila e carotenóides (pigmentos associados a fotossíntese) mediante imagens de alta resolução obtidas através de RPA. Os resultados demonstraram a viabilidade do mapeamento da concentração de carotenóides foliares no nível da videira apresentando um erro quadrático médio (RMSE) abaixo de 1,3 $\mu\text{G}/\text{cm}^2$ e um RMSE relativo (R-RMSE) de 14,4% (FLIGHT – Aproximações baseadas em um Modelo de Interação da Luz Florestal) e 12,9% (SAILH - Aproximações baseadas em pressupostos médio-turvos) para os 2 anos de imagens hiperespectrais.

No estudo de Garcia-Ruiz et al. (2013), sensoriamento remoto e índices de vegetação foram usados para detecção da Huanglongbing (“*Candidatus Liberibacter asiaticus*”), em árvores de citrus. No trabalho foram comparadas imagens obtidas através de RPA e aviões para a detecção da doença, onde imagens obtidas por RPA a

baixas altitudes se mostraram promissoras para uma detecção confiável do nível de severidade.

Durante os estudos de classificação, a precisão em imagens obtidas por RPA foi na faixa de 67-85% e o percentual de falsos negativos esteve entre 7% e 32%. Os valores correspondentes com dados de imagens obtidas de avião foram de 61-74% e 28-45% para a precisão e falsos positivos, respectivamente. Entre os algoritmos de classificação testados, a máquina de vetores de suporte (SVM) com kernel resultou em melhor desempenho do que outros métodos como SVM (linear), análise linear discriminante e análise discriminante quadrática (GARCIA-RUIZ et al., 2013).

Em Sugiura et al. (2016), um RPA foi utilizado em conjunto com uma câmera RGB, para estimativa de severidade de ferrugem tardia da batata, onde foi obtido coeficiente de correlação de 0,77. Para tal estimativa foi desenvolvido de um algoritmo utilizando processamento digital de imagens.

Uma característica comum das aplicações específicas de sensoriamento remoto na agricultura através de imagens é a obtenção de índices de vegetação e também o uso das bandas espectrais para estimar o estado nutricional e fisiológico das plantas, como observado nos trabalhos citados na presente seção.

2.5. Processamento digital de imagens e índices de vegetação

Um segmento importante de PDI consiste na execução de operações matemáticas dos dados, visando as suas transformações em imagens de melhor qualidade e que sejam mais apropriadas para uma determinada aplicação, bem como corrigir ruídos devidos a erros instrumentais, interferências da atmosfera (erros radiométricos) e a geometria de imageamento (distorções geométricas), os quais podem ocorrer durante a obtenção de imagens (MENESES; ALMEIDA, 2012).

Segundo Meneses e Almeida (2012), somente com cuidadosos processamentos computacionais pode-se extrair a informação no limite mais ideal à análise. Ao se considerar, por exemplo, o volume de dados que integra uma cena correspondente a um conjunto de multibandas, haverá centenas de milhões de dados registrados, e não há como imaginar uma análise sem os recursos de processamento. Isto ocorre na maioria dos trabalhos citados, como por exemplo, no trabalho de Calderón et al. (2013) onde o PDI é utilizado para correção atmosférica e para cálculo dos índices de vegetação. No trabalho de Garcia-Ruiz et al. (2013), não foi realizada correção atmosférica devido a

baixa altitude de voo do RPA que obteve as imagens, porém foi utilizado o processamento estatístico para cálculo dos índices.

Além da execução de operações matemáticas para correção de ruídos, o processamento digital de imagens também permite o uso de operações aritméticas (soma, subtração, multiplicação, divisão) para outras finalidades e para a transformação dos dados a partir da combinação de imagens, gerando como resultado uma imagem completamente distinta da original. O processo de transformação é executado pixel a pixel, por meio de uma regra matemática pré-definida envolvendo, normalmente, no mínimo duas bandas do mesmo sensor ou bandas de datas de aquisição diferentes (MENESES; ALMEIDA, 2012).

Dentre essas operações aritméticas, a operação de divisão de bandas é a que permite discriminar variações e realçar reflectâncias de alvos específicos. Meneses e Almeida (2012) afirmam que o exemplo que melhor ilustra os princípios da divisão de bandas, é a criação de índices, visando o realce das variações de densidade da cobertura vegetal, ao que se denomina índice de vegetação.

A variedade de índices de vegetação que podem ser calculados depende das regiões do espectro luminoso utilizadas. Segundo Dutra (2014), essas regiões se definem em: regiões do visível (VIS), infravermelho próximo (NIR) e infravermelho (IR). A Figura 4 ilustra as categorias e divisão do espectro magnético.




Figura 4 - Espectro eletromagnético
Fonte: Dutra (2014)

As imagens multiespectrais têm permitido desenvolver índices que são associados a diversas propriedades fisiológicas da vegetação (vigor, senescência, estresse hídrico) (EMBRAPA, 2014). De modo geral, os índices mais utilizados nos trabalhos consultados são: LAI (CARLSON; RIPLEY, 1997; BERNI et al., 2009; CALDERÓN et al., 2013; CÓRCOLES et al., 2013; ZARCO-TEJADA et al., 2013), e o índice de vegetação da diferença normalizada (NDVI – do inglês *Normalized Difference Vegetation Index*) (MYNENI, 1995; CARLSON; RIPLEY, 1997; KOGA; CANTERI; GODOY, 2007; BERNI et al., 2009; CALDERÓN et al., 2013; GARCIA-RUIZ et al., 2013).

O NDVI baseia-se no contraste entre a absorção máxima no vermelho devido a pigmentos da clorofila e a reflexão máxima no infravermelho causada pela estrutura celular da folha (HABOUDANE et al., 2004). Na Equação 1 (CARLSON; RIPLEY, 1997) é apresentado o cálculo para obtenção do NDVI.

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

Onde NIR e VIS representam as reflectâncias da superfície médias ao longo de intervalos de comprimentos de onda no visível ($\lambda \sim 0.6 \mu\text{m}$, “vermelho”) e infravermelho próximo ($\lambda \sim 0.8 \mu\text{m}$) do espectro luminoso, respectivamente (CARLSON; RIPLEY, 1997).

O índice de área foliar (LAI) é uma variável chave usada por fisiologistas de culturas e modeladores para estimar cobertura foliar, bem como a previsão de crescimento e a produtividade das plantas. Sua determinação é fundamental para a compreensão de processos biofísicos de dosséis florestais e agrícolas e para prever o seu crescimento e produtividade (HABOUDANE et al., 2004).

Apesar de grande aceitação do NDVI, Huete (1988) constata que esse índice não confirma ser um bom indicador de biomassa de vegetação se o terreno possuir uma pobre cobertura de vegetação, como em áreas semi-áridas, ou áridas. Assim sendo, um novo índice foi proposto: o índice de vegetação ajustado para solos (SAVI - do inglês *Soil Adjusted Vegetation Index*) que tem melhor desempenho para as áreas com baixa cobertura vegetal, ou seja, com a presença natural de exposições de solos, e que se mostra sensível à variação dos tipos de solos (MENESES; ALMEIDA, 2012). Na Equação 2 é apresentado o cálculo desse índice.

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

Onde L é uma constante empiricamente determinada para minimizar a sensibilidade do índice de vegetação às variações de reflectância dos tipos de solo. Como a primeira parte da equação SAVI é idêntica ao índice NDVI, se L for igual a zero o SAVI é igual ao NDVI. Para áreas de cobertura vegetal intermediária, L é tipicamente em torno de 0,5. O fator $(1 + L)$ assegura que o intervalo de valores de SAVI é o mesmo que o do NDVI, isso é, entre -1 +1 (MENESES; ALMEIDA, 2012).

Um índice de vegetação que possui grande potencial para uso em estimativa de severidade de doença é o índice de reflectância fotoquímica (PRI_{570}), devido a sua alta correlação com o pigmento xantofila presente nas folhas das plantas (CALDERÓN et al., 2013; ZARCO-TEJADA et al., 2013). Na Equação 3 é apresentado o cálculo deste índice.

$$PRI_{570} = \frac{(R_{570}-R_{531})}{(R_{570}+R_{531})} \quad (3)$$

Onde R_{570} representa a banda do espectro luminoso de frequência 570 nm, e R_{531} a frequência 531 nm.

Dos trabalhos citados até o momento, os trabalhos de Calderón et al. (2013), Zarco-Tejada et al. (2013) e Berni et al. (2009) fazem uso do índice de reflectância fotoquímica (PRI_{570}).

2.6. Correção radiométrica

Uma prática comum no uso de imagens aéreas aplicadas à espectroscopia é o processo de correção radiométrica. Os Números Digitais (ND) de uma imagem, que representam o brilho medido por um sensor, não podem ser referidos apenas às propriedades de reflexão e de emissão dos objectos observados (MEYER et al., 1993). As características e informações das imagens são influenciadas por efeitos radiométricos adicionais. Teillet (1986) os subdivide em duas categorias principais: efeitos induzidos por sensores e efeitos relacionados à cena.

Os efeitos induzidos pelo sensor resumem aspectos técnicos como a calibração de detectores, a filtragem, a estabilidade da plataforma e do sistema, etc. Os efeitos relacionados com a cena incluem a influência da topografia, atmosfera, ângulo de visão, efeito de adjacência, posição do sol e propriedades de reflectância dos objetos (TEILLET, 1986).

No trabalho de Calderón et al. (2013) e Zarco-Tejada et al. (2013), as imagens multiespectrais e hiperespectrais foram radiometricamente calibradas com um sistema de fonte luminosa uniforme (esfera integradora, CSTM-USS-2000C Sistema de Fonte Uniforme, LabSphere, NH, EUA) em quatro diferentes níveis de iluminação e seis diferentes tempos de integração. A correção atmosférica foi realizada com o modelo de simulação SMARTS, desenvolvido pelo Laboratório Nacional de Energias Renováveis, do Departamento de Energia dos EUA.

Em Berni et al. (2009), a calibração de imagens multiespectrais foi realizada utilizando um método de linha empírica, colocando dois alvos escuros e brancos em uma posição central capturados em imagens dentro do plano de voo do RPA. As medições espectrais de campo foram feitas com os espectrômetros de campo ASD (FieldSpec Handheld Pro, ASD Inc., CO, U.S.) de faixa espectral de 350-1050 nm no momento da aquisição da imagem. O espectrômetro de campo ASD foi primeiro calibrado utilizando um painel branco Spectralon (SRT-99-180, LabSphere, NH, EUA), permitindo assim o cálculo da reflectância do painel branco e escuro nos espectros a serem utilizados posteriormente para a calibração pelo método de linha empírica.

Existem alguns problemas associados a correção radiométrica, como o problema conhecido como de *vignetting*, ou vinhetamento, que ocorre devido à geometria da lente e do sensor. Nem todas as partes do sensor recebem a mesma quantidade de luz. Isso é mais visível nos cantos da imagem, e para compensar esse efeito, é possível aplicar uma correção de vinhetamento (PIX4D, 2016b).

Outro problema de imagens aéreas acontece quando os sensores de estado sólido como CMOS (do inglês *Complementary Metal Oxide Semiconductor*) ou CCDs (do inglês *Charge-coupled Device*) estão contaminados com ruído causado pela estimulação térmica de elétrons, o que é chamado *dark current*. Para compensar este efeito, é possível subtrair determinados frames escuros. *Dark current* depende fortemente da temperatura (PIX4D, 2016b).

A Sobreposição espectral ocorre em câmeras de lente única, como as câmeras de filtro modificadas para fornecer acesso à captura das frequências do infravermelho ou

Red Edge (vermelho limítrofe, frequência de 690-730 nm) no lugar de uma das outras bandas, o que significa que as bandas geralmente cobrem um espectro grande e que muitas vezes se sobrepõem um pouco. Por exemplo, pode ocorrer de o infravermelho estar contaminado com um pouco de azul. Para reduzir este efeito é possível aplicar uma matriz de cor específica para correção (PIX4D, 2016b).

Por fim, o problema de *ISO/aperture/exposure time*, ou tempo de abertura/exposição, acontece quando as câmeras precisam ajustar continuamente as configurações para se adaptarem à diferença de brilho em cada imagem. Se as imagens adquiridas forem dados lineares do sensor (como nas imagens de formato *RAW* e *TIFF*), é possível combinar com precisão imagens com diferentes ajustes de tempo de exposição corrigindo os respectivos efeitos (PIX4D, 2016b).

As correções radiométricas de irradiância do sol e irradiância e angulação do sol dependem do uso de um alvo de calibração, que é utilizado nas missões para obter valores de reflectância mais precisos, servindo de parâmetro para correção, pois são conhecidos os valores de reflectância padrão para o alvo (PIX4D, 2016b).

Segundo a documentação do Pix4d (2016b), ao calibrar radiometricamente uma câmera que capta diferentes bandas, é necessário conhecer o albedo (razão entre a quantidade de luz difundida pela superfície de um corpo) do material em cada banda capturada pela câmera. Berni et al. (2009) utilizou este tipo de abordagem.

2.7. Mineração de dados

A mineração de dados é uma tecnologia que agrega métodos tradicionais de análise de dados com sofisticados algoritmos para processamento de grande volume de dados. Ela viabiliza a exploração e análise de novos tipos de dados e também a análise de velhos tipos de dados em novas maneiras (TAN; STEINBACH; KUMAR, 2006).

Técnicas de mineração de dados são implementadas para escavar grandes volumes de dados e encontrar padrões que poderiam, por outros métodos, permanecer desconhecidos. Uma das áreas de aplicação da mineração de dados é a criação de modelos preditivos, que são categorizados em dois tipos de tarefas denominadas classificação, para dados discretos, e regressão, para dados numéricos contínuos (TAN; STEINBACH; KUMAR, 2006).

Dentre as técnicas de regressão, a Máquina de Vetores de Suporte (SVM – do inglês *Support Vector Machine*) apresenta robustez e precisão, possuindo uma base

teórica sólida. Essa técnica tem bom desempenho mesmo com poucos exemplos e também em bases de dados com alta dimensão (quantidade elevada de variáveis/atributos). Além disso, métodos eficientes para SVM também estão sendo desenvolvidos em um ritmo acelerado (WU et al., 2008).

Na agricultura, a SVM foi aplicada para prever a umidade do solo (GILL et al., 2006). Medições de umidade do solo são úteis na previsão e compreensão de vários processos hidrológicos, incluindo fluxos de energia e umidade, seca, programação de irrigação e geração de chuva / escoamento (GILL et al., 2006). Na abordagem usada por Gill et al. (2006), a umidade do solo e os dados meteorológicos são usados para gerar previsões para quatro e sete dias à frente, com coeficientes de correlação de 89% e 87%, respectivamente.

Outra aplicação de SVM dentro da agricultura é apresentada no trabalho de Rumpf et al. (2010), onde técnicas de SVM foram aplicadas para detectar e classificar doenças através de correlações entre índices de vegetação com severidade dos sintomas de diferentes patógenos. Os patógenos analisados são *Cercospora beticola*, *Uromyces betae* e *Erysiphe betae*, que são os causadores das doenças foliares mancha de Cercospora, ferrugem de beterraba e oídio, respectivamente, durante um período de 21 dias após a inoculação (RUMPF et al., 2010). A coleta de dados foi feita com um espectrorradiômetro de mão que captura reflectância no intervalo de frequência entre 400 e 1050 nm com uma resolução espectral de 1,4 nm. A partir dessas leituras foram calculados nove índices de vegetação para sua correlação com cada uma das doenças (RUMPF et al., 2010). Como resultado, foi possível notar que a precisão da classificação melhorou à medida que a severidade da doença aumentou (Figura 5). A diferença no número de folhas doentes fornece informações adicionais sobre a confiabilidade dos resultados da classificação. Com apenas 1-2% de área foliar doente, a precisão da classificação foi de 65% para todas as doenças. A precisão da diferenciação entre folhas saudáveis e folhas com sintomas de manchas foliares de Cercospora aumentou rapidamente com uma gravidade da doença de 3-5%. Quando mais de 10% da área foliar foi coberta por manchas foliares, a precisão da classificação atingiu 100% (Figura 5) (RUMPF et al., 2010).




Figura 5 - Resultados da classificação de folhas de beterraba inoculadas com os diferentes patógenos dependendo da severidade da doença
Fonte: RUMPF et al. (2010)

No estudo de Garcia-Ruiz et al. (2013), sensoriamento remoto e índices de vegetação foram usados para detecção de uma doença que tem por principal sintoma amarelecimento das folhas, a Huanglongbing (*Candidatus Liberibacter asiaticus*), em árvores de citrus. No trabalho foram comparadas imagens obtidas através de RPA e aviões para a detecção da doença, onde imagens obtidas por RPAs a baixas altitudes se mostraram promissoras para uma detecção confiável do nível de severidade.

Durante os estudos de classificação, as precisões na faixa de 67-85% e falsos negativos de 7% a 32% foram adquiridos a partir de dados obtidos por RPA, ao passo que os valores correspondentes foram de 61-74% e 28-45% com dados obtidos por aeronaves. Entre os algoritmos de classificação testados, a máquina de vetores de suporte (SVM) com kernel resultou em melhor desempenho do que outros métodos como SVM (linear), análise linear discriminante e análise discriminante quadrática (GARCIA-RUIZ et al., 2013).

Outro tipo de técnica utilizada para classificação e regressão são as árvores de decisão. Em uma árvore de decisão, cada nó folha corresponde a um rótulo de classe, ou regra no caso de regressão. Os nós não terminais, o que inclui a raiz e outros nós internos contém condições de teste de atributos para separar registros que possuem diferentes características (TAN; STEINBACH; KUMAR, 2006).

Rumpf et al. (2010) também utilizaram árvores de decisão para prever a severidade das doenças de beterraba analisadas, porém em comparação com a classificação, nos resultados das árvores de decisão o erro de classificação foi sempre maior que nas SVMs.

As regras de decisão podem ser induzidas a partir de dados de treinamento em um estilo de baixo para cima, de específico para geral, ou em um estilo de cima para baixo de geral para específico, como na construção de árvores de decisão. O estado inicial de uma solução de regra de decisão é a coleção de todas as instâncias individuais ou exemplos em um conjunto de dados de treinamento, cada um dos quais pode ser considerado como uma regra de decisão altamente especializada (APTÉ; WEISS, 1997).

A maioria dos sistemas de regra de decisão emprega um processo de busca que tenta evoluir essas regras altamente específicas em regras individuais mais genéricas. Esse processo de busca é iterativo e geralmente termina quando as regras não podem mais ser generalizadas, ou algum outro critério de parada alternativo é satisfeito (APTÉ; WEISS, 1997).

Os métodos de indução de regras tentam encontrar um conjunto de regras de cobertura dividindo os exemplos em suas classes corretas. O conjunto de cobertura é encontrado heurísticamente procurando uma única "melhor" regra que abrange casos para apenas uma classe. Tendo encontrado uma regra conjuntiva "melhor" para uma classe C, a regra é adicionada ao conjunto de regras, e os casos que a satisfazem são removidos de consideração adicional. O processo é repetido até que nenhum caso permaneça descoberto (APTÉ; WEISS, 1997).

3. MATERIAIS E MÉTODOS

3.1. Área experimental e planejamento das missões de voo

O experimento foi conduzido em Ponta Grossa – Paraná, na Fazenda Escola Capão da Onça pertencente a Universidade Estadual de Ponta Grossa, situada nas coordenadas geográficas 25°13' de latitude Sul, 50°01' de longitude Oeste e 869 metros de altitude. De acordo com o sistema de classificação climática de Köppen baseado na vegetação, temperatura e pluviosidade, a região dos Campos Gerais pertence ao clima Cfb – Clima temperado; temperatura média no mês mais frio abaixo de 18°C, com verões frescos, temperatura média no mês mais quente abaixo de 22°C e sem estação seca definida, a precipitação média anual é de 1422 milímetros, sendo janeiro o mês mais chuvoso e agosto o mais seco (IAPAR, 2015).

O solo no local do experimento é classificado com Cambissolo Háplico Tb Eutrófico típico e textura argilosa (EMBRAPA, 2006). A cultivar de soja utilizada foi a Nidera NA 5909 RG, que apresenta resistência ao glifosato, ciclo semiprecoce, hábito de crescimento indeterminado, resistência ao acamamento, capacidade de engalhamento, excelente adaptação ao Sul do Brasil, resistente ao cancro da haste (*Phomopsis phaseoli* f. sp. *meridionalis*/*Diaporthe phaseolorum* f. sp. *meridionalis*), mancha olho de rã (*Cercospora sojina* Hara) e ao crestamento bacteriano (*Pseudomonas savastanoi* pv. *glycinea*); medianamente suscetível ao oídio (*Microsphaera diffusa*) e suscetível a ferrugem asiática (*Phakopsora pachyrhizi*) e ao nematóide de cisto (*Heterodera glycines*) (NIDERA, 2016).

A semeadura da cultura da soja foi realizada em sistema de plantio direto na palha de trigo, em 16 de dezembro de 2015, em espaçamento entrelinhas de 0,45 m com 15 sementes por metro para obter uma densidade de 12 plantas por metro e uma população final de 250.000 plantas por hectare. O tratamento de sementes foi realizado com fipronil + piraclostrobina + metil tiofanato (Standak Top – 200 mL p.c. 100 Kg⁻¹ de semente) e inoculação das sementes com *Bradyrhizobium japonicum* (Nitrogen – 300 mL p.c. 100 Kg⁻¹ de semente). Para a adubação de base foi utilizado 300 kg por hectare do fertilizante NPK na fórmula 02:08:12. A emergência da cultura ocorreu em 21 de dezembro de 2015. Os demais tratos culturais foram realizados conforme a necessidade da cultura.

O delineamento experimental adotado foi o de blocos casualizados, com 11 tratamentos e quatro repetições, sendo que um dos tratamentos é a testemunha (sem aplicação de fungicida) e nos demais tratamentos foram utilizados fungicidas e outros produtos alternativos com diferentes frequências de aplicação (o que resulta em um gradiente de severidade na área acompanhada). Cada parcela media 4,0 m de largura por 4,5 m de comprimento, totalizando 18 m² (Figura 6).

O desenvolvimento da cultura da soja foi acompanhado pela escala fenológica proposta por Fehr e Caviness (1977), revisada por Ritchie et al. (1997).

As avaliações de severidade da ferrugem asiática foram realizadas por especialista semanalmente durante o ciclo da soja, a partir dos primeiros sintomas com o auxílio da escala diagramática de Godoy, Koga e Canteri (2006) (Figura 3), esses dados serão utilizados em conjunto com as bandas espectrais do equipamento para criação dos modelos de regressão. Foram avaliadas 7 plantas escolhidas ao acaso em cada parcela.



Figura 6 – Imagem do local de realização do experimento para controle da ferrugem asiática da soja na safra 2015/2016 na fazenda escola da Universidade estadual de Ponta Grossa

Fonte: do autor.

A proposta inicial para as campanhas de obtenção das imagens foi planejada para que os voos fossem realizados semanalmente no verão da safra de 2015/2016, acompanhando os estádios de desenvolvimento da cultura da soja, principalmente nas fases próximas ao florescimento da cultura que são os estádios mais prováveis para o

surgimento de lesões, de acordo com o padrão de desenvolvimento da doença descrito por Reis, Bresolin e Carmona (2006).

Os voos foram realizados semanalmente sobre a área experimental, o mais próximo possível das datas de quantificação de severidade da ferrugem asiática da soja. A Tabela 2 mostra as datas das missões realizadas e a câmera utilizada no voo.

Tabela 2 - Datas de realização de voos na área experimental e câmeras utilizadas
NIR com a geração de fotos

	RGB	NIR	CR2
11/12/2015		*	
16/12/2015		*	
05/01/2016		*	
13/01/2016		*	
18/01/2016		*	
26/01/2016		*	
02/02/2016		*	
12/02/2016		*	
19/02/2016	*	*	
25/02/2016	*	*	
04/03/2016	*	*	*
08/03/2016	*		*
14/03/2016	*		*
18/03/2016	*		*

Fonte: do autor

Como é possível notar na Tabela 2, antes de 19/02/2016 não foi realizado nenhum voo com a câmera RGB. Isso se deve ao fato de que em dezembro de 2015 foi detectado um defeito na câmera e então a mesma foi encaminhada ao fornecedor para manutenção.

Na Tabela 2, existem também duas colunas para a câmera NIR. Essa distinção foi feita pois até a data de 04/03/2016 foi constatado, através do processamento, que não era possível extrair as bandas espectrais das imagens geradas por essa câmera devido ao padrão de trabalho estabelecido pela empresa senseFly (imagens possuíam extensão *.jpg*, em um formato que impossibilitava a extração correta dos dados). O indicado nessa situação é o uso de uma configuração de câmera que permite com que as imagens sejam geradas com a extensão *CR2*, que por fim permite a extração correta das bandas e geração de imagens *TIFF* através do pré-processamento no software Emotion 2 (SANTIAGO-CINTRA, 2016a).

A resolução das imagens adotada foi 3,4 cm/pixel com sobreposição lateral de 60% e longitudinal de 75%. As datas em que as medidas em campo ocorreram para avaliação da doença estão apresentadas na Tabela 3.

Tabela 3 - Datas de medição da severidade da ferrugem asiática na área experimental com cultura da soja na fazenda escola da Universidade Estadual de Ponta Grossa

Datas de avaliações em campo	Estádio fenológico da cultura
06/02/2016	V7
13/02/2016	R1
22/02/2016	R3
25/02/2016	R5.1
03/03/2016	R5.3
11/03/2016	R6

Fonte: do autor

Para montar as bases a serem utilizadas, os dados de severidade de cada uma dessas datas foram relacionados com os valores espectrais das imagens a partir da proximidade entre as datas (Tabela 4).

Tabela 4 - Relação de datas de coleta para criação das bases de dados

Datas de voo	Datas de leitura em campo	Imagens utilizadas para a base
25/02/2016	25/02/2016	RGB
04/03/2016	03/04/2016	RGB e NIR
08/03/2016	11/03/2016	RGB e NIR
14/03/2016	11/03/2016	RGB e NIR

Fonte: do autor

Assim, para cada data de voo apresentada na Tabela 4 foi criada uma base de dados a ser analisada através da mineração de dados.

3.2. Descrição do equipamento utilizado

O equipamento utilizado foi um RPA eBee (Figura 7), fabricado pela empresa suíça senseFly. Esse RPA permite realizar a tomada de imagens de forma rápida e sob demanda, incluindo inteligência artificial para realizar a decolagem, o voo e a aterrissagem de maneira automática por autopiloto.



Figura 7 – Equipamento RPA eBee utilizado nos voos da cultura da soja (Glycine max)
Ponta Grossa – PR, 2016
Fonte: Sensefly (2015)

O equipamento eBee vem acompanhado do software Emotion 2, que permite configuração prévia do plano de voo bem como sua alteração em tempo real. Com o software é possível definir a área da coleta de dados, a altitude, resolução das imagens e a sobreposição longitudinal e latitudinal da área a ser sobrevoada. O software também permite realizar o monitoramento em tempo real do eBee através de informações de voo, tais como: altitude, velocidade do vento, status de bateria, dentre outras. Além disso, o Emotion 2 permite a realização do pré-processamento das imagens, onde através do sistema inercial e do GPS embarcados na RPA, o software é capaz de proporcionar as coordenadas geográficas de cada imagem.

Foram utilizadas duas câmeras, uma de modelo Sony Cyber-shot WX RGB com 18.2 megapixels, e outra Canon S110 NIR com 12 megapixels, ambas permitindo a coleta de imagens com resolução de até 3,4 cm/pixel (Figura 8).



Figura 8 - Câmeras utilizadas nos voos da cultura da soja (Glycine max) Ponta Grossa – PR, 2016; (a) Sony Cyber-shot WX RGB (b) Canon S110 NIR
Fonte: Sensefly (2015)

As câmeras são fornecidas com um conjunto de parâmetros configurados pela empresa senseFly, para garantir que as imagens obtidas sejam as mais precisas considerando a aplicação na agricultura. A configuração mais importante, principalmente na câmera NIR, é a relação de velocidade do obturador, a qual deve ser a menor possível para evitar borrões nas imagens, uma vez que as câmeras estão em constante movimento durante o voo. A velocidade configurada é de 1/2000s, aproximadamente 0,0005 segundos (SANTIAGO-CINTRA, 2016a).

A câmera RGB captura dados nas bandas do RED (vermelho), GREEN (verde) e BLUE (azul), enquanto a NIR captura informações na região do NIR (infravermelho próximo), RED (vermelho) e GREEN (verde). Apesar das duas câmeras fornecerem informações na região do vermelho e do verde, cada uma considera frequências diferentes, como pode ser observado na Figura 9 (SANTIAGO-CINTRA, 2016a; SANTIAGO-CINTRA, 2016b).




Figura 9 - Comprimentos de onda filtrados pelas câmeras RGB e NIR

Fonte: Santiago-cintra, 2016a; Santiago-cintra, 2016b

Na câmera RGB as imagens são feitas no padrão JPEG (do inglês *Joint Photographic Experts Group*) e possuem intensidade de 8 bits por canal, ou seja, os valores (ND, ou número digital) que representam as tonalidades de cada pixel podem variar de 0 a 255 em cada banda. Já na câmera NIR, as imagens são obtidas em formato CR2 (do inglês *Canon Raw Version 2*) e convertidas para o formato *TIFF*, ambos os formatos com intensidade de 16 bits por canal, onde os valores variam de 0 a 65536 em cada banda.

Após o voo as imagens são pré-processadas no software Emotion 2, onde são georreferenciadas, e no caso da câmera NIR é feita a conversão do formato CR2 gerado

pela câmera para *TIFF*, formato utilizado para geração de ortomosaicos e mapas de refletância para essa câmera (PIX4D, 2016).

3.3. Georreferenciamento das imagens obtidas

Imagens de alta resolução espacial coletadas por RPAs têm demonstrado potencial para monitoramento de variáveis agronômicas e ambientais. No entanto, é necessário a captura de um grande número de imagens sobrepostas que devem ser consolidadas para produzir uma única ortoimagem (também denominada ortomosaico) que representa toda a área de trabalho (GÓMEZ-CANDÓN; DE CASTRO; LÓPEZ-GRANADOS, 2013).

O processamento fotogramétrico de imagens obtidas por RPAs pode ser realizado com as posições centrais das imagens que recebem uma coordenada dada pelo GNSS (Sistema de navegação global por satélite), mas para se garantir a precisão do processo de mosaicagem é conveniente o uso de pontos de apoio e pontos de controle no terreno (GCPs - do inglês *Ground Control Points*) (GÓMEZ-CANDÓN; DE CASTRO; LÓPEZ-GRANADOS, 2013).

Para a correção geométrica das imagens coletadas por RPAs, coordenadas mais precisas de objetos fixos ao nível do solo são necessárias, porém tais objetos devem ser reconhecíveis nas imagens. Existem diversas ferramentas para a realização do processo de correção geométrica em um mosaico, como por exemplo, sistemas de informação geográfica (GIS – do inglês *Geographic Information Systems*), que podem ser utilizados em diferentes momentos, dependendo da metodologia adotada.

Liba e Berg-Jurgens (2015) usam GCPs com imagens de resolução espacial de 5cm/pixel obtidas por meio de um RPA utilizando o software PIX4D para geração dos mosaicos, onde a precisão utilizando GCPs foi de 0,132m, e de 1,417m sem o uso de GCPs. Esse software é fornecido pela empresa PIX4D a partir de uma licença para uso particular ou por contrato de serviço online.

Outra metodologia é a utilização de GCPs para correção de georreferenciamento após a geração do mosaico, utilizando o próprio sistema de obtenção das imagens, sendo que a distorção é corrigida informando as coordenadas dos GCPs visualizados nas imagens para ajuste do mosaico.

Com a finalidade de medir o georreferenciamento dos ortomosaicos gerados pelo equipamento eBee, em conjunto com o software de processamento, foi realizado

um estudo sobre a precisão das coordenadas geradas a partir da utilização de GCPs para aferição. Esse estudo foi realizado em agosto de 2016, posteriormente às coletas feitas para a soja.

O voo para obtenção das imagens foi realizado em uma área experimental da região dos Campos Gerais do Paraná, na Fazenda Santa Cruz, localizada na cidade de Ponta Grossa - PR, utilizando o eBee com a câmera Sony Cyber-shot RGB. O voo foi conduzido em uma altitude de 120 metros no dia 11 de agosto de 2016 entre 12 e 14h. A resolução utilizada foi de 3,4 cm/pixel.

Com a finalidade de visualizar os GCPs nas imagens a partir da resolução escolhida, foram confeccionados marcadores com fundo branco medindo 60 cm x 60 cm. Tais marcadores são posicionados com auxílio de estacas a uma altura de 50 cm do solo, tendo em vista o acompanhamento no crescimento das culturas em diferentes experimentos. O marcador possui um X feito com fita de marcação, para auxiliar na identificação do ponto central, onde é feita a amarração com a coordenada geográfica (Figura 10).



Figura 10 - Marcador GCP utilizado no estudo de georreferenciamento
Fonte: do autor

Um receptor geodésico Trimble R4 (Figura 11a) foi utilizado para a coleta da posição dos GCPs, com coordenadas pós processadas com base nas estações da Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS (RBMC) de Curitiba-PR e Guarapuava-PR. Para isso, foram definidos 10 pontos de controle ao longo da área de estudo, como ilustrado na Figura 11b.



Figura 11– GPS Trimble R4. (a) Disposição dos GCPs na área do estudo de georreferenciamento (b)
Fonte: do autor

As imagens foram georreferenciadas no software Emotion 2 e processadas no software PIX4D, para a geração dos mosaicos.

O software PIX4D calcula as posições e orientações das imagens originais de forma automática através da triangulação aérea (AAT – do inglês *Automatic Aerial Triangulation*) e do ajuste de feixes em bloco (BBA – do inglês *Bundle Block Adjustment*). Com base em nuvem de pontos 3D obtidos durante a AAT e BBA, é gerado um Modelo Digital de Superfície (MDS) por ligação destes pontos. O ortomosaico é então criado a partir da projeção e combinação das imagens originais com o MDS (PIX4D, 2016a).

A ferramenta utilizada para a correção dos mosaicos foi o QGis (GIS, 2016a), software de uso livre, com o *plugin* de georreferenciamento, para corrigir um mosaico já gerado utilizando pontos de controle selecionados manualmente.

Para este teste de georreferenciamento o mosaico utilizado foi gerado pelo software PIX4D e foram utilizados cinco tratamentos de métodos de correção geométrica (cada tratamento é uma composição do mosaico gerado com um método de correção geométrica, que tem por resultado um novo mosaico após a correção), sendo três pelo software PIX4D e dois pelo software QGis. No PIX4D o primeiro mosaico (tratamento PIX0) foi corrigido sem a utilização de GCPs, o segundo (tratamento PIX5) utilizando cinco GCPs e o terceiro (tratamento PIX10) utilizando dez GCPs. No software QGis para os dois tratamentos restantes, os dois mosaicos resultantes (tratamentos QGis5 e QGis10) foram gerados através da correção utilizando método de transformação “polinomial 1”, e de reamostragem o “vizinho mais próximo”, com 5 e 10 GCPs respectivamente.

Foi escolhido o método de transformação polinomial de primeira ordem, pois segundo a documentação do QGis essa transformação preserva a colinearidade e permite apenas o escalonamento, translação e rotação (GIS, 2016b). Segundo a documentação também, o método de reamostragem pelo vizinho mais próximo deve ser a escolha quando as estatísticas da imagem não puderem ser mudadas.

A escolha da quantidade de GCPs se deu devido a recomendação do PIX4D, em que um número mínimo de 5 pontos de controle é recomendado, e de 5 a 10 pontos de controle são geralmente suficientes, mesmo para grandes projetos. Mais pontos de controle não contribuem de forma significativa para aumentar a precisão (PIX4D, 2016a).

Com base nas coordenadas dos GCPs medidas com o receptor geodésico, foi calculada a distância das coordenadas dos GCPs para cada um dos mosaicos gerados. Foi calculado também o erro do desvio médio quadrático (RMSE – do inglês *Root Mean Square Error*) como indicativo de diferença entre as distâncias. Além disso, para saber se as distâncias medidas possuem uma diferença significativa entre os mosaicos, foi utilizado o teste de Tukey.

O teste de Tukey é um método estatístico de comparação múltipla. O teste pode ser utilizado juntamente com a análise de variância (ANOVA) para identificar a diferença entre grupos de dados significativamente diferentes uns dos outros. Seu funcionamento é baseado na distribuição da amplitude estudentizada e na execução da diferença significativa honesta, como explicado em Navidi (2012).

Os pontos em vermelho na Figura 12 representam as coordenadas exatas dos GCPs, e como pode ser observado, há um erro entre tal coordenada e seu respectivo marcador na imagem. Sendo assim, para todos os tratamentos foi medido o erro para cada um dos GCPs (Tabela 5). O mosaico que obteve o menor RMSE (0,378) foi o QGis10. O mosaico que apresentou maior RMSE (2,122) em relação a distância dos pontos GCP foi o mosaico PIX0.

O teste de Tukey foi conduzido num delineamento inteiramente casualizado, ao nível 5% de significância, com cinco tratamentos e dez repetições (Tabela 6).



Figura 12 - Demonstração do erro de georreferenciamento (tratamento PIX0)
Fonte: do autor

Tabela 5 - Distâncias dos GCPs em relação a coordenada exata, em metros (m) e RMSE para cada mosaico

GCP	PIX0	PIX5	PIX10	QGis5	QGis10
1	2,039	1,027	0,67	0,275	0,277
2	1,959	1,042	0,661	0,075	0,71
3	2,2	1,226	0,946	0,6	0,367
4	2,57	0,973	0,71	1,09	0,675
5	1,539	0,395	0,43	0,253	0,25
6	1,373	0,377	0,614	0,366	0,361
7	1,74	0,622	0,808	0,297	0,111
8	2,261	0,589	0,778	0,264	0,05
9	2,41	0,542	0,744	0,26	0,107
10	2,717	0,56	0,842	0,175	0,213
RMSE	2,1218	0,7892	0,7326	0,4564	0,3788

Fonte: do autor

Tabela 6 - Resultados do Teste de Tukey 5% para os diferentes tratamentos

Tratamentos	Médias	Significância
PIX0	2,08	a
PIX5	0,74	b
PIX10	0,72	b
Qgis5	0,37	bc
Qgis10	0,31	c

*Médias com letras iguais indicam diferença não significativa pelo teste de Tukey ($p < 0.05$)

Fonte: do autor

Houve diferença significativa entre os mosaicos PIX0 em relação aos demais. Os mosaicos PIX5 e PIX10 não apresentaram diferença significativa entre eles. Não é possível estabelecer diferença significativa do tratamento QGis5 dos demais tratamentos, além do PIX0. Além de possuir menor erro, o processo de correção do mosaico pelo QGis (tratamentos QGis5 e QGis10) é menos trabalhoso quando comparado com a geração dos mosaicos corrigidos pelo PIX4D (tratamentos PIX5 e PIX10), tendo em vista a necessidade de demarcação dos GPCs em todas as imagens antes da geração do mosaico.

Liba e Berg-jurgens (2015) utilizaram imagens de RPA e 9 GCPs para a geração de um mosaico com a ferramenta PIX4D e compararam com um mosaico gerado sem o uso de GCPs. Quando medida a precisão dos mosaicos, encontraram o RMSE de 0,132 e 1,417 com e sem os GCPs, respectivamente (1,285 de diferença).

Neste estudo de georreferenciamento, os mosaicos gerados pelo PIX4D sem a utilização de GCPs apresentaram um RMSE de 2,122 e os mosaicos gerados pelo mesmo método com 5 e 10 GCPs obtiveram um RMSE de 0,789 e 0,732, respectivamente (1,39 de diferença de diferença entre pix0 e QGis10).

O resultado desse experimento pode sofrer influência de diversas variáveis, como a resolução espacial das imagens, equipamentos utilizados para coleta de imagens e de coordenadas dos GCPs, variáveis climáticas no momento das coletas, além do próprio software utilizado. Isso pode explicar a diferença de valores RMSE obtidos nesse trabalho em relação ao de Liba e Berg-jurgens (2015), apesar de a proporção da diferença do RMSE entre os tratamentos sem GCP e com GCP ser relativamente próxima nos dois trabalhos (1,285 para Liba e Berg-jurgens e 1,39 no teste apresentado nesta seção).

3.4. Pós-processamento das imagens coletadas, geração do mapa de reflectância e correções

O software PIX4D, utilizado nesse trabalho, oferece suporte para algumas calibrações radiométricas acrescentadas a ferramenta em uma atualização em setembro de 2016, como as opções de correção “câmera”, “câmera e irradiância solar” e “câmera, irradiância e ângulo do sol” (PIX4D, 2016). Essas operações são realizadas apenas quando selecionada a opção para gerar o mapa de reflectância (MR) da área.

Para as correções, na opção “câmera”, são realizadas operações de correção relacionadas ao sensor, como *optical vignetting*, *dark current*, *spectral overlap* e *ISO/aperture/exposure time* (PIX4D, 2016b). As demais opções utilizam o alvo de calibração, conforme explicado na seção 2.6.

Tanto o mapa de reflectância como o ortomosaico são obtidos a partir do MDS, para ambos os mapas o valor de cada pixel é obtido como uma média ponderada dos pixels nas imagens originais que correspondem a este pixel em particular (PIX4D, 2016a).

Para o ortomosaico, o equilíbrio de cores é aplicado, isso significa que o PIX4D tentará ajustar a intensidade das cores em cada imagem para que as imagens se encaixem melhor em conjunto. O objetivo desta operação é produzir um resultado visualmente mais agradável (PIX4D, 2016a).

Para o mapa de reflectância, não foi aplicado qualquer equilíbrio de cores. O peso de cada pixel (a partir das imagens originais) na média ponderada também é computado de forma diferente. O objetivo é produzir um mapa onde o valor de cada pixel indica fielmente a reflectância do objeto (PIX4D, 2016a). A diferença entre o ortomosaico e o mapa de reflectância gerados pelo PIX4D (Figura 13), onde a parte superior mostra os ortomosaicos para as câmeras RGB e NIR (letras *a* e *c*, respectivamente) e a parte inferior mostra os mapas de reflectância (letras *b* e *d*, respectivamente).




Figura 13 - Comparação entre os ortomosaicos e os mapas de reflectância gerados pelo PIX4D. Mosaico RGB (a), Mapa de reflectância RGB (b), Mosaico NIR (c), Mapa de reflectância (d)

Fonte: do autor

Como o RPA eBee foi adquirido em novembro de 2015 e a área começou a ser acompanhada logo em dezembro, e visto que o método de calibração pela irradiância solar depende da aquisição de um alvo de calibração com os valores de cada porção mensurados, ou então da criação de um alvo e sua mensuração através de um espectrômetro, foi utilizada somente a opção de calibração da câmera no PIX4D para os voos realizados. Tomou-se o cuidado de analisar e comparar isoladamente fotos de uma mesma data apenas, que por consequência teriam condições de voo semelhantes.

Após a coleta das imagens feitas pelo voo, o procedimento padrão utilizado foi o pós-processamento das imagens pelo software Emotion 2, que também é utilizado para criação dos planos de voo e controle do RPA (SENSEFLY, 2016).

Na opção de pós-processamento do Emotion 2, as imagens são georreferenciadas através do log da missão de voo e exportadas para imagens de extensão *TIFF*, para ambas as câmeras. Esse pós-processamento também gera um projeto para o software PIX4D para geração dos mosaicos, mapas de reflectância, índices de vegetação, etc.

Assim, para cada data de missão de voo foi gerado um mapa de reflectância a partir das imagens do voo, onde foram feitas as correções radiométricas da opção “câmera”, descritas anteriormente na presente seção.

Para a correção geométrica e de georrefenciamento não foram usados os marcadores para GCP mostrado na Figura 10, pois ainda não haviam sido confeccionados. Para correção geométrica, foram utilizadas coordenadas de feições identificáveis (postes e cantos das áreas experimentais) da imagem medidas com um GPS Trimble com precisão de até 20 cm (Figura 14) (TRIMBLE, 2016).



Figura 14 - Pontos utilizados para a correção geométrica
Fonte: do autor

Foram escolhidos os métodos de transformação polinomial e de reamostragem pelo vizinho mais próximo, conforme descrito no item 3.3. Após a correção de georreferenciamento é possível medir a diferença entre os pontos base e os pontos na imagem corrigida. Na Tabela 7 é mostrada a distância entre os pontos da imagem em relação aos pontos base e seu RMSE.

Tabela 7 - Distância dos pontos em relação a base após a imagem ser corrigida geometricamente

Ponto de referência	Distância entre os pontos (m)
1	0,075
2	0,275
3	0,053
4	0,274
5	0,724
6	0,326
7	0,88
8	1,437
9	0,072
10	0,681
11	0,35
12	0,525
RMSE	0,6121

Fonte: do autor

3.5. Extração e criação das bases de dados

Após a correção geométrica dos mapas de reflectância, foram definidos pontos aleatórios dentro de cada parcela. A quantidade de pontos aleatórios por parcela foi baseada em proporção a área do polígono utilizado para representá-la (Figura 15). Optou-se por centralizar o polígono o máximo possível dentro da parcela e manter sua área de maneira que não invadisse outras parcelas, mesmo em caso de haver pequena variação de precisão do georreferenciamento.




Figura 15 - Polígonos definidos para representação de cada parcela
Fonte: do autor

O cálculo do número de pontos foi baseado em um valor que cobriria parte suficiente do número de pixels de cada parcela. Esse número máximo de pontos foi calculado dividindo a área (m^2) pela resolução (3,4 cm de aresta/pixel ou 0,034 m de aresta/pixel) da imagem ao quadrado (área de 1 pixel, $11,56\text{ cm}^2$ ou $0,001156m^2$). A Tabela 8 mostra essa relação para cada uma das parcelas dos blocos 1 e 2 da área experimental como modo de exemplificar o cálculo do número de pontos.

Tabela 8 - Relação entre área e número de pontos por parcela para os blocos 1 e 2 da área experimental

Tratamento	Bloco	Nº pontos	Área (m²)
11	1	4302	4,97
10	1	3139	3,62
9	1	3187	3,68
8	1	2259	2,61
7	1	3189	3,68
6	1	2207	2,55
5	1	2944	3,40
4	1	2590	2,99
3	1	2903	3,35
2	1	2818	3,25
1	1	4129	4,77
10	2	3746	4,33
9	2	3183	3,67
8	2	2509	2,90
7	2	2030	2,34
6	2	2492	2,88
5	2	2440	2,82
4	2	2503	2,89
3	2	2439	2,81
2	2	2263	2,61
1	2	2770	3,20
11	2	3520	4,06

Fonte: do autor

Foram definidas três proporções (20%, 40% e 70%) em relação ao número de pontos de cada parcela, e ao agrupar os dados de todas as parcelas em uma única base obteve-se três bases (uma para cada proporção). Essas três proporções foram definidas com o objetivo de avaliar se existe diferença e influência do número de pontos (número amostral) para construção de um modelo de predição de severidade de ferrugem asiática da soja.

Para cada ponto, foram extraídos os valores das três bandas espectrais dos dois mapas de reflectância (um para cada câmera, exceto para o voo de 25/02/2016 que só possui o mapa da RGB conforme explicado na seção 4.1) por data de voo, em cada uma das proporções definidas. Assim, foram estabelecidas 12 bases de dados (uma para cada porcentagem definida, para os quatro voos utilizados na criação das bases).

Os valores de reflectância foram extraídos utilizando o *plugin* Point Sampling Tool (POINT SAMPLING TOOL, 2016) da ferramenta QGis (GIS, 2016a). Após a extração foi utilizada a calculadora Raster para cálculo do índice de vegetação NDVI a

partir das bandas RED e NIR da câmera NIR. Para esse cálculo, é necessário que as bandas usadas sejam da mesma câmera por causa da diferença de intensidade de bits por canal entre as câmeras RGB (256 tons de cor por canal) e NIR (65536 tons de cor por canal), e porque as câmeras foram usadas nas mesmas datas mas em momentos de voos diferentes, visto que o equipamento não permite o uso de mais de uma câmera por voo. O número total de registros para as bases de proporção 20%, 40% e 70% são 25042, 50058, 87585 respectivamente, sendo que o valor de 100% corresponde a 123687 pontos.

3.6. Mineração dos dados extraídos das imagens

A partir dos conceitos apresentados sobre os métodos de regressão SVM e árvores de decisão na seção 2.7, optou-se por utilizar neste trabalho os algoritmos SMOREG e M5Rules, que são aplicações dos respectivos métodos (FRANK; HALL; WITTEN, 2016). Os algoritmos fazem parte da plataforma Weka para mineração de dados, tendo sido utilizada a versão 3.8 do software (FRANK; HALL; WITTEN, 2016).

SMOreg implementa o algoritmo de otimização mínima sequencial para aprender um modelo de regressão de vetor de suporte. Para execução desse algoritmo, optou-se pela normalização da base. A normalização dimensiona todos os valores numéricos no conjunto de dados para que estejam entre 0 e 1. Os valores normalizados podem ser escalados e traduzidos com constantes fornecidas pelo usuário (FRANK; HALL; WITTEN, 2016). Já o algoritmo M5Rules obtém regras de regressão de árvores construídas usando o modelo de aprendizado por árvore denominado M5. (FRANK; HALL; WITTEN, 2016).

4. RESULTADOS E DISCUSSÃO

4.1. Mineração de dados e criação dos modelos preditivos

Após a geração das bases foi realizada a execução das bases nos algoritmos SMOREG e M5Rules, conforme especificado no item 3.6.

A execução de cada base foi repetida três vezes para contemplar isoladamente cada câmera e o índice de vegetação (RGB, NIR e NDVI) com diferentes atributos (R, G e B para câmera RGB; R, G e NIR para a câmera NIR; o valor do índice para o NDVI) para predição de severidade (severidade da doença como atributo meta). Consequentemente, foi gerada uma regra para cada grupo de atributos utilizado em cada repetição. Optou-se por essa divisão na execução para testar isoladamente o potencial de predição de cada câmera (RGB e NIR) e do NDVI. A Tabela 9 apresenta os coeficientes de correlação para cada uma das bases geradas e processadas pelo algoritmo SMOREG, com destaque para os coeficientes superiores a 0,9.

Tabela 9 - Coeficientes de correlação entre as bandas e o NDVI com a severidade da ferrugem asiática da soja para o algoritmo SMOREG

Proporção	Data		
	RGB	NIR	NDVI
25/02/2016			
20%	0,5883	x	x
40%	0,5980	x	x
70%	0,5998	x	x
04/03/2016			
20%	0,9331	0,8235	0,3733
40%	0,9334	0,8237	0,3781
70%	0,9332	0,8231	0,3730
08/03/2016			
20%	0,9441	0,9270	0,8752
40%	0,9445	0,9267	0,8742
70%	0,9449	0,9272	0,8750
14/03/2016			
20%	0,9669	0,9415	0,8776
40%	0,9671	0,9415	0,8786
70%	0,9672	0,9416	0,8787

Fonte: do autor

É possível observar que o número de pontos da base (tamanho amostral) mostrou-se pouco significativo para criação de modelos pelo algoritmo SMOREG (Tabela 9), visto que a correlação variou a partir da terceira e quarta casa decimal para as diferentes proporções.

Nota-se também que a partir da data de voo 04/03/2016 (relacionado com leitura em campo de 03/03/2016 - Estádio fenológico R5.3) a correlação sempre foi maior que 0,93 para as bandas da câmera RGB (R, G e B), ao passo que para a câmera NIR apenas após 08/03/2016 (relacionado com leitura em campo de 11/03/2016 - Estádio fenológico R6) conseguiu-se obter um coeficiente de correlação maior que 0,9. Os modelos gerados com o NDVI se mostraram menos eficientes do que aqueles gerados com os canais das bandas RGB e NIR.

Outro ponto de destaque é que a correlação sempre foi maior para a câmera RGB e que foi possível obter valores acima de 0,9 (90%) em uma data anterior (04/03/2016) que a câmera NIR e o NDVI para o algoritmo SMOREG. A Tabela 10 mostra as equações de estimativa de severidade (ES) que possuem coeficiente de correlação maior que 0,9, em suas respectivas datas de voo.

Tabela 10 - Equações onde a correlação foi maior que 0,9 para o algoritmo SMOREG

Proporção		Data de voo
		04/03/2016
	RGB	NIR
20%	ES = 2,4109 * (normalized) R – 1,3257 * (normalized) G - 0.7712 * (normalized) B + 0.2165	x
40%	ES = 2,4583 * (normalized) R – 1,3552 * (normalized) G – 0,768 * (normalized) B + 0,2276	x
70%	ES = 2,4478 * (normalized) R – 1,3946 * (normalized) G – 0,7743 * (normalized) B + 0,2169	x
08/03/2016		
20%	ES = 5,3147 * (normalized) R – 4,5756 * (normalized) G + 0,5268 * (normalized) B + 0,2179	ES = 1,3265 * (normalized) R_NIR + 2,9422 * (normalized) G_NIR - 4,4636 * (normalized) NIR + 0,8184
40%	ES = 5,4719 * (normalized) R – 4,6998 * (normalized) G + 0,5378 * (normalized) B + 0,216	ES = 1,2011 * (normalized) R_NIR + 3,0869 * (normalized) G_NIR – 4,5141 * (normalized) NIR + 0,8218
70%	ES = 5,6217 * (normalized) R – 4,9258 * (normalized) G + 0,5385 * (normalized) B + 0,215	ES = 1,1952 * (normalized) R_NIR + 3,1086 * (normalized) G_NIR – 4,5222 * (normalized) NIR + 0,8135
14/03/2016		
20%	ES = 4,2677 * (normalized) R – 2,24 * (normalized) G – 1,2115 * (normalized) B – 0,0031	ES = 1,007 * (normalized) R_NIR - 0,2787 * (normalized) G_NIR – 1,6141 * (normalized) NIR + 0,8912
40%	ES = 4,261 * (normalized) R – 2,2565 * (normalized) G – 1,2178 * (normalized) B + 0,0007	ES = 1,0121 * (normalized) R_NIR - 0,272 * (normalized) G_NIR – 1,6757 * (normalized) NIR + 0,9057
70%	ES = 4,3047 * (normalized) R – 2,2438 * (normalized) G – 1,2261 * (normalized) B - 0,0029	ES = 1,0251 * (normalized) R_NIR - 0,2944 * (normalized) G_NIR – 1,6335 * (normalized) NIR + 0,9071

Fonte: do autor

Assim como não houve grande diferença entre os coeficientes de correlação para diferentes bases das proporções utilizadas (20%, 40% e 70%), observa-se que igualmente não existe grande diferença entre as equações entre diferentes proporções em uma mesma câmera. Importante notar também que os valores dos atributos nas equações estão todos normalizados (variando entre 0 e 1), conforme explicado no item 3.5.

A Tabela 11 mostra os resultados obtidos para o algoritmo M5Rules.

Tabela 11 - Coeficientes de correlação entre as bandas e o NDVI com a severidade da ferrugem asiática da soja para o algoritmo M5Rules

Proporção	25/02/2016		
	RGB	NIR	NDVI
20%	0,6807	x	x
40%	0,7004	x	x
70%	0,7116	x	x
	04/03/2016		
	RGB	NIR	NDVI
20%	0,9568	0,8791	0,4728
40%	0,9593	0,8812	0,4823
70%	0,9607	0,8823	0,4775
	08/03/2016		
	RGB	NIR	NDVI
20%	0,9686	0,9628	0,9288
40%	0,9700	0,9637	0,9293
70%	0,9708	0,9641	0,9298
	14/03/2016		
	RGB	NIR	NDVI
20%	0,9754	0,9652	0,9313
40%	0,9767	0,9664	0,9340
70%	0,9777	0,9663	0,9333

Fonte: do autor

Os resultados obtidos foram similares aos apresentados pelo algoritmo SMOREG para as câmeras RGB e NIR, com a exceção de que os valores dos coeficientes de correlação são maiores e que os coeficientes de correlação para o NDVI foram maiores que 0,9 a partir da data de voo 08/03/2016 (relacionada com leitura em campo de 11/03/2016 - Estádio de desenvolvimento da soja R6).

Os valores dos coeficientes de correlação para o algoritmo M5Rules são maiores que os coeficientes do SMOREG possivelmente porque ele gera várias equações para diversas subdivisões de valores de atributos na base, fazendo uma especialização do

conhecimento, ao passo que o SMOREG busca criar um modelo genérico em apenas uma equação, conforme descrito no item 2.7. Por exemplo, na base de 20% para a câmera RGB no algoritmo M5Rules, foram obtidas 59 regras que formam o modelo para essa base. A Tabela 12 apresenta as duas primeiras regras desse modelo.

Tabela 12 - Duas primeiras regras do modelo da base de 20% para o algoritmo M5Rules

Nº	Condição	Equação de estimativa
1	SE	
	R ≤ 2948,26	
	B > 1838,119	
	R ≤ 2804,315	
	B ≤ 2148,969	ES = 0,0519 * R - 0,0153 * G - 0,0362 * B + 8,6801
	R ≤ 2649,004	
	B ≤ 2036,486	
	R > 2469,076	
	G ≤ 3642,061	
	B > 1936,936	
2	SE	
	R ≤ 2948,26	
	B ≤ 1831,135	ES = 0,0968 * R - 0,0976 * G + 0,0098 * B + 115,9051
	R > 2524,64	
	R > 2697,149	

Fonte: do autor

No trabalho de Rumpf et al. (2010), foi indicado que a precisão do classificador aumentou a medida que a severidade da ferrugem da beterraba aumenta. A partir dos resultados mostrados nas Tabela 9 e Tabela 11, é possível observar que o valor do coeficiente de correlação apresentou tendência a aumentar com o aumento da severidade, independente do modelo utilizado (RGB, NIR e NDVI). Isso é de certa forma esperado visto que é mais fácil estabelecer um modelo quando se possui amostras mais representativas (no caso, um gradiente maior de valor de severidade distribuído entre as 44 parcelas à medida que os sintomas aumentam em diferentes velocidades), o que justamente mostra a dificuldade em tentar prever o valor de uma variável quando não se possui boa representatividade amostral. Em contrapartida, quando se cria um modelo de predição, quanto antes as amostras forem suficientes para uma predição com nível de precisão aceitável, melhor.

Como houve diferença entre os coeficientes de correlação das datas de voo 25/02/2016 (estádio fenológico R5.1) e 04/03/2016 (estádio de fenológico R5.3) para a

câmera RGB, provavelmente os estádios fenológicos da cultura da soja que melhor permitem a detecção usando o espectro visível se encontram em períodos após R5, de acordo com as tendências de correlação observadas nas Tabela 9 e Tabela 11.

Nos trabalhos de Calderón et al. (2013), Zarco-Tejada et al. (2013) e Berni et al. (2009) é demonstrado que o índice de reflectância fotoquímica (PRI₅₇₀) foi eficiente para detecção de doença por sua alta correlação com o pigmento da xantofila, responsável pela cor amarela das folhas quando em maior proporção que a clorofila. Esse índice é baseado em frequências da banda do visível como a câmera RGB, porém só é possível realizar o seu cálculo com as frequências específicas de 570 nm e 531 nm, conforme mostrado anteriormente na equação 3. No trabalho de Sugiura et al. (2016) também foi estimada a severidade de doença utilizando uma câmera RGB obtendo 0,77 de correlação.

Os coeficientes de correlação obtidos corroboram com a ideia de que para detecção de patógenos que causam o amarelecimento foliar, frequências do espectro visível possuem alta correlação. Ou seja, estes resultados indicam a possibilidade de inserção dos RPAs na identificação da severidade da ferrugem asiática em áreas comerciais do cultivo de soja.

Os voos ocorreram na área onde a semeadura foi realizada na segunda época (16 de dezembro). Silva, Juliatti e Silva (2007) observaram que a ferrugem asiática é mais agressiva em semeaduras tardias, com grande e acelerada desfolha, o que causou redução drástica na produtividade da primeira para a segunda época. Ou seja, há necessidade de voos em áreas com diferentes épocas de semeadura.

Outro fato relevante é que estes dados de correlação foram obtidos em duas avaliações (estádios fenológicos R5.3 e R6), sendo que em geral, as cultivares apresentam maior suscetibilidade a infecção desde o início da fase vegetativa até o início do florescimento (V1 a R1), pois a cultura está em constante crescimento e não está bem desenvolvida (BALARDIN et al., 2006). Futuros experimentos são necessários para estimar a severidade da ferrugem asiática por imagens de RPAs, para avaliar a correlação e identificar qual estágio fenológico é o mais adequado para realizar os voos.

A constatação dos primeiros sintomas da ferrugem asiática é de suma importância, pois a aplicação no momento ideal torna-se fundamental para a eficiência do controle químico. Pesquisas de vários autores têm demonstrado a baixa eficiência dos produtos quando não utilizados na época certa, ou seja, preventivamente ou com baixa severidade do patógeno (GODOY et al., 2009; NAVARINI et al., 2007). Devido à

importância da cultura da soja pra o agronegócio, o modelo preditivo de estimativa da severidade baseado em valores de reflectância espectral pode ser uma forma rápida e eficiente de observar a ocorrência e quantificar a severidade auxiliando no manejo da doença.

5. CONCLUSÃO

Aeronaves remotamente pilotadas possuem potencial de aplicação na detecção de doenças como a ferrugem asiática da soja, que causa o amarelecimento foliar e desfolha.

O acompanhamento da área experimental próximo ao estágio fenológico R5 apresenta maior probabilidade para obtenção de alta correlação com o nível de severidade da ferrugem asiática da soja com a câmera RGB.

Foi possível concluir também que os modelos gerados com o algoritmo SMOREG são uma boa opção para a estimativa da ferrugem asiática da soja, visto que os modelos gerados são mais genéricos e menos especializados que os modelos gerados pelo algoritmo M5Rules.

Para trabalhos futuros, seria importante a realização de correção radiométrica das imagens através da irradiância solar, o que permitiria uma análise com dados de reflectância mais precisos e a validação e aprimoramento dos modelos obtidos neste trabalho. Sugere-se também a criação de uma única base de dados a partir de imagens de várias missões de voo em diferentes estádios fenológicos da cultura, com o propósito de tentar estabelecer uma regra mais genérica para detecção da severidade da ferrugem asiática da soja em períodos anteriores aos conseguidos nesse trabalho.

Finalmente, a análise de modelos de regressão gerados com resoluções menores que 3,4 cm/pixel é um trabalho relevante, visto que o uso de resoluções menores diminui o tempo de voo, de processamento das imagens e de mineração dos dados extraídos das mesmas.

REFERÊNCIAS

AMORIM, L.; RESENDE, A. M.; FILHO, A. B. Manual de fitopatologia. Brasília, 2011.

APTÉ, J. C.; WEISS, S. Data mining with decision trees and decision rules. **Future Generation Computer Systems**, v. 13, p. 197-210. 1997.

BALARDIN, R. S.; DALLAGNOL, L. J.; DIDONÉ, H. T.; NAVARINI, L. Influência do Fósforo e do Potássio na Severidade da Ferrugem da Soja *Phakopsora pachyrhizi*. **Fitopatologia Brasileira**, Brasília, v. 31, n. 4, p. 462-467. 2006.

BERNI, J. A. J.; ZARCO-TEJADA, P. J.; SUARÉZ, L.; FERERES, E. 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, mar. 2009.

CALDERÓN, R.; NAVAS-CORTÉS, J. A.; LUCENA, C.; CATALINA, A.; ZARCO-TEJADA, P. J. High-resolution airborne hyperspectral and thermal imagery for early detection of Verticillium wilt of olive using fluorescence, temperature and narrow-band spectral indices. **Remote Sensing of Environment**, v. 139, 2013.

CAMPBELL, J. B. WYNNE, R. H. Introduction to remote sensing. Quinta edição. The Guilford Press. Nova York-Londres. 2011.

CARLSON, T. N.; RIPLEY, D. A. On the Relation between NDVI, Fractional Vegetation Cover, and Leaf Area Index. **Remote Sensing of Environment**. v. 62, 1997.

CÓRCOLES, J. I.; ORTEGA, J. F.; HERNÁNDEZ, D.; MORENO, M. A. Estimation of leaf area index in onion (*Allium cepa* L.) using an unmanned aerial vehicle. **Biosystems Engineering**, v. 115, 2013.

CONAB, Companhia Nacional do abastecimento. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/16_12_13_11_37_10_boletim_graos_dezembro_2016.pdf> Acesso em: 14 de dez de 2016.

DECEA - Departamento de controle do espaço aéreo. Sistemas de aeronaves remotamente pilotadas e o acesso ao espaço aéreo Brasileiro. 2015.

DUTRA, E. P. Uso de VANTs na Agricultura – Obtenção e Tratamento de Dados. Trabalho de conclusão de curso – artigo. Ponta Grossa: Universidade Estadual de Ponta Grossa, 2014.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro nacional de Pesquisa de Solos. Sistema brasileiro de classificação de solos. Rio de Janeiro, p.306. 2006.

EMBRAPA. Agricultura de precisão, resultados de um novo olhar. Brasília, DF, p. 120. 2014.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Disponível em: <<http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Soja/SojaCentralBrasil2003/doenca.htm>>. Acesso em: 05 mar. 2016.

FAPCEN, Fundação de apoio a Pesquisa do Corredor de Exportação Norte. Disponível em: <<http://www.fapcen.agr.br/?p=80>> Acesso em: 05 de out de 2015.

FEHR, W. R.; CAVINESS, C. E. Stages on soybean development. Ames: Iowa State University/Cooperative Extension Service, p.11 (Special Report, 80). 1977.

FRANK E.; HALL M. A.; WITTEN, I. H. (2016). The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques", **Morgan Kaufmann**, v. 4, 2016.

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

GILL, M.K.; ASEFA, T.; KEMBLOWSKI, M.W.; MCKEE, M. Soil Moisture Prediction using Support Vector Machines. **Journal of the American Water Resources Association**. v.42 (4), p.1033–1046, 2006.

GIS Development Team. QGIS Geographic Information System. Open Source Geospatial. Disponível em: URL <http://QGIS.osgeo.org>. Acesso em: 05 set. 2016a.

GIS. Documentação do QGIS - Georreferenciador. Disponível em: URL https://docs.QGIS.org/2.2/pt_BR/docs/user_manual/plugins/plugins_georeferencer.html. Acesso em: 05 set. 2016b.

GODOY, C.V.; CANTERI, M.G. Efeitos protetor, curativo e erradicante de fungicidas no controle da ferrugem da soja causada por *Phakopsora pachyrhizi*, em casa de vegetação. **Fitopatologia brasileira**, v. 29, p. 97-101, 2004.

GODOY, C.V.; KOGA, L. J.; CANTERI, M.G. Diagrammatic scale for assessment of soybean rust severity. **Fitopatologia brasileira**, v. 31, 2006.

GODOY, C. V.; FLAUSINO, A. M.; SANTOS, L. C. M.; PONTE, M. D. P. Eficiência do controle da ferrugem asiática da soja em função do momento de aplicação sob condições de epidemia em Londrina, PR. **Tropical Plant Pathology**, Brasília, v. 34, n. 1, p. 56-61. 2009.

GODOY, C.V.; UTIAMADA, C. M; MEYER, M. C.; CAMPOS, H. D.; ROESE A. D.; FORCELINI, A. D. Eficiência de fungicidas para o controle da ferrugem-asiática da soja, *Phakopsora pachyrhizi*, na safra 2013/14: resultados sumarizados dos ensaios cooperativos. Londrina. Resumos. Londrina, 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, 2013.

HABOUDANE, D.; MILLER, J. R.; PATTEY, E.; ZARCO-TEJADA, P. J.; STRACHAN, I. B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**. V. 90, 2004.

HARTMAN, G. L.; WANG, T. C.; SHANMUGASUNDARAM, S. Soybean rust research: progress and future prospects. In: WORLD SOYBEAN RESEARCH CONFERENCE, 5. 1994.

HENNING, A. A.; ALMEIDA, A. M.; GODOY, C. V.; SEIXAS, C. D. S.; YORINORI, J. T.; COSTAMILAN, L. M.; FERREIRA, L. P.; MEYER, M. C.; SOARES, R. M.; DIAS, W.P. Manual de identificação de doenças de soja. 5.ed. Londrina: Embrapa Soja, 2014.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, 1988, v. 25, p. 295-309.

IAPAR, Instituto Agrônomo do Paraná. Disponível em :<<http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=863>> Acesso em: 05 de out de 2015.

JULIATTI, F. C. Perdas causadas por doenças na cultura da soja, com ênfase na ferrugem asiática. In: Workshop de epidemiologia de doenças de plantas, quantificação de doenças de plantas, quantificação de perdas no manejo de doenças de planta. Anais. 1. 2005, Viçosa. UFV. p. 81-94. 2005.

KOGA, L. J.; CANTERI, M. G.; GODOY, C. V. Relação entre medidas de reflectância e área foliar sadia, severidade da ferrugem asiática e produtividade da cultura da soja. **Ciências Agrárias**. V. 28, n. 4, 2007.

LIBA, N., BERG-JÜRGENS, J. (2015) Accuracy of Orthomosaic Generated by Different Methods in Example of UAV Platform MUST Q. IOP Conference Series: Materials Science and Engineering, 96(1), 8.

MAPA, Ministério da Agricultura, Pecuária e Abastecimento. SOJA. Disponível em: <http://www.agricultura.gov.br/vegetal/culturas/soja>. Acesso em: 24 fev. 2014.

MAUAD, M.; SILVA, B.L.T.; NETO, A.I.A.; ABREU, V.G. Influência da densidade de semeadura sobre características agrônomicas na cultura da soja. **Revista Agrarian**.v.3, n.9, p.175-181, 2010.

MENESES, P. R.; ALMEIDA, T, Introdução ao processamento de imagens de sensoriamento remoto. Brasília, 2012.

MEYER, P.; ITTEN, I. K.; KELLENBERGER, T.; SANDMEIER, S.; SANDMEIER, R. Radiometric corrections of topographically induced effects on Landsat TM data in an alpine. **Journal of Photogrammetry and Remote Sensing**, v. 48(4): 17-28, 1993.

MOTTA, J. L. G. Subsídios à previsão de safra da soja no rio grande do sul usando técnicas de geoprocessamento e sensoriamento remoto. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2002.

MYNENI, R. B.; HALL, F. G.; SELLERS, P. J.; MARSHAK, A. L. The interpretation of spectral vegetation indexes. **Geoscience and Remote Sensing**. v. 33, 1995.

NAVARINI, L.; DALLAGNOL, L. J.; BALARDIN, R. S.; MOREIRA, M. T.; MENEGHETTI, R. C.; MADALOSSO, M. G. Controle químico da ferrugem asiática (*Phakopsora pachyrhizi* Sydow) na cultura da soja. **Summa Phytopathologica, Botucatu**, v. 33, n. 2, p. 182-186. 2007.

NAVIDI, W. Probabilidade e estatística para ciências exatas. AMGH Editora. ed. 1 p. 433. 2012.

NIDERA Sementes, Disponível em: < <http://www.niderasementes.com.br/produto/na-5909-rg--sul.aspx>> Acesso em: 14 dez. 2016.

PIX4D. Pix4D Software Manual Pix4D Support. Lausanne, Suíça: Pix4D SA. Disponível em: <https://support.pix4d.com/hc/en-us/articles/204272989-Offline-Getting-Started-and-Manual-pdf-#gsc.tab=0>. Acesso em: 05 dez. 2016 (a).

PIX4D. Pix4D Software, Camera Requirements for Precision Agriculture. Disponível em: <https://support.pix4d.com/hc/en-us/articles/204894705-Camera-Requirements-for-Precision-Agriculture#gsc.tab=0>. Acesso em: 05 dez. 2016 (b).

POINT SAMPLING TOOL. QGIS Software, Sampling Raster Data using Points or Polygons. Disponível em: http://www.qgistutorials.com/pt_BR/docs/sampling_raster_data.html. Acesso em: 05 dez. 2016.

PUTZEK, J; PUTZEK, M. T. L. Os reinos dos fungos. Santa Cruz do Sul: EDUNISC, v1. p. 606. 1998.

REIS, E. M.; BRESOLIN, A. C. R.; CARMONA, M. Doenças da soja I – Ferrugem asiática. Passo Fundo, 2006.

RITCHIE, S. W.; HANWAY, Y. J.; THOMPSON, H. E.; BENSON, G. O. How a soybean plant develops. Ames, Iowa State University of Science and technology. p. 20.1997.

ROESE, A. D.; ROMANI, R. D.; FURLANETTO, C.; STANGARLIN, J. R.; PORTZ, R. L. Levantamento de doenças na cultura da soja, *Glycine max* (L.) Merrill, em municípios da região Oeste do Estado do Paraná. **Acta Scientiarum**. V. 23, n. 5, 2001.

RUMPF, T.; MAHLEIN, A. K.; STEINER, U.; OERKE, E. C.; DEHNE, H. W.; PLÜMER, L. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. **Computers and Electronics in Agriculture**. v. 74, p. 91-99, 2010.

SANTIAGO-CINTRA, eBee – Camera S110, Santiago e Cintra Geotecnologias, São Paulo, 2016a.

SANTIAGO-CINTRA, eBee – Camera WX, Santiago e Cintra Geotecnologias, São Paulo, 2016b.

SATELLITE IMAGING CORP. Satellite Imaging Corporation – World-view 4. Disponível em: <http://www.satimagingcorp.com/satellite-sensors/geoeye-2/>, 2017.

SENSEFLY. Especificações do VANT eBee. Disponível em: <http://www.santiagoocintra.com.br/Produtos.aspx?idSubCategoria=c6acc237-cb4d-42f9-8adf-e64bcee72b4f>, Acesso em: 05 out. 2015.

SENSEFLY. Software Emotion 2. Disponível em: <https://www.sensefly.com/software/emotion-2.html>, Acesso em: 05 dez. 2016.

SILVA, V. A.; JULIATTI, F. C.; SILVA, L. A. Interação entre resistência genética parcial e fungicidas no controle da ferrugem asiática da soja. Pesquisa Agropecuária Brasileira. [online]. 2007, v. 42, n. 9, p. 1261-1268. Disponível em: <<http://dx.doi.org/10.1590/S0100-204X2007000900007>>. Acesso em: 15 set. 2014.

SINCLAIR, J. B.; HARTMAN, G. L. Soybean Rust. In: HARTMAN GL, Sinclair JB, Rupe JC (Eds.). Compendium of Soybean Diseases. 4 ed. Saint paul MN. APS Press, p. 25-26, 1999.

STRECK, N. A.; PAULA, G. M.; CAMERA, C.; MENEZES, N. L.; LAGO, I. Estimativa do plastocrono em cultivares de soja. **Bragantia**, Campinas, v. 67, p. 67-73, 2008.

SUGIURA R.; TSUDA, S.; TAMIYA, S.; ITOH, A.; NISHIWAKI, K.; MURAKAMI, N.; SHIBUYA, Y.; HIRAFUJI, M., NUSKE, S. Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. **Biosystems engineering**, v. 148, p. 1-10, 2016.

TAN, P.; STEINBACH N.; KUMAR, V. Introduction to Data Mining. Addison-Wesley. v.1. 2006.

TEILLET. E. M.; Image correction for radiometric effects in remote sensing. **Int. J. Remote Sensing**, v.7(12): p.1637-1651, 1986.

TRIMBLE. GPS Trimble ProXT. Disponível em: <http://www.santiagoocintra.com.br/produtos?cod=21&cat=107>, Acesso em: 05 dez. 2016.

USDA, United States Department of Agriculture. Disponível em: <http://www.ers.usda.gov/topics/crops/soybeans-oil-crops.aspx#.UgjZMqyQaZQ>. Acesso em: 14 dez. 2016.

XIANG, H.; TIAN, L. Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. **Biosystems Engineering**, v. 108, n. 2, p. 104-113 2011.

WU, X.; KUMAR, V.; QUINLAN, J. R.; GROSH, J.; YANG, Q.; MOTODA, H.; MCLACHLAN, G. J.; NG, A.; LIU, B.; YU, P. S.; ZHOU, Z.; STEINBACH, M.; HAND, D. J.; Steinberg, D. Top 10 algorithms in data mining. **Knowledge and Information Systems**, v. 14, p. 1-37. 2008.

YANG, C. A high-resolution airborne four-camera imaging system for agricultural remote sensing. **Computers and electronics in Agriculture**, v. 88, out. 2012.

YORINORI, J. T. Situação atual das doenças potenciais no Cone Sul. In: CONGRESSO BRASILEIRO DE SOJA E MERCOSOJA, 2, 2002, Foz do Iguaçu. Anais Foz do Iguaçu: [s.n.], 2002. p. 171-186.

YORINORI, J. T.; PAIVA, W. M.; FREDERICK, R. D.; COSTAMILAN, L. M.; BERTAGNOLLI, P. F.; HARTMAN, G. E.; GODOY, C. V.; NUNES JUNIOR, J. Epidemics of soybean rust (*Phakopsora pachyrhizi*) in Brazil and Paraguay (from 2001 to 2003). **Plant Disease**, Saint Paul, v. 89, n. 6, p. 675-677. 2005.

YORINORI T. J. Soybean “asian” rust in the american continente: evolution, economic importance and control strategies, Soybean Asian Rust: etology, epidemiology and management. 1ª edição. Uberlandia: Edufu. p. 23-42. 2006.

YORINORI T. J.; Nunes junior J. Soybean Germplasm with Resistance and Tolerance to “Asian” Rust and Screening Methods. In: SOUTH AMERICAN WORKSHOP ON SOYBEAN RUST. 2006.

ZARCO-TEJADA, P. J.; GUILLÉN-CLIMENT, M. L.; HERNÁNDEZ-CLEMENTE, R.; CATALINA, A.; GONZÁLEZ, M. R.; MARTÍN, P. Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). **Agricultural and Forest Meteorology**, v. 171-172, 2013.