

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta dissertação será disponibilizado somente a partir de 14/10/2024.



GLÓRIA MARIA PADOVANI EDERLI

**CLASSIFICAÇÃO DE ÁREAS INFESTADAS COM NEMATOIDES
BASEADA EM ALGORITMOS DE APRENDIZADO DE MÁQUINA
UTILIZANDO IMAGENS HIPERESPECTRAIS DE ALTA RESOLUÇÃO
ESPACIAL**



Presidente Prudente - SP

2023

GLÓRIA MARIA PADOVANI EDERLI

**CLASSIFICAÇÃO DE ÁREAS INFESTADAS COM NEMATOIDES
BASEADA EM ALGORITMOS DE APRENDIZADO DE MÁQUINA
UTILIZANDO IMAGENS HIPERESPECTRAIS DE ALTA RESOLUÇÃO
ESPACIAL**

Dissertação de mestrado apresentada ao Programa de Pós-graduação em Ciências Cartográficas da Faculdade de Ciência e Tecnologia – UNESP – Universidade Estadual “Júlio de Mesquita Filho” – Campus de Presidente Prudente – SP, como parte dos requisitos para obtenção do título de Mestre em Ciências Cartográficas.

Orientador: Prof. Dr. Aluir Porfírio Dal Poz

Coorientadores: Prof. Dr. Nilton Nobuhiro Imai e
Prof. Dr. Adilson Berveglieri

Presidente Prudente - SP

2023

E22c

Ederli, Glória Maria Padovani

Classificação de áreas infestadas com nematoides baseada em algoritmos de aprendizado de máquina utilizando imagens hiperespectrais de alta resolução espacial / Glória Maria Padovani Ederli. -- , 2024

88 p. : il., tabs., fotos, mapas

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Farmacêuticas, Araraquara,

Orientador: Aluir Porfírio Dal Poz

Coorientador: Nilton Nobuhiro Imai

1. Ciências exatas. 2. Sensoriamento remoto. 3. Agricultura de precisão. I.
Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências
Farmacêuticas, Araraquara. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

O IMPACTO ESPERADO

A pesquisa propõe o uso de sensoriamento remoto para detectar nematoides em plantações de soja, reduzindo custos e aumentando eficiência. O benefício inclui manejo mais preciso, preservação da produtividade agrícola e potencial impacto econômico ao evitar perdas.

THE EXPECTED IMPACT

The research proposes the use of remote sensing to detect nematodes in soybean fields, reducing costs and increasing efficiency. The benefits include more precise management, preservation of agricultural productivity, and potential economic impact by preventing losses.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: CLASSIFICAÇÃO DE ÁREAS INFESTADAS COM NEMATÓIDES BASEADA EM ALGORITMOS DE APRENDIZADO DE MÁQUINA UTILIZANDO IMAGENS HIPERESPECTRAIS DE ALTA RESOLUÇÃO ESPACIAL

AUTORA: GLÓRIA MARIA PADOVANI EDERLI

ORIENTADOR: ALUIR PORFIRIO DAL POZ

COORDENADOR: NILTON NOBUHIRO IMAI

COORDENADOR: ADILSON BERVEGLIERI

Aprovada como parte das exigências para obtenção do Título de Mestra em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:



Documento assinado digitalmente

ALUIR PORFIRIO DAL POZ

Data: 30/01/2024 15:06:00-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. ALUIR PORFIRIO DAL POZ (Participação Presencial)

Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Virtual)

Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Prof. Dr. FÁBIO FERNANDO DE ARAÚJO (Participação Virtual)

Programa de Pós-graduação em Agronomia / Universidade do Oeste Paulista

Presidente Prudente, 19 de abril de 2023

DEDICATÓRIA

À minha família por todo amor, apoio e por proporcionarem momentos de alegria. Aos meus amigos pelo companheirismo.

AGRADECIMENTOS

À Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido durante o desenvolvimento do projeto de pesquisa, por meio da bolsa de estudo (Processo 88887.482203/2020-00).

Ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) e à Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP) pela infraestrutura disponibilizada, fundamental para a realização da pesquisa de mestrado.

Aos meus coorientadores, Prof. Dr. Nilton Nobuhiro Imai e Prof. Dr. Adilson Berveglieri, expresso minha profunda gratidão pelos ensinamentos e constante apoio ao longo desta desse trabalho.

Ao Prof. Dr. Aluir Porfírio Dal Poz, sou grata pela orientação sólida e pelo incentivo ao longo dos últimos anos, que foram fundamentais para o meu crescimento acadêmico e profissional.

Aos amigos e colegas do PPGCC, em especial à turma do processo seletivo de 2020 e aos frequentadores do Laboratório de Fotogrametria e Sensoriamento Remoto, agradeço pelas conversas e contribuições. À Allana, Roberta, Vitória, João e Mariana, pela amizade.

Expreso minha gratidão a todos os professores do Departamento de Cartografia e do PPGCC, cujos ensinamentos durante os cursos de graduação e pós-graduação foram fundamentais para minha formação.

À banca de qualificação e da defesa final, agradeço pelas correções e sugestões construtivas, que foram essenciais para aprimorar a versão final desta dissertação.

Aos meus pais, Antonio e Sueli, por seu apoio, e aos meus irmãos, Jonas, Natana, Daniel, Rebeca e Maria Angélica, por estarem sempre presentes, oferecendo ajuda e suporte. Um agradecimento especial à minha sobrinha Helena, por proporcionar momentos de alegria.

Agradeço a todos que, de forma direta ou indireta, contribuíram para a realização deste trabalho. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

A detecção de nematoides em plantações é fundamental para evitar prejuízos na produtividade, entretanto, o diagnóstico preciso da distribuição populacional requer uma grande quantidade de amostras de solo e de raiz em todo o campo, o que implica em um custo elevado. Nesse contexto, as técnicas de sensoriamento remoto podem auxiliar no manejo e controle dos nematoides, especialmente as que envolvem Veículos Aéreos Não Tripulados (VANTs). Este estudo propõe o uso de imagens hiperespectrais obtidas por câmera embarcada em VANT e técnicas de fotogrametria e sensoriamento remoto, para detectar e classificar as áreas parasitadas por nematoides na cultura de soja, de acordo com a intensidade de infestação a partir de algoritmos de aprendizado de máquina juntamente com amostras de solo coletadas em campo para validação. Foram testados os algoritmos de aprendizado de máquina *Random Forest*, *Support Vector Machine* e *K-Nearest Neighbors*, além do índice desenvolvido que relaciona os fitonematoides de uma região com os nematoides de vida livre (IFVL). Foram calculadas as matrizes de confusão e as métricas estatísticas sensibilidade, precisão, F_1 -score, RMSE e acurácia balanceada para avaliar os modelos gerados. Os resultados indicam que o melhor modelo foi obtido com o algoritmo *Random Forest*, e que a melhor divisão da intensidade de infestação de nematoides foi representada por cinco classes calculadas a partir do IFVL que alcançou uma acurácia balanceada de 96,5%. Também foi avaliado o melhor período fenológico para a coleta dos dados, que apresentou ser no fim do período reprodutivo, quando a diferença espectral entre as plantas saudáveis e parasitadas com fitonematoides aumenta, em que a região entre 771 nm e 790 nm demonstrou grande importância para detectar as áreas parasitadas. Portanto, este estudo conclui que as imagens hiperespectrais podem ser uma alternativa para o manejo e controle de fitonematoides em culturas de soja, reduzindo custos e aumentando a eficiência na detecção de áreas infectadas.

Palavras-chave: Agricultura de precisão, Nematoides, Aprendizado de Máquina, Imagens hiperespectrais.

Abstract

The detection of nematodes in plantations is fundamental to avoid losses in productivity, however, the precise diagnosis of population distribution requires a large amount of soil and root samples throughout the field, which implies a high cost. In this context, remote sensing techniques can support in nematode management and control, especially those involving Unmanned Aerial Vehicles (UAVs). This study proposes the use of hyperspectral images obtained by a camera onboard UAVs and remote sensing and photogrammetry techniques to detect and classify areas parasitized by nematodes in soybean crops according to the intensity of infestation using machine learning algorithms along with soil samples collected in the field for validation. Machine learning algorithms including Random Forest, Support Vector Machine, and K-Nearest Neighbors, as well as the developed index that relates plant parasitic nematodes to free-living nematodes (IFVL), were tested. Confusion matrix and statistical metrics including , sensitivity, precision, F1-score, RMSE, and balanced accuracy were calculated to evaluate the generated models. Results indicate that the best model was obtained using the Random Forest algorithm and that the best division of nematode infestation intensity was represented by five classes calculated from the IFVL, which achieved a balanced accuracy of 96.5%. The best phenological period for data collection was also evaluated, which was found to be at the end of the reproductive period when the spectral difference between healthy and nematode-infested plants increases, with the region between 771 nm and 790 nm demonstrating great importance in detecting parasitized areas. Therefore, this study concludes that hyperspectral images can be an alternative for nematode management and control in soybean crops, reducing costs and increasing efficiency in detecting infected areas.

Keywords: Precision agriculture, Nematodes, Machine learning, Hyperspectral images.

Lista de tabelas

Tabela - 1 Bandas espectrais do Sentinel-2.	30
Tabela - 2 Especificações técnicas da câmera hiperespectral Rikola.	31
Tabela - 3 Comprimentos de onda central das bandas utilizadas da câmera Rikola.	56
Tabela - 4 Matrizes de confusão normalizadas.	73
Tabela - 5 RMSE.	74
Tabela - 6 Sensibilidade, precisão e F_1 para 2 classes.	75
Tabela - 7 Sensibilidade, precisão e F_1 para 5 classes.	75
Tabela - 8 Sensibilidade, precisão e F_1 para 10 classes.	76
Tabela - 9 Acurácia balanceada.	77
Tabela - 10 Valores numérico de cada classe.	80

Lista de ilustrações

Figura - 1 Escala fenológica da soja.	26
Figura - 2 Raízes da soja: (a) plantas saudáveis e (b) com nematoides das lesões radiculares.	28
Figura - 3 Soja atacada pelo nematoide de galhas: (a) lavoura e (b) raízes.	28
Figura - 4 Câmera hiperespectral Rikola.	31
Figura - 5 Intervalo espectral dos sensores da câmara Rikola.	32
Figura - 6 Princípio do Interferômetro de Fabry-Perot (FPI).	33
Figura - 7 Estrutura interna da planta.	34
Figura - 8 Exemplo do funcionamento do algoritmo <i>Random Forest</i>	39
Figura - 9 Área de estudo localizada no Município de Caiuá.	44
Figura - 10 Divisão dos blocos da fazenda experimental.	45
Figura - 11 Grupo de parcelas utilizadas para a análise das respostas espectrais a partir de imagens da missão Sentinel-2.	46

Figura - 12 Grupo de parcelas utilizadas para extrair informações para treinamento dos algoritmos.	47
Figura - 13 (A) Distribuições dos pontos de amostras nematológicas de uma parcela e (B) área considerada por ponto de amostra.	48
Figura - 14 Estatísticas descritivas das amostras utilizadas como referência.	49
Figura - 15 Distribuição dos pontos das amostras nematológicas utilizadas para análise da resposta espectral.	51
Figura - 16 Distribuição dos pontos de controle e de verificação para fototriangulação das imagens.	52
Figura - 17 Exemplos dos alvos de isopor no ortomosaico. (A) Parcela, (B) e (C) alvos de isopor.	54
Figura - 18 VANT modelo X800 (GEO).	54
Figura - 19 Alvos de referência no processo de calibração por linha empírica.	55
Figura - 20 Espectrorradiômetro FieldSpec® Handheld.	56
Figura - 21 Distribuição dos pontos das amostras nematológicas.	58
Figura - 22 Área considerada para cálculo da média das respostas espectrais.	58
Figura - 23 Exemplo de seleção de conjunto de pixels aleatórios para cálculo da média das respostas espectrais: (A) considerando 50 pixels dentro da área, (B) considerando 75 e (C) considerando 95.	59
Figura - 24 Média das respostas espectrais das classes da data 1 (Dezembro). ...	64
Figura - 25 Média das respostas espectrais das classes da data 2 (Janeiro).	64
Figura - 26 Média das respostas espectrais das classes da data 3 (Fevereiro).	65
Figura - 27 Gráfico das médias das respostas espectrais em dezembro de 2021. ...	65
Figura - 28 Gráfico das médias das respostas espectrais em janeiro de 2022.	66
Figura - 29 Gráfico das médias das respostas espectrais em fevereiro de 2022.	66
Figura - 30 Gráfico da diferença entre as respostas espectrais da data de janeiro e dezembro.	67
Figura - 31 Gráfico da diferença entre as respostas espectrais da data de fevereiro e janeiro.	68
Figura - 32 Ortomosaico gerado a partir das imagens adquiridas pelo DJI Phantom 4.	70

Figura - 33 Exemplos de ortomosaicos gerados a partir das imagens adquiridas pelo sensor hiperespectral.	71
Figura - 34 Gráfico das médias das respostas espectrais para o sensor hiperespectral.	71
Figura - 35 Classificação das variáveis por ordem de importância.	79
Figura - 36 Resultado utilizando o classificador RF e 5 classes.	81

Lista de abreviaturas e siglas

CART	<i>Classification and Regression Trees</i>
CEPEA	Centro de Estudos Avançados em Economia Aplicada
CMOS	<i>Complementary Metal Oxide Semiconductor</i>
Colab	Google Colaboratory
EVA	Etileno Vinil Acetato
ESA	<i>European Space Agency</i>
FPI	<i>Fabry-Perot Interferometer</i>
FSLP	<i>Feature Selection via Linear Programming</i>
FWHM	<i>Full Width at Half Maximum</i>
GNSS	<i>Global Navigation Satellite System</i>
GSD	<i>Ground Sampling Distance</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
ICE	<i>Interactive Correlation Environment</i>
IFVL	Índice fitonematoides e nematoides de vida livre
KNN	<i>K-Nearest Neighbors</i>
MMQ	Método dos Mínimos Quadrados
MSI	<i>MultiSpectral Instrument</i>
ND	Número Digital
NRI	<i>Normalized Ratio Indices</i>
ONU	Organização das Nações Unidas
PIB	Produto Interno Bruto
PPK	<i>Post Processed Kinematic</i>
QGIS	Quantum GIS
RBF	<i>Radial Basis Function</i>

REM	Radiação Eletromagnética
RF	<i>Random Forest</i>
RTK	<i>Real Time Kinematic</i>
SBN	Sociedade Brasileira de Nematologia
SIG	Sistemas de Informação Geográfica
SVM	<i>Support Vector Machine</i>
SWIR	<i>Short-Wave Infrared</i>
TPU	<i>Tensor Processing Unit</i>
UNOESTE	Universidade do Oeste Paulista
USDA	<i>United States Department of Agriculture</i>
VANT	Veículos Aéreos Não Tripulados

Sumário

1	INTRODUÇÃO	17
1.1	Objetivos	20
1.1.1	Geral	20
1.1.2	Específicos	20
1.2	Justificativa	21
1.3	Justificativa	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Fenologia da soja	25
2.2	Nematoides na soja	27
2.3	Missão Sentinel-2	29
2.4	Câmera hiperespectral Rikola	30
2.4.1	FPI	32
2.5	Interação da radiação eletromagnética com a vegetação	33
2.6	Calibração Radiométrica	35
2.7	Aprendizado de máquina na agricultura de precisão	37
2.7.1	Random Forest	37
2.7.2	Support Vector Machine	41
2.7.3	K-Nearest Neighbors	42
3	MATERIAL E MÉTODOS	44
3.1	Materiais	44
3.1.1	Área de estudo e dados	44
3.1.2	Dados de Referência	47
3.1.3	Equipamentos e aplicativos	49
3.2	Metodologia	50
3.2.1	Avaliação das respostas espectrais na cultura da soja com diferentes níveis de infestação por fitonematoides nos estádios fenológicos	50
3.2.2	Levantamento Geodésico	52

3.2.3 Levantamento aéreo e processamento de imagens digitais	53
3.2.4 Índice fitonematoides e nematoides de vida livre	57
3.2.5 Extração de informações para treinamento de algoritmo de aprendizado de máquina	57
3.2.6 Algoritmos de aprendizado de máquina	59
3.2.7 Variáveis de importância	61
3.2.8 Métricas de avaliação dos classificadores	62
4 RESULTADOS E DISCUSSÕES	64
4.1 Análise das respostas espectrais na cultura da soja com diferentes níveis de infestação por fitonematoides nos estádios fenológicos utilizando imagens do sensor MSI/Sentinel-2	64
4.2 Análise das respostas espectrais com diferentes níveis de infestação por fitonematoides utilizando imagens do sensor hiperespectral	69
4.3 Métricas de avaliação dos classificadores	72
4.3.1 Matriz de confusão	72
4.3.2 Sensibilidade, precisão, F_1 score, RMSE e Acurácia balanceada	74
4.3.3 Variáveis por ordem de importância	78
4.4 Mapa temático	80
5 CONCLUSÕES E RECOMENDAÇÕES	82
REFERÊNCIAS	85

1 Introdução

A soja é a principal oleaginosa cultivada em todo o mundo. Durante o período de 2000 a 2020, o Brasil ocupou a posição de segundo maior produtor e exportador de soja. No entanto, a partir de 2020, o país conquistou o primeiro lugar nesse ranking, registrando uma produção de 126 milhões de toneladas e exportando 84 milhões de toneladas. O Brasil é responsável por aproximadamente 50% do comércio mundial de soja, de acordo com dados da Embrapa (ARAGAO; CONTINI, 2020).

Como ocorre em qualquer cultura agrícola, vários fatores podem impactar negativamente o processo de crescimento e produção da soja. Dentre esses fatores, destaca-se a presença de nematoides, especificamente o grupo dos nematoides parasitas de plantas, também conhecidos como fitonematoides. Esses microrganismos do solo possuem a capacidade de parasitar o sistema radicular das plantas ao longo de todo o ciclo de cultivo. Os fitonematoides apresentam baixa mobilidade e interferem na absorção adequada de nutrientes pelas plantas (PINHEIRO, 2022), comprometendo sua saúde ao longo de um período prolongado. Essa condição persiste mesmo após a colheita e pode afetar negativamente as safras subsequentes.

No Brasil, os fitonematoides mais prejudiciais à cultura são os formadores de galhas (*Meloidogyne spp.*), o nematoide de cisto (*Heterodera glycines*), o nematoide das lesões radiculares (*Pratylenchus brachyurus*) e o nematoide reniforme (*Rotylenchulus reniformis*) (DIAS et al., 2010). No oeste do Estado de São Paulo, onde predominam solos arenosos, os fitonematoides de maior predominância são os causadores das lesões radiculares (*Pratylenchus brachyurus*), que são considerados endoparasitas migratórios, e o nematoide das galhas (*Meloidogyne*), um endoparasita sedentário.

Além do grupo dos fitonematoides, outro grupo de nematoides que deve ser levado em consideração quando se trata de cultivares de soja é o grupo de nematoides de vida livre. Esse grupo, ao contrario dos fitonematoides, são organismos benéficos, não afetam a produção vegetal, mas estão diretamente ligados aos processos relevantes no solo, como reciclagem de carbono, compostos nitrogenados e de nutrientes minerais, com efeitos positivos para a fertilidade dos solos e produtividade das culturas agrícolas (FERRAZ; BROWN, 2016). Também são comumente utilizados como indicadores de perturbação ou qualidade do solo (BONGERS; FERRIS, 1999).

O sintoma mais comum que os fitonematoides causam são as reboleiras, que podem ser confundidas com sintomas de outros problemas recorrentes nos cultivos, como mancha de calcário, compactação do solo e deficiência nutricional, e assim podem passar despercebidos pelos produtores. Tradicionalmente, o diagnóstico de extensas áreas infestadas por nematoides e a determinação dos níveis de gravidade nessas áreas têm sido onerosos e nem

sempre viáveis do ponto de vista técnico. Uma estimativa precisa do potencial de danos requer a análise laboratorial de um grande número de amostras de solo para identificar os locais mais críticos em uma área infestada. As perdas causadas pelos fitonematoides, o alto custo da análise laboratorial de amostras de solo e a necessidade de controle eficaz exigem o desenvolvimento de métodos específicos de detecção e quantificação de danos em cada local (MARTINS; GALO; VIEIRA, 2017).

Dessa forma, uma alternativa que tem ganhado destaque nos últimos anos são as abordagens de agricultura de precisão que utilizam técnicas provenientes do sensoriamento remoto. Um princípio fundamental dessa abordagem é que a presença, distribuição e intensidade de um fator específico que reduz a produtividade em um campo devem ser identificáveis (MELAKEBERHAN, 2002). A reflectância do dossel da vegetação por meio de sensores remotos multiespectrais e hiperespectrais, tanto de longa distância quanto de curta distância, tem sido investigada para a detecção de diferentes nematoides e patógenos fúngicos presentes no solo (HEATH et al., 2000; LAUDIEN; BARETH; DOLUSCHITZ, 2003; LAWRENCE et al., 2004; WHEELER; KAUFMAN, 2003).

Essas técnicas permitem analisar as características espectrais das plantas e identificar possíveis infestações ou doenças que afetam o seu desempenho produtivo. As imagens multiespectrais e hiperespectrais são ferramentas eficientes na agricultura devido ao comportamento espectral das plantas, que permite detectar variações em suas características físicas (MORIYA, 2015). Essa capacidade de detecção de variações espectrais é especialmente útil na identificação de pragas e doenças, uma vez que as plantas infectadas apresentam comportamentos espectrais distintos das plantas saudáveis (RIEDEL; BLACKMER, 1999; ZHANG et al., 2003; MARIN et al., 2019). Além disso, de acordo com Hillnhütter et al. (2011), a indução de sintomas nas folhas, a formação de grupos (reboleiras) pelo parasita e sua limitada capacidade de mobilidade no solo tornam sua detecção facilitada por meio do sensoriamento remoto, permitindo a aplicação de técnicas de agricultura de precisão.

Os métodos de classificação de dados obtidos por sensores ópticos, baseados em aprendizado de máquina, têm recebido destaque devido à sua eficiência. Segundo Lary et al. (2016), os algoritmos baseados em aprendizado de máquina têm a capacidade de reconhecer padrões a partir de conjuntos de amostras de treinamento e generalizar a informação extraída para toda a imagem. Esse algoritmos não são limitados apenas a dados espectrais em seu processamento, podendo incluir outras fontes de informações relevantes para a classificação. O objetivo principal desses algoritmos é construir limites de decisão que possibilitem a maior separação entre os objetos, buscando minimizar os erros de classificação (VAPNIK, 1999).

Várias abordagens têm sido avaliadas para a detecção e classificação de nematoides em diferentes culturas, como em Martins (2013) em que avaliaram o potencial das imagens

multiespectrais RapidEye na detecção e discriminação de áreas de cana-de-açúcar infestadas por nematoides usando uma abordagem de classificação não supervisionada. Hillnhütter et al. (2011) utilizou dados hiperespectrais para detectar o estresse causado pelo nematoide do cisto na cultura de beterraba. Em Arantes et al. (2021) são utilizadas imagens aéreas hiperespectrais para a detecção espectral de nematoides na soja durante o estágio de floração, utilizando regressões lineares simples e múltiplas.

O uso dos dados provenientes de sensoriamento remoto combinado com algoritmos de aprendizado de máquina representam uma abordagem promissora para a detecção e classificação de nematoides. Estudos recentes, como os de Xavier et al. (2019) e Marra (2020), têm se dedicado a investigar o potencial das imagens multiespectrais do sensor MSI/Sentinel-2 para classificar nematoides na cultura do café utilizando redes neurais como técnica de aprendizado de máquina, esses estudos demonstraram eficiência na classificação dos nematoides. Porém, é importante ressaltar que no conjunto de estudos focados na detecção e classificação de fitonematoides a presença de nematoides de vida livre não são consideradas. Para uma compreensão completa das interações que ocorrem na área estudada, é fundamental considerar a presença e a influência dos nematoides de vida livre, além dos fitonematoides.

Para um mapeamento mais detalhado de plantações, é necessário o uso de imagens com maior resolução espacial, obtidas por levantamentos fotogramétricos realizados em dias e horários específicos. Os Veículos Aéreos Não Tripulados (VANTs), combinados com sensores espectrais e novos algoritmos, têm possibilitado diversas aplicações de imagem digital para gerar produtos cartográficos de alta precisão em grandes áreas (COLOMINA; MOLINA, 2014). As câmeras utilizadas nos levantamentos fotogramétricos com VANT devem ser leves e de porte pequeno para viabilizar o levantamento aéreo de maneira eficiente. Por exemplo, a câmera hiperespectral Rikola, adotada neste trabalho, possui um peso aproximado de 700 gramas, o que permite seu transporte por um VANT.

Neste contexto, nesta pesquisa levantou-se a hipótese de que imagens hiperespectrais obtidas por câmara embarcada em VANT e técnicas baseadas na fotogrametria e no sensoriamento remoto podem ser utilizadas para classificar as áreas parasitadas por nematoides no cultivo de soja de acordo com a intensidade de infestação de fitonematoides e levando em consideração a presença de nematoides de vida livre na área. Sendo assim, o trabalho visa avaliar o potencial das imagens hiperespectrais de alta resolução espacial na classificação de acordo com a intensidade de infestação de nematoides na cultura de soja, utilizando os algoritmos baseados em aprendizado de máquina *Random Forest*, *Support Vector Machine* e *K-Nearest Neighbors* e validar os resultados por meio de amostras nematológicas coletadas em campo.

5 Conclusões e Recomendações

O objetivo geral deste estudo é avaliar o potencial das imagens hiperespectrais na detecção e classificação da intensidade de infestação de fitonematoides na cultura de soja em uma fazenda experimental localizada em Caiuá, São Paulo. Para alcançar este objetivo, foi adotada uma abordagem de aprendizado de máquina, utilizando um conjunto de amostras de campo e um índice proposto que relaciona a quantidade de nematoides de vida livre e fitonematoides (IFVL).

É importante destacar que o número reduzido de amostras em campo é uma escolha estratégica deste estudo, considerando que a coleta de amostras nematológicas em campo é uma tarefa onerosa e exaustiva. Dessa forma, a limitação do número de amostras contribui para a redução dos custos e das horas de trabalho necessárias para o levantamento dos dados.

Neste estudo, foi apresentado uma abordagem para utilizar imagens multiespectrais como uma ferramenta para auxiliar no planejamento de um levantamento aéreo por VANT em uma fazenda experimental, utilizando uma câmera hiperespectral de alta resolução espacial. As imagens da missão Sentinel-2 foram utilizadas principalmente para validar se o período fenológico em que as imagens do sensor hiperespectral foram capturadas foi o mais adequado para extrair as informações mais relevantes para o estudo, conforme apresentado na Seção 4.1. Os resultados demonstraram que as respostas espectrais das plantas de soja parasitadas com nematoides ficam em maior evidência no período fenológico no final da fase reprodutiva. Com isso, foi possível determinar que a data de captura das imagens com o sensor hiperespectral é satisfatória para a extração das informações espectrais das plantas de soja parasitadas com nematoides.

Além disso, foram analisadas as curvas espectrais das médias das respostas espectrais para cada classe (calculadas a partir do IFVL) do sensor hiperespectral utilizado (Seção 4.2). Verificamos que as classes possuem separabilidade entre elas, o que indica que os classificadores de aprendizado de máquina conseguem distingui-las com maior precisão e que o IFVL é um índice válido para ser utilizado para dividir as classes.

Depois de extrair as informações das imagens obtidas por técnicas de sensoriamento remoto, foram testados três algoritmos baseados em aprendizado de máquina comumente utilizados em trabalhos realizados dentro do tópico agricultura de precisão, o RF, o SVM e o KNN. Esses algoritmos foram testados com diferentes valores de parâmetros. Também foram testados diferentes números de classes para representar o resultados de nível de infestação de fitonematoides a partir do IFVL, que foram 2, 5 e 10 classes.

Após a análise dos resultados obtidos neste estudo, pode-se concluir que o algoritmo RF com 5 classes, levando em consideração a quantidade de amostras de campo disponíveis,

foi o mais adequado para mapear a intensidade de infestação de fitonematoides na cultura de soja, como apresentado na Seção 4.3.2. A escolha desse modelo baseou-se principalmente na acurácia balanceada, que foi de 96,5%. Esses resultados indicam que o RF é um algoritmo eficaz para trabalhar com dados de alta dimensionalidade e complexidade, como os provenientes de Sensoriamento Remoto e Fotogrametria. Seus resultados têm sido consistentes na literatura, e sua habilidade em lidar com dados de alta dimensionalidade e em fornecer estimativas da importância relativa das variáveis na análise o tornam uma ferramenta importante para pesquisas na área.

A partir do algoritmo RF, foi gerado um gráfico que apresenta as variáveis por ordem de importância que contribuíram para o desempenho deste modelo. Os resultados mostraram que as quatro variáveis mais influentes na classificação foram as bandas com comprimentos de onda centrais de 790,30 nm, 751,06 nm, 771,87 nm e 701,27 nm, respectivamente. Todas essas bandas pertencem à região do *red edge* do espectro eletromagnético, que é conhecida por ser sensível a mudanças no conteúdo de clorofila e na estrutura da vegetação. Esses resultados são consistentes com estudos anteriores que mostram a importância das bandas do *red edge* para a detecção de estresse e doenças em plantas.

Além disso, o IFVL apresentou resultados satisfatórios para indicar o nível de infestação de fitonematoides, considerando-se também os nematoides de vida livre presentes na região. Isso pode ser um fator importante a ser considerado em estudos futuros, já que esses tipos de nematoides podem gerar um certo equilíbrio.

É importante ressaltar que a limitação do número de amostras de campo pode ter afetado os resultados obtidos. Porém, isso também indica que a utilização de dados de Sensoriamento Remoto e Fotogrametria pode ser uma alternativa interessante para reduzir custos e horas de trabalho.

Em conclusão, este estudo contribui para a aplicação de técnicas de agricultura de precisão na detecção e classificação da intensidade de infestação de fitonematoides na cultura de soja, utilizando dados de Sensoriamento Remoto e Fotogrametria e algoritmos de aprendizado de máquina.

Como recomendações futuras para o desenvolvimento de trabalhos com interesses similares, é importante explorar e investigar índices de vegetação que utilizem as bandas que se mostraram mais eficientes na detecção de áreas parasitadas por fitonematoides, bem como diferentes sensores, como o sensor multiespectral. Além disso, é interessante considerar um número maior de espécies de nematoides e analisar se algumas delas têm maior influência nas respostas do que outras.

No que diz respeito aos estudos de algoritmos, é válido testar com diferentes valores de parâmetros e com mais algoritmos, incluindo abordagens de aprendizado profundo.

Outra sugestão é aumentar o tamanho do conjunto de dados de treinamento para melhorar a capacidade de generalização do modelo e avaliar o desempenho em diferentes áreas geográficas e em diferentes safras agrícolas.

Referências

- ADELABU, S.; MUTANGA, O.; ADAM, E. Evaluating the impact of red-edge band from rapideye image for classifying insect defoliation levels. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 95, p. 34–41, 2014. Citado 2 vezes nas páginas 40 e 41.
- ALMEIDA, R. d. O. et al. Predictive models for soybean yields using unmanned aerial vehicles and machine learning techniques. *Precision Agriculture*, Springer, v. 19, n. 4, p. 593–608, 2018. Citado na página 78.
- ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, Taylor Francis, v. 46, n. 3, p. 175–185, 1992. Citado 2 vezes nas páginas 42 e 43.
- ARAGAO, A.; CONTINI, E. *O AGRO NO BRASIL E NO MUNDO: UMA SÍNTESE DO PERÍODO DE 2000 A 2020*. 2020. <<https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/pimenta/producao/doencas-e-pragas/doencas/nematoides>>. Citado na página 17.
- ARANTES, B. H. T. et al. Spectral detection of nematodes in soybean at flowering growth stage using unmanned aerial vehicles. *Ciência Rural*, SciELO Brasil, v. 51, 2021. Citado 3 vezes nas páginas 19, 22 e 24.
- ARRIBAS, J. I. et al. Comparison of different algorithms for varietal classification of grapevine by leaf spectral reflectance. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 14, n. 3, p. 4903–4918, 2014. Citado na página 43.
- ASD Inc. *ASD. FieldSpec®UV/VNIR: HandHeld Spectroradiometer. User's Guide*. Version 1.19. Boulder, CO, USA, 2003. 72 p. Citado na página 56.
- BARROS, J. F. D. et al. Estimac o da produtividade da soja utilizando t cnicas de sensoriamento remoto. In: *Congresso Brasileiro de Engenharia Agr cola*. [S.l.: s.n.], 2018. p. 1–8. Citado na p gina 42.
- BARSI, J. A.; SCHOTT, J. R.; RAQUENO, N. G. Radiometric and geometric analysis of worldview-2 imagery acquired over dunhuang megadunes. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 6, n. 12, p. 11945–11964, 2014. Citado na p gina 35.
- BELGIU, M.; DR GUT , L. Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, Elsevier, v. 114, p. 24–31, 2016. Citado 3 vezes nas p ginas 38, 39 e 40.
- BELGIU, M.; DR GUT , L.; STROBL, J. Quantitative evaluation of variations in rule-based classifications of land cover in urban neighbourhoods using worldview-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 87, p. 205–215, 2014. Citado na p gina 40.
- BERRAR, D. A brief review of the basics of classification. *Environmetrics*, Wiley Online Library, v. 17, n. 5, p. 557–568, 2006. Citado na p gina 42.

- BONGERS, T.; FERRIS, H. Nematode community structure as a bioindicator in environmental monitoring. *Trends in Ecology and Evolution*, Elsevier, London, v. 4, p. 224–228, 1999. Citado na página 17.
- BREIMAN, L. Bagging predictors. *Machine learning*, Springer, v. 24, n. 2, p. 123–140, 1996. Citado na página 38.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001. Citado 2 vezes nas páginas 38 e 59.
- BRODERSEN, K. H. et al. The balanced accuracy and its posterior distribution. In: IEEE. *International Conference on Pattern Recognition*. [S.l.], 2010. p. 3121–3124. Citado na página 62.
- CAI, L. et al. Mapping soil properties using ensemble learning methods: A case study of the soybean fields in northeast china. *Geoderma*, v. 404, p. 115291, 2021. Citado na página 42.
- CAMPOS, I. et al. Combining a water balance model with evapotranspiration measurements to estimate total available soil water in irrigated and rainfed vineyards. *Agricultural Water Management*, Elsevier, v. 165, p. 141–152, 2016. Citado na página 37.
- CARNEIRO, R. G. et al. Uptake and translocation of nitrogen, phosphorus and calcium in soybean infected with *meloidogyne incognita* and *m. javanica*. *Fitopatologia Brasileira*, Sociedade Brasileira de Fitopatologia, v. 27, n. 2, p. 141–150, 2002. Citado na página 29.
- CAVALLARO, G. et al. Extended self-dual attribute profiles for the classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 12, n. 8, p. 1690–1694, 2015. Citado na página 41.
- COLDITZ, R. R. An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. *Remote Sensing*, MDPI, v. 7, n. 8, p. 9655–9681, 2015. Citado na página 40.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, Elsevier, v. 92, p. 79–97, 2014. Citado na página 19.
- COLWELL, J. E. Vegetation canopy reflectance. *Remote sensing of environment*, Elsevier, v. 3, n. 3, p. 175–183, 1974. Citado na página 34.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado 2 vezes nas páginas 41 e 59.
- DIAS, W. et al. Nematóides em soja: identificação e controle. *Embrapa Soja-Circular Técnica (INFOTECA-E)*, Londrina: CNPSo., 2010. Citado 4 vezes nas páginas 17, 27, 28 e 29.
- DIETTERICH, T. G. Ensemble methods in machine learning. In: SPRINGER. *International workshop on multiple classifier systems*. [S.l.], 2000. p. 1–15. Citado na página 38.
- DINGUIRARD, M.; SLATER, P. Radiometric calibration. *Manual of Remote Sensing*, John Wiley & Sons, v. 3, p. 183–225, 1999. Citado na página 36.

- DU, P. et al. Random forest and rotation forest for fully polarized sar image classification using polarimetric and spatial features. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 105, p. 38–53, 2015. Citado na página 59.
- ESA, S.-. *ESA*. 2021. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Citado 2 vezes nas páginas 29 e 30.
- FASSNACHT, F. E. et al. Comparison of feature reduction algorithms for classifying tree species with hyperspectral data on three central european test sites. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 7, n. 6, p. 2547–2561, 2014. Citado na página 41.
- FEHR, W. R.; CAVINESS, C. E. *Stages of Soybean Development*. Ames, 1977. 11 p. Citado na página 26.
- FERRAZ, L.; BROWN, D. Nematologia de plantas: fundamentos e importância. *Manaus: Norma Editora*, v. 1, p. 251, 2016. Citado 3 vezes nas páginas 17, 27 e 57.
- FOODY, G. M.; MATHUR, A. Toward intelligent training of supervised image classifications: directing training data acquisition for svm classification. *Remote Sensing of Environment*, v. 93, n. 1, p. 107–117, 2004. ISSN 0034-4257. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S003442570400207X>>. Citado na página 41.
- FORMAGGIO, A. R.; SANCHES, I. D. *Sensoriamento remoto em agricultura*. [S.l.]: Oficina de Textos, 2017. Citado 2 vezes nas páginas 25 e 27.
- FRAZIER, R. J. et al. Characterization of aboveground biomass in an unmanaged boreal forest using landsat temporal segmentation metrics. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 92, p. 137–146, 2014. Citado na página 40.
- FREITAS, L. *Introdução à nematologia*. [S.l.]: Universidade Federal de Viçosa, 2006. Citado na página 28.
- GARG, S. et al. Towards a multimodal system for precision agriculture using iot and machine learning. In: IEEE. *2021 12th international conference on computing communication and networking technologies (ICCCNT)*. [S.l.], 2021. p. 1–7. Citado na página 43.
- GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. *Pattern recognition letters*, Elsevier, v. 27, n. 4, p. 294–300, 2006. Citado na página 39.
- HAAS, J.; BAN, Y. Urban growth and environmental impacts in jing-jin-ji, the yangtze, river delta and the pearl river delta. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 30, p. 42–55, 2014. Citado na página 40.
- HAN, L. et al. A machine learning-based method for yield prediction of soybean based on remote sensing data. *Field Crops Research*, Elsevier, v. 149, p. 11–18, 2013. Citado na página 43.

- HASEEB, A.; SRIVASTAVA, N.; PANDEY, R. The influence of *meloidogyne incognita* on growth, physiology, nutrient concentration and alkaloid yield of *hyoscyamus niger*. *Nematologia Mediterranea*, Firenze University Press, v. 18, n. 2, p. 127–129, 1990. Citado na página 29.
- HEATH, W. et al. The potential use of spectral reflectance from the potato crop for remote sensing of infection by potato cyst nematodes. *Aspects of Applied Biology*, v. 60, p. 185–188, 2000. Citado 3 vezes nas páginas 18, 22 e 24.
- HILLNHÜTTER, C. et al. Use of imaging spectroscopy to discriminate symptoms caused by *heterodera schachtii* and *rhizoctonia solani* on sugar beet. *Precision Agriculture*, Springer, v. 13, n. 1, p. 17–32, 2012. Citado 2 vezes nas páginas 22 e 24.
- HILLNHÜTTER, C. et al. Remote sensing to detect plant stress induced by *heterodera schachtii* and *rhizoctonia solani* in sugar beet fields. *Field Crops Research*, Elsevier, p. 70–77, jan 2011. Citado 2 vezes nas páginas 18 e 19.
- HONKAVAARA, E. et al. Radiometric calibration of a hyperspectral camera—specifications and results. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 64, n. 2, p. 223–230, 2009. Citado 2 vezes nas páginas 35 e 36.
- HONKAVAARA, E. et al. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight uav spectral camera for precision agriculture. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 5, p. 5006–5039, 2013. Citado na página 32.
- INAMASU, R. Y. et al. Agricultura de precisão: um novo olhar. *Embrapa Instrumentação-Livro científico (ALICE)*, São Carlos, SP: Embrapa Instrumentação, 2011. 334 p., 2011. Citado 2 vezes nas páginas 22 e 23.
- IPPOLITI, G. A.; EPIPHANIO, J. C.; SHIMABUKURO, Y. E. Utilização de sensoriamento remoto na previsão de área a ser plantada com culturas de verão em três municípios do estado de são paulo. *CD-ROM do IX Simpósio Brasileiro de Sensoriamento Remoto*, 1998. Citado na página 21.
- JENKINS, W. et al. A rapid centrifugal-flotation technique for separating nematodes from soil. *Plant disease reporter*, v. 48, n. 9, 1964. Citado na página 48.
- JENSEN, J. R. *Remote Sensing of the Environment: An Earth Resource Perspective*. [S.l.]: Prentice Hall, 2007. Citado na página 33.
- JENSEN, J. R.; EPIPHANIO, J. C. N. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. [S.l.]: Parêntese Editora São José dos Campos, 2009. Citado na página 79.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, Elsevier, v. 147, p. 70–90, 2018. Citado na página 37.
- KAMIR, E.; WALDNER, F.; HOCHMAN, Z. Estimating wheat yields in australia using climate records, satellite image time series and machine learning methods. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 160, p. 124–135, 2020. Citado na página 43.

- LARY, D. J. et al. Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, Elsevier, v. 7, n. 1, p. 3–10, 2016. Citado na página 18.
- LAUDIEN, R.; BARETH, G.; DOLUSCHITZ, R. Analysis of hyperspectral field data for detection of sugar beet diseases. In: *Proceedings of the EFITA Conference, 2003*. Debrecen, Hungary: [s.n.], 2003. Citado na página 18.
- LAWRENCE, G. W. et al. Remote sensing and precision nematocide applications for *Rotylenchulus reniformis* management in cotton. In: COOK, R.; HUNT, D. J. (Ed.). *Nematology Monographs and Perspectives*. Leiden, Netherlands: Brill, 2004. p. 13–21. Citado na página 18.
- LAWRENCE, R. L.; WOOD, S. D.; SHELEY, R. L. Mapping invasive plants using hyperspectral imagery and breiman cutler classifications (randomforest). *Remote Sensing of Environment*, Elsevier, v. 100, n. 3, p. 356–362, 2006. Citado 2 vezes nas páginas 39 e 41.
- LIAKOS, K. G. et al. Machine learning in agriculture: A review. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 8, p. 2674, 2018. Citado na página 37.
- LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, Taylor & Francis, v. 28, n. 5, p. 823–870, 2007. Citado na página 59.
- LU, P. et al. Physiological effects of meloidogyne incognita infection on cotton genotypes with differing levels of resistance in the greenhouse. *Journal of Nematology*, Society of Nematologists, v. 46, n. 4, p. 352–359, 2014. Citado na página 29.
- MAKYNEN, J. et al. Unmanned aerial vehicle (uav) operated megapixel spectral camera. *Electro-Optical Remote Sensing, Photonic Technologies, and Applications V. SPIE*, v. 8186, p. 81860Y–1–81860Y–9, 2011. Citado na página 33.
- MAKYNEN, J. A lightweight hyperspectral imager. 64 p. Dissertação (Mestrado) — Helsinki University of Technology, Helsinki, Finland, 2009. Disponível em: <<http://lib.tkk.fi/Dipl/2009/urn100105.pdf>>. Citado na página 33.
- MANSOUR, K. et al. Discriminating indicator grass species for rangeland degradation assessment using hyperspectral data resampled to aisa eagle resolution. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 70, p. 56–65, 2012. Citado na página 41.
- MARIN, D. B. et al. Multispectral radiometric monitoring of bacterial blight of coffee. *Precision Agriculture*, Springer, v. 20, n. 5, p. 959–982, 2019. Citado na página 18.
- MARRA, A. B. Detecção e mapeamento de nematoides na cultura cafeeira por meio de imagens multiespectrais do msi/sentinel-2 e classificação baseada em aprendizado de máquina. Universidade Estadual Paulista (UNESP), 2020. Citado na página 19.
- MARTINS, G. D. *CARACTERIZAÇÃO ESPECTRAL E ESPACIAL DE ÁREAS INFESTADAS POR NEMATOIDES E MIGDOLUS FRYANUS EM CULTURA CANAVIEIRA*. Dissertação (Mestrado) — Unesp, Presidente Prudente, 2013. Dissertação de Mestrado - Curso de Ciências Cartográfica. Citado na página 18.

- MARTINS, G. D.; GALO, M. d. L. B. T.; VIEIRA, B. S. Detecting and mapping root-knot nematode infection in coffee crop using remote sensing measurements. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 10, n. 12, p. 5395–5403, 2017. Citado na página 18.
- MARTINS, G. D. et al. Detecting and mapping root-knot nematode infection in the coffee crop using remote sensing measurements. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 12, n. 5, p. 1325–1333, 2019. Citado 2 vezes nas páginas 22 e 24.
- MELAKEBERHAN, H. Embracing the emerging precision agriculture technologies for site-specific management of yield-limiting factors. *Journal of Nematology*, v. 34, n. 2, p. 185–188, 2002. Citado na página 18.
- MIYOSHI, G. T. Caracterização espectral de espécies de mata atlântica de interior em nível foliar e de copa. Universidade Estadual Paulista (Unesp), 2016. Citado 4 vezes nas páginas 31, 32, 33 e 37.
- MLADENOVA, I. E. et al. Intercomparison of soil moisture, evaporative stress, and vegetation indices for estimating corn and soybean yields over the us. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 10, n. 4, p. 1328–1343, 2017. Citado na página 37.
- MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologia de aplicação. 4ª edição. Viçosa. Editora UFV, 2012. Citado na página 35.
- MORIYA, É. A. S. Identificação de bandas espectrais para detecção de cultura de cana-de-açúcar sadia e doente utilizando câmara hiperespectral embarcada em vant. Universidade Estadual Paulista (UNESP), 2015. Citado 4 vezes nas páginas 18, 37, 55 e 57.
- NEUMAIER, N. et al. Estádios de desenvolvimento da cultura de soja. *Embrapa Soja-Capítulo em livro científico (ALICE)*, In: BONATO, ER (Ed.) Estresses em soja. Passo Fundo: Embrapa Trigo, 2000., 2000. Citado na página 26.
- NGUYEN, Q. H. et al. Influence of data splitting on performance of machine learning models in prediction of shear strength of soil. *Mathematical Problems in Engineering*, v. 2021, 2021. Citado na página 60.
- NOVO, E. M. L. d. M. *Sensoriamento Remoto: princípios e aplicações*. São Paulo: Edgard Blucher, 2008. v. 01. 363 p. ISBN 9788521204411. Disponível em: <www.blucher.com.br>. Acesso em: 13 mar. 2021. Citado 2 vezes nas páginas 37 e 42.
- NUTTER, F. et al. Use of remote sensing to detect soybean cyst nematode-induced plant stress. *Journal of Nematology*, v. 34, n. 3, p. 222–231, 2002. Citado 3 vezes nas páginas 22, 24 e 29.
- OLIVEIRA, L. de et al. Conhecendo a fenologia do feijoeiro e seus aspectos fitotécnicos. *Embrapa Arroz e Feijão-Livro técnico (INFOTECA-E)*, Brasília, DF: Embrapa, 2018., 2018. Citado na página 25.

- OLIVEIRA, R. A. et al. Avaliação do corregristo de imagens coletadas por uma câmara hiperespectral de quadro. In: SOCIEDADE BRASILEIRA DE CARTOGRAFIA. *XXVI Congresso Brasileiro de Cartografia (CBC)*. Gramado, 2014. Disponível em: <http://www.cartografia.org.br/cbc/trabalhos/4/585/CT04-98_1404422611.pdf>. Citado 2 vezes nas páginas 32 e 33.
- ONODA, M. *Estudo sobre um algoritmo de árvores de decisão acoplado a um sistema de banco de dados relacional*. 2001. 110p. Tese (Doutorado) — Dissertação (Mestrado)-Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001. Citado na página 40.
- Organização das Nações Unidas (ONU). *Objetivos de Desenvolvimento Sustentável*. acesso em 26 de fevereiro de 2023. <<https://nacoesunidas.org/pos2015/ods>>. Citado 2 vezes nas páginas 22 e 24.
- OTOBONI, C. E. de M. *Precisão em Proteção de plantas Fatec Shunji Nishimura Pompeia/SP*. 2018. Disponível em: <<http://avantagro.com.br/agricultura-de-precisao-no-manejo-de-nematoides/>>. Citado 2 vezes nas páginas 21 e 23.
- PAL, M. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, Taylor & Francis, v. 26, n. 2, p. 217–222, 2005. Citado na página 59.
- PEERBHAY, K. Y.; MUTANGA, O.; ISMAIL, R. Random forests unsupervised classification: The detection and mapping of solanum mauritianum infestations in plantation forestry using hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 8, n. 6, p. 3107–3122, 2015. Citado na página 41.
- PINHEIRO, J. B. *Nematoides*. 2022. <<https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/pimenta/producao/doencas-e-pragas/doencas/nematoides>>. Citado na página 17.
- PLANT, R. E. Site-specific management: the application of information technology to crop production. *Computers and electronics in agriculture*, Elsevier, v. 30, n. 1-3, p. 9–29, 2001. Citado 2 vezes nas páginas 21 e 23.
- PONZONI, F.; SHIMABUKURO, Y.; KUPLICH, T. Sensoriamento remoto da vegetação. atual e ampl. *São Paulo: Oficina de Textos*, 2012. Citado 2 vezes nas páginas 33 e 34.
- PONZONI, F. J.; KUPLICH, T. M.; RUDORFF, B. F. T. Calibration of remote sensing sensors. *Brazilian Archives of Biology and Technology*, Scielo Brasil, v. 50, n. 3, p. 429–443, 2007. Citado 2 vezes nas páginas 35 e 36.
- RIEDEL, W. E.; BLACKMER, T. M. Leaf reflectance spectra of cereal aphid-damaged wheat. *Crop Science*, Wiley Online Library, v. 39, n. 6, p. 1835–1840, 1999. Citado na página 18.
- SAARI, H. et al. Novel miniaturized hyperspectral sensor for uav and space applications. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Proceedings SPIE 7474, Sensors, Systems, and Next-Generation Satellites XIII*. [S.l.], 2009. v. 7474, p. 74741M–74741M–12. Citado 2 vezes nas páginas 32 e 33.

- SAHOO, R. N. et al. *Processing of hyperspectral remote sensing data*. New Delhi: Division of Agriculture Physics, Indian Agriculture Research Institute, 2013. Citado 2 vezes nas páginas 36 e 57.
- SARTONO, B.; SYAFITRI, U. D. Metode pohon gabungan: Solusi pilihan untuk mengatasi kelemahan pohon regresi dan klasifikasi tunggal. In: *Forum Statistika dan Komputasi*. [S.l.: s.n.], 2010. v. 15, n. 1. Citado na página 59.
- SCHAER, B.; STRAUCH, C.; KNICKEL, K. Marketing sustainable agriculture: An analysis of the potential role of new food supply chains in sustainable rural development. sus-chain. *Sus-Chain, QLK5-CT-2002-01349*, 2002. Citado 2 vezes nas páginas 21 e 23.
- SEELAN, S. K. et al. Remote sensing applications for precision agriculture: A learning community approach. *Remote sensing of environment*, Elsevier, v. 88, n. 1-2, p. 157–169, 2003. Citado 2 vezes nas páginas 22 e 24.
- SHARMA, A. et al. Machine learning applications for precision agriculture: A comprehensive review. *IEEE Access*, IEEE, v. 9, p. 4843–4873, 2020. Citado na página 43.
- SILVA, L. Uma aplicação de árvores de decisão, redes neurais e knn para a identificação de modelos arma não sazonais e sazonais. *Rio de Janeiro. 145p. Tese de Doutorado-Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro*, 2005. Citado na página 38.
- SLATER, P.; HOUGH, M. A comparison of methods for atmospheric correction of landsat data. *Remote Sensing of Environment*, v. 23, p. 195–213, 1987. Citado na página 36.
- SMITH, G.; MILTON, E. The use of the empirical line method to calibrate remotely sensed data to reflectance. *International Journal of Remote Sensing*, Taylor & Francis, v. 20, n. 13, p. 2653–2662, 1999. Citado na página 36.
- TEILLET, P.; GUINDON, B.; GOODENOUGH, D. On the slope-aspect correction of multispectral scanner data. *Canadian Journal of Remote Sensing*, v. 16, p. 83–93, 1990. Citado na página 36.
- THOME, K.; BIGGAR, S.; SLATER, P. Atmospheric correction algorithms for the thematic mapper: Evaluation and application. *Remote Sensing of Environment*, v. 78, p. 49–61, 2001. Citado na página 36.
- VAPNIK, V. *The nature of statistical learning theory*. [S.l.]: Springer science & business media, 1999. Citado na página 18.
- VAPNIK, V. N. *Statistical Learning Theory*. [S.l.]: Wiley-Interscience, 1998. Citado na página 41.
- WANG, H. et al. Mapping robinia pseudoacacia forest health conditions by using combined spectral, spatial, and textural information extracted from ikonos imagery and random forest classifier. *remote Sensing*, MDPI, v. 7, n. 7, p. 9020–9044, 2015. Citado na página 40.

WANG, X.; LI, Y.; LI, J. Estimation of soybean yield based on hyperspectral images using machine learning algorithms. In: SPRINGER. *International Conference on Computer and Computing Technologies in Agriculture*. [S.l.], 2020. p. 3–11. Citado 2 vezes nas páginas 60 e 78.

WANG, Y. et al. Evaluation of machine learning algorithms for predicting soybean yield with hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, v. 58, p. 139–149, 2017. Citado 2 vezes nas páginas 42 e 43.

WANG, Z. et al. Comparative study of machine learning algorithms for classification of soybean and weed species using high resolution aerial imagery. *Computers and Electronics in Agriculture*, v. 151, p. 79–89, 2018. Citado na página 42.

WHEELER, T. A.; KAUFMAN, H. W. Relationship of aerial broad band reflectance to *Meloidogyne incognita* density in cotton. *Journal of Nematology*, v. 36, p. 48–57, 2003. Citado na página 18.

XAVIER, L. C. M. et al. Potencial de imagens multiespectrais sentinel 2 na detecção de nematoides na cultura cafeeira. *Revista Brasileira de Geomática*, v. 7, n. 2, p. 095–114, 2019. Citado na página 19.

YI, P. et al. Estimating soybean yield using deep learning from uav-based multispectral images. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 10, n. 10, p. 1498, 2018. Citado na página 42.

ZHANG, M. et al. Detection of stress in tomatoes induced by late blight disease in california, usa, using hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 4, n. 4, p. 295–310, 2003. Citado na página 18.

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture—a worldwide overview. *Computers and electronics in agriculture*, Elsevier, v. 36, n. 2-3, p. 113–132, 2002. Citado 2 vezes nas páginas 22 e 24.

ZHANG, X. et al. Determination of key canopy parameters for mass mechanical apple harvesting using supervised machine learning and principal component analysis (pca). *Biosystems engineering*, Elsevier, v. 193, p. 247–263, 2020. Citado na página 43.