

RESSALVA

Atendendo solicitação do(a)
autor(a), o texto completo desta
dissertação será disponibilizado
somente a partir de 07/07/2028

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**SENSORIAMENTO REMOTO ORBITAL E APRENDIZADO
DE MÁQUINA NA IDENTIFICAÇÃO DA INFESTAÇÃO DE
Sphenophorus levis (COLEOPTERA: CURCULIONIDAE) NA
CULTURA DA CANA-DE-AÇÚCAR**

Felipe dos Santos Silva Diniz
Engenheiro Agrônomo

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**SENSORIAMENTO REMOTO ORBITAL E APRENDIZADO
DE MÁQUINA NA IDENTIFICAÇÃO DA INFESTAÇÃO DE
Sphenophorus levis (COLEOPTERA: CURCULIONIDAE) NA
CULTURA DA CANA-DE-AÇÚCAR**

Discente: Felipe dos Santos Silva Diniz

Orientador: Prof. Dr. David Luciano Rosalen

Dissertação apresentada à Faculdade de
Ciências Agrárias e Veterinárias – Unesp,
Câmpus de Jaboticabal, como parte das
exigências para a obtenção do título de mestre
em Agronomia (Entomologia Agrícola)

D585s Diniz, Felipe dos Santos Silva

Sensoriamento Remoto orbital e aprendizado de máquina na identificação da infestação de *Sphenophorus levis* (Coleoptera: Curculionidae) na cultura da cana-de-açúcar / Felipe dos Santos Silva Diniz. -- Jaboticabal, 2026

89 p. : tabs., mapas

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: David Luciano Rosalen

1. Agricultura de precisão. 2. Bicudo da cana-de-açúcar. 3. Entomologia. 4. Índice de Vegetação por Diferença Normalizada. 5. Inteligencia artificial. I. Título.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: SENSORIAMENTO REMOTO ORBITAL E APRENDIZADO DE MÁQUINA NA IDENTIFICAÇÃO DA INFESTAÇÃO DE *Sphenophorus levis* (COLEOPTERA: CURCULIONIDAE) NA CULTURA DA CANA-DE-AÇÚCAR

AUTOR: FELIPE DOS SANTOS SILVA DINIZ

ORIENTADOR: DAVID LUCIANO ROSALEN

Aprovado como parte das exigências para obtenção do Título de Mestre em Agronomia (Entomologia Agrícola), pela Comissão Examinadora:

David Luciano

Rosalen:835552857

34

Assinado de forma digital por
David Luciano
Rosalen:83555285734
Dados: 2026.07.09 11:17:56
-03'00'

Prof. Dr. DAVID LUCIANO ROSALEN (Participação Presencial)

Departamento de Engenharia / UNESP / Câmpus de Jaboticabal - FCAV

Pós-Doutorando FERNANDO HENRIQUE IOST FILHO (Participação Virtual)

Departamento de Entomologia e Acarologia / ESALQ USP Piracicaba/SP



Documento assinado digitalmente
RAFAEL MAJOR PITTA
Data: 13/07/2026 15:57:06-0300
Verifique em <https://validar.iti.gov.br>

Pesquisador Dr. RAFAEL MAJOR PITTA (Participação Virtual)

Empresa Brasileira de Pesquisa Agropecuária (EMPRAPA) - Agrosilvipastoril / Sinop/MT

Jaboticabal, 07 de julho de 2026.



Documento assinado digitalmente
FERNANDO HENRIQUE IOST FILHO
Data: 20/07/2026 09:40:48-0300
Verifique em <https://validar.iti.gov.br>

DADOS CURRICULARES DO AUTOR

Felipe dos Santos Silva Diniz – Nascido em Campina Grande, Paraíba, Brasil, em 23 de outubro de 2000, filho de Ediclebia dos Santos Silva Diniz e Laudivan da Silva Diniz. Em agosto de 2018, ingressou no curso de Agronomia da Universidade Federal da Paraíba (UFPB), Centro de Ciências Agrárias, Câmpus de Areia (CCA), concluindo-o em dezembro de 2023, obtendo o título de Engenheiro Agrônomo. Durante a graduação, participou de projetos de Iniciação Científica (PIBIC) relacionados ao uso do Sensoriamento Remoto, com ênfase no monitoramento de culturas agrícolas e no estudo de bacias hidrográficas sob orientação do Prof. Dr. Guttemberg da Silva Silvino. Em agosto de 2024, iniciou o curso de Mestrado no Programa de Pós-Graduação em Agronomia (Entomologia Agrícola) da Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Faculdade de Ciências Agrárias e Veterinárias (FCAV), Câmpus de Jaboticabal. Durante o mestrado foi bolsista da Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e realizou pesquisas relacionadas à utilização de Sensoriamento Remoto com algoritmos de aprendizado de máquina na predição de áreas sob infestação de pragas, sob a orientação do Prof. Dr. David Luciano Rosalen.

*" Deus é a minha fortaleza e a minha força, e ele
perfeitamente desembaraça o meu caminho"*

II Samuel 22:33

À Deus por sua infinita graça e por guiar meus
passos, à minha família e aos meus amigos.

Dedico.

AGRADECIMENTOS

A Deus por me conceder saúde, força, sabedoria, e por permitir que eu chegasse até esta etapa da minha vida.

À minha família, em especial aos meus pais, Ediclebia dos S. S. Diniz e Laudivan da S. Diniz, pelo amor, apoio e incentivo incondicionais em todos os momentos.

À minha amada esposa Cananda C. C. Ferreira, pelo amor e companheirismo, por proporcionar momentos felizes e por nunca deixar de acreditar em mim, sendo fonte constante de incentivo durante esta caminhada.

Aos meus irmãos, Gabriel dos S. S. Diniz e Davi dos S. S. Diniz, pelo apoio ao longo desta jornada.

Ao meu orientador Prof. Dr. David L. Rosalen, pela oportunidade, orientação e conhecimentos repassados, essenciais para a realização deste trabalho.

Aos integrantes do Núcleo de Geomática e Agricultura de Precisão (NGAP) pela convivência e colaboração ao longo desta jornada, e aos amigos que conquistei.

Ao Programa de Pós-Graduação em Agronomia (Entomologia Agrícola) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela oportunidade e pela concessão da bolsa de estudo.

Ao Centro de Pesquisa em Engenharia – Fitossanidade em Cana-de-Açúcar (Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 17/25258-1).

Aos membros da banca de qualificação e defesa, Dr. Fernando H. Iost Filho e Dr. Rafael M. Pitta, meus agradecimentos pela contribuição a este trabalho.

A todos os professores do Programa de Pós-Graduação em Agronomia (Entomologia Agrícola), pelos ensinamentos transmitidos e pela contribuição para minha formação acadêmica e profissional.

A todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho, os meus mais sinceros agradecimentos.

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

SUMÁRIO

SUMÁRIO	i
RESUMO	iii
ABSTRACT	iv
LISTA DE FIGURAS	v
LISTA DE TABELAS	vi
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	4
2.1. Cana-de-açúcar	4
2.1.1 Pragas de solo atuantes na cultura da cana-de-açúcar	6
2.2 <i>Sphenophorus levis</i>	8
2.2.1. Métodos de manejo	9
2.3 Sensoriamento Remoto	11
2.4 Índices de Vegetação	13
2.5 Aprendizado de Máquina	19
2.5.1 Random Forest	20
2.5.2 Extreme Gradient Boosting	22
2.5.2.1 <i>Método Ensemble</i>	23
2.5.3 K Nearest neighbor	24
2.5.4 Regressão Logística Multinomial	25
2.5.5 Autoencoder	26
2.5.6 Rede Neural Perceptron Multicamadas	27
3. MATERIAL E MÉTODOS	28
3.1 Monitoramento em campo e obtenção de dados de amostragem	28
3.2 Obtenção e pré-processamento das imagens orbitais	29
3.3 Diagnóstico remoto	32
3.4 Pré-processamento do banco de dados	33
3.5 Performance dos modelos de classificação	35
4. RESULTADOS	38
5. DISCUSSÃO	47
6. CONCLUSÕES	57

7. REFERÊNCIAS	58
8. APÊNDICES	80
8.1 APÊNDICE A.....	81
8.2 APÊNDICE B.....	88

SENSORIAMENTO REMOTO ORBITAL E APRENDIZADO DE MÁQUINA NA IDENTIFICAÇÃO DA INFESTAÇÃO DE *Sphenophorus levis* (COLEOPTERA: CURCULIONIDAE) NA CULTURA DA CANA-DE-AÇÚCAR

RESUMO – O uso do Sensoriamento Remoto (SR) associado ao aprendizado de máquina representa uma alternativa promissora para o monitoramento fitossanitário de culturas agrícolas, permitindo a identificação indireta de pragas por meio da análise das alterações espectrais provocadas nas plantas hospedeiras. Nesse contexto, o objetivo deste trabalho foi comparar diferentes modelos e algoritmos de aprendizado de máquina na predição da infestação de *Sphenophorus levis* em áreas comerciais de cana-de-açúcar, bem como identificar as variáveis espectrais mais relevantes para a classificação supervisionada das áreas infestadas. Foram utilizados 53.112 pontos amostrais coletados entre os anos de 2019 e 2023 em municípios localizados nas regiões intermediárias de Araraquara e Ribeirão Preto, SP. As informações espectrais foram obtidas por meio de imagens dos satélites Sentinel-2, utilizando bandas espectrais e índices de vegetação derivados de imagens multiespectrais com resoluções espaciais de 10 e 20 m. Os algoritmos Random Forest, K-Nearest Neighbors (KNN), Extreme Gradient Boosting (XGBoost), Regressão Logística Multinomial, Perceptron Multicamadas e Autoencoder foram avaliados em diferentes cenários de classificação, considerando imagens recentes e tardias em relação às datas de amostragem em campo. O desempenho dos modelos foi avaliado por meio das métricas: acurácia, índice kappa, AUC, sensibilidade, precisão e medida-F1. Os resultados demonstraram que os algoritmos Random Forest, XGBoost e KNN apresentaram os melhores desempenhos preditivos, alcançando acurácia máxima de 70%, enquanto o Autoencoder apresentou desempenho inferior aos demais modelos avaliados. De maneira geral, os modelos treinados com imagens tardias apresentaram desempenho superior aos modelos com imagens recentes. Entre as variáveis preditoras que mais influenciaram os modelos de melhor desempenho, destacaram-se principalmente os índices ARI2, CRI2, TCARI, NIRv e CRI1, cuja relevância variou conforme a resolução espacial e o período das imagens utilizadas. Conclui-se que a integração de índices de vegetação e bandas espectrais a métodos de aprendizado de máquina apresenta eficácia na classificação de áreas infestadas por *S. levis*, reforçando o potencial dessas técnicas como ferramentas auxiliares na identificação de tais áreas por meio do processo de pré-amostragem indireta.

Palavras-chave: agricultura digital, bicudo da cana-de-açúcar, índice de vegetação, manejo integrado de pragas, observação da terra

ORBITAL REMOTE SENSING AND MACHINE LEARNING IN IDENTIFYING *Sphenophorus levis* (COLEOPTERA: CURCULIONIDAE) INFESTATION IN SUGARCANE CROPS

ABSTRACT - The use of Remote Sensing (RS) combined with machine learning represents a promising alternative for phytosanitary monitoring of agricultural crops, allowing the indirect identification of pests through the analysis of spectral changes caused in host plants. In this context, the objective of this work was to compare different machine learning models and algorithms in predicting *Sphenophorus levis* infestation in commercial sugarcane areas, as well as to identify the most relevant spectral variables for the supervised classification of infested areas. 53,112 sampling points were used, collected between 2019 and 2023 in municipalities located in the intermediate regions of Araraquara and Ribeirão Preto, SP. Spectral information was obtained from Sentinel-2 satellite images, using spectral bands and vegetation index derived from multispectral images with spatial resolutions of 10 and 20 m. The Random Forest, K-nearest Neighbors (KNN), Extreme Gradient Boosting (XGBoost), Multinomial Logistic Regression, Multilayer Perceptron and Autoencoder algorithms were evaluated in different classification scenarios, considering both recent and late images relative to the field sampling dates. Model performance was assessed using accuracy, kappa index, AUC, sensitivity, precision, and F-measure metrics. The results showed that Random Forest, XGBoost, and KNN algorithms presented the best predictive performance, achieving a maximum accuracy of 70%, while the Autoencoder showed inferior performance compared to the other models evaluated. In general, models trained with late images performed better than models with recent images. Among the predictive variables that most influenced the best-performing models, the ARI2, CRI2, TCARI, NIRv, and CRI1 indices stood out, with their relevance varying according to the spatial resolution and period of the images used. It is concluded that the integration of vegetation indices and spectral bands with machine learning methods proves effective in classifying areas infested by *S. levis*, reinforcing the potential of these techniques as auxiliary tools for identifying such areas through the indirect pre-sampling process.

Keywords: digital agriculture; sugarcane weevil; vegetation index; integrated pest management; earth observation

LISTA DE FIGURAS

Figura 1. Mapa de localização das áreas em que foram realizadas as amostragens das populações de <i>Sphenophorus levis</i>	28
Figura 2. Distribuição das observações de acordo com as classes empregadas nos modelos de aprendizado de máquina	34
Figura 3. Desempenho médio dos modelos avaliados	39
Figura 4. Desempenho dos modelos com menor capacidade preditiva para a classificação de infestação por <i>S levis</i> . Os valores nas células correspondem às métricas observadas, enquanto as cores representam o desempenho relativo padronizado dentro de cada métrica. Tons mais escuros indicam melhor desempenho relativo e tons mais claros indicam pior desempenho relativo	43
Figura 5. Desempenho dos modelos com maior capacidade preditiva para a classificação de infestação por <i>S levis</i> . Os valores nas células correspondem às métricas observadas, enquanto as cores representam o desempenho relativo padronizado dentro de cada métrica. Tons mais escuros indicam melhor desempenho relativo e tons mais claros indicam pior desempenho relativo	44
Figura 6. Ranking de contribuições das diferentes variáveis em cada modelo treinado pelo algoritmo Random Forest	45
Figura 7. Ranking de contribuições das diferentes variáveis em cada modelo treinado pelo algoritmo Extreme Gradient Boosting - XGBoost.....	46

LISTA DE TABELAS

Tabela 1. Índices de vegetação utilizados nos modelos de predição da infestação do <i>S. levis</i>	17
Tabela 2. Relação entre as datas das amostragens de campo e das imagens orbitais utilizadas, bem como a classificação temporal das imagens recentes e tardias	30
Tabela 3. Configuração espectral das bandas selecionadas do sensor MSI presente nos satélites Sentinel 2A e Sentinel 2B	32
Tabela 4. Identificação e descrição das variáveis utilizadas na composição dos modelos.....	35
Tabela 1A. Performance de classificação dos modelos treinados pelos diferentes algoritmos (média e erro padrão da média resultantes de uma matriz de confusão da validação cruzada por 10 repetições).....	81
Tabela 1B. Performance de classificação dos modelos treinados pelos diferentes algoritmos (média e erro padrão da média resultantes de uma matriz de confusão da validação cruzada por 10 repetições).....	88

1 INTRODUÇÃO

Dentre as culturas agrícolas cultivadas no Brasil, a Cana-de-Açúcar (*Saccharum spp.*), tem importância econômica muito expressiva no País, sendo essencial ao setor sucroalcooleiro na produção de subprodutos como o açúcar, o etanol e a energia elétrica que é produzida pela queima do bagaço e da palhada. A cana-de-açúcar tem o estado de São Paulo como polo produtivo no País, alcançando produção de cerca de 709.129 toneladas, além disso, mais da metade do volume total de açúcar produzido no país vem do estado de SP com uma produção de 25,7 milhões de toneladas (CONAB, 2026).

Durante o manejo da cana-de-açúcar, as principais dificuldades encontradas estão relacionadas a fitossanidade (incidência de pragas e doenças), Prudencio *et al.* (2025) comentam que além do surgimento de novas pragas ao longo dos anos, o comportamento das pragas tradicionais também vem se modificando.

Sphenophorus levis Vaurie, 1978 (Coleoptera, Curculionidae) é um inseto que permanece no solo sob restos vegetais e provoca danos internos nos internódios basais da cana-de-açúcar, esse comportamento do inseto dificulta a verificação visual das injúrias, os danos a base do colmo podem provocar perdas de até 30 t ha⁻¹ ano⁻¹ (Leite *et al.*, 2012), onde as perdas advêm da morte de 50 a 60% dos perfilhos entre 6 a 7 meses após o plantio (Alves *et al.*, 2026). Casteliani *et al.* (2020) apontam que cada aumento de 1% de dano nos “rizomas” provoca perdas de 1% na cana devido a reduções de 0,318% no peso dos colmos e 0,68% no número de brotos gerados.

S. levis é uma praga que tem o seu monitoramento retardado devido à dificuldade operacional na realização de sua amostragem populacional. Tradicionalmente a sua amostragem ocorre por meio da inspeção da base da planta, onde ocorre a avaliação dos danos provocados pelo inseto, que são quantificados em todas os seus estágios de desenvolvimento (Queiroz, 2024), para que os danos sejam avaliados é necessário que a touceira seja retirada do solo causando a morte da planta, esta ação além de ser destrutiva é bastante laboriosa, sendo necessário

uma maior mão de obra, principalmente quando se busca amostrar grandes áreas cultivadas.

Métodos de amostragem indireta a partir da utilização de Sensoriamento Remoto (SR) permitiram que as análises de identificação precoce da praga fossem ampliadas, a partir do uso de informações obtidas remotamente sem que a planta analisada seja modificada ou que sofra alguma ação deletéria. O sensoriamento remoto é uma técnica eficiente e rápida que é capaz de adquirir e analisar dados de propriedade espectral da superfície terrestre, através das mais variadas distâncias sem que haja contato físico (Shaurub, 2024).

As atividades de sensoriamento remoto de acordo com Abreu e Coutinho (2014), obrigatoriamente necessitam de uma fonte de energia como a radiação eletromagnética, que pode ser registrado por sensores ao ser refletida pela matéria, no caso da cana-de-açúcar, o dossel da planta é a superfície mais analisada, por cobrir todas as regiões da planta.

Plataformas orbitais estão ligadas a suas órbitas, o que segundo Abdullah *et al.* (2023) facilita o comprimento da faixa de área observada, por meio de várias resoluções temporais e espaciais, visto que essas plataformas são capazes de garantir uma vista sinóptica da área com grande acurácia por meio de imagens multiespectrais (El-Ghany *et al.*, 2020).

A resolução temporal pode variar a depender do satélite, os satélites que contêm sensores embarcados do qual fornecem acesso aos dados para o público, possuem um tempo de revisita mais demorado em comparação às opções disponibilizadas pelo setor privado. A influência da temporalidade das imagens em relação a obtenção dos dados amostrais de pragas no campo é um fator limitante na análise dos dados se a mudança fisiológica do hospedeiro sofrer alterações ao longo do tempo devido ao estresse induzido pelo processo de ataque (Zhang *et al.*, 2019).

Estresses bióticos e abióticos são passíveis de serem detectados em culturas agrícolas por meio do SR, principalmente aos estresses causados pela ação de pragas, Filho *et al.* (2022) e Barros *et al.* (2021) apontam que imagens multi e hiperespectrais permitem a detecção dos danos causados por pragas e seu respectivo monitoramento.

O uso de sensores e a obtenção de características espectrais, bem como de imagens, têm sido aplicados de forma extensiva pela sua capacidade de fornecer resultados com elevada acurácia na detecção de pragas ou dos danos provocados pelas mesmas em culturas agrícolas (Queiroz *et al.*, 2020; Thomas *et al.*, 2018), a exemplo da cultura do café (Vilela *et al.*, 2023); cultura da soja (Mirik *et al.*, 2006; Ribeiro *et al.*, 2024); amendoim (Pinto *et al.*, 2025); algodão (Fan *et al.*, 2025); cana-de-açúcar (Johansen *et al.*, 2018), entre outros.

O aprendizado de máquina (*Machine Learning*) é um conjunto de métodos para a análise de dados, que detecta automaticamente padrões nos dados, e, utiliza-se destes padrões descobertos para prever novos dados (Murphy, 2012). A integração entre o uso da inteligência artificial e o aprendizado de máquina vem revolucionando as áreas das ciências naturais, no contexto da entomologia agrícola especificamente, a construção de modelos preditivos, à partir do treinamento de algoritmos de aprendizado de máquina, propiciam a predição de infestações de pragas a partir da análise de dados referentes ao histórico da região, dados de populações de pragas e variáveis ambientais (Netam *et al.*, 2025).

Os algoritmos de aprendizado de máquina tradicionais constantemente empregados na análise de dados biológicos são: K-Nearest Neighbor (KNN), Regressão Logística Multinomial (RLM), Support Vector Machine (SVM), Naive Bayes (NB), Random Forest (RF), Árvores de decisão e Extreme Gradient Boosting (XGBoost).

A análise de dados de SR através de métodos estatísticos de aprendizado de máquina segundo Holloway e Mengersen (2018), demonstra clara interface do qual vem sendo objeto de interesse por parte de pesquisadores, instituições e países, a medida em que os dados de SR vem se tornando cada vez mais disponíveis gratuitamente, propiciando a obtenção facilitada de métricas ambientais e agrícolas.

As informações fornecidas pelo SR e AM permitem com que os produtores e agricultores adotem abordagem preditivas, ou seja, planejamento minucioso e antecipado sobre tópicos ambientais que embasam ainda mais o planejamento e a tomada de decisão (Coman *et al.*, 2025). Ademais, os dados de SR para monitoramento estão auxiliando a implementação de diversos Objetivos de

Desenvolvimento Sustentável (ODS) propostos pela Organização das Nações Unidas (Holloway e Mengersen, 2018).

Dentre os ODS propostos pela ONU, o monitoramento remoto de focos e/ou infestações de insetos praga contribuem diretamente no objetivo 2, denominado Fome Zero e Agricultura Sustentável, que busca erradicar a fome, alcançar a segurança alimentar, melhorar a nutrição e promover a agricultura sustentável (ONU, 2026). Esse objetivo é alcançado através da manutenção da colheita eficiente e da qualidade das culturas agrícolas necessárias para suprir a demanda gerada pelo aumento populacional (Aziz *et al.*, 2025; Mpisane *et al.*, 2025). O objetivo 13 (Ação contra a mudança global do clima) igualmente é alcançado pelo aumento do monitoramento ambiental através do uso de novas tecnologias como o aprendizado de máquina e a inteligência artificial, que reduzem a incerteza e mitigam riscos advindos das mudanças (UNESCO, 2020).

Objetivou-se com este trabalho comparar diferentes modelos e algoritmos na predição da infestação de *S. levis* em áreas comerciais da cultura da cana-de-açúcar. Especificamente, buscou-se: avaliar o desempenho dos modelos propostos; comparar a influência dos diferentes conjuntos de variáveis na capacidade de detecção das classes de infestação; identificar os algoritmos mais eficientes no treinamento dos modelos propostos; determinar o modelo de melhor desempenho preditivo e identificar as bandas espectrais e índices de vegetação que mais contribuíram para o desempenho dos modelos de classificação.

6 CONCLUSÕES

Conclui-se que a integração de índices de vegetação e bandas espectrais com métodos de aprendizado de máquina apresenta eficácia na classificação de áreas infestadas por *S. levis*; Os modelos treinados pelos algoritmos Random Forest, Extreme Gradient Boosting e KNN apresentam os melhores desempenhos na classificação da infestação; As imagens tardias com os índices em que utilizou-se a banda do vermelho limítrofe proporcionam aos modelos informações de maior relevância dentre as diferentes variáveis na classificação.

Os resultados obtidos reforçam o potencial do uso de técnicas de SR aliadas a métodos de aprendizado de máquina como ferramentas auxiliares na identificação de áreas infestadas através do processo de pré-amostragem indireta, especialmente aquelas afetadas por pragas de solo, como *S. levis*, que podem ocasionar danos significativos à produtividade.

7 REFERÊNCIAS

Abdel-Rahman MA, Alluhaidan AS, El-Rahman SA, Masnour AE, Amar ASl, Sobh MA, Bahaa-Eldin AM, Shamseldin T, Shalaby M (2026) Feature importance guided autoencoder for dimensionality reduction in intrusion detection systems. **Scientific Reports** 16:5013. DOI: <https://doi.org/10.1038/s41598-026-36695-9>

Abdullah HM, Mohana NT, Khan BM, Ahmed SM, Hossain M, Islan KHS, Redoy MH, Ferdush J, Bhuiyan MAHB, Hossain MM, Ahmed T (2023) Present and future scopes and challenges of plant pest and disease (P&D) monitoring: Remote sensing, image processing, and artificial intelligence perspectives. **Remote Sensing Applications: Society and Environment** 32:100996. DOI: <https://doi.org/10.1016/j.rsase.2023.100996>

Abreu KMPd, Coutinho LM (2014) Remote sensing applied to the study of vegetation with emphasis on index of vegetation and landscapes metrics. **Vértices** 16:173-198. DOI: <https://doi.org/10.5935/2F1809-2667.20140012>

Aguilar J, Romero C, Lozano CdC, Garcia E (2026) Unbalanced Data Mining Algorithms from IoT Sensors for Early Cockroach Infestation Prediction in Sewer Systems. **Algorithms** 19(2):152. DOI: <https://doi.org/10.3390/a19020152>

Ahmetoglu H, Das R (2022) A comprehensive review on detection of cyber-attacks: Data sets, methods, challenges, and future research directions. **Internet of Things** 20:100615. DOI: <https://doi.org/10.1016/j.iot.2022.100615>

Alsadik B, Ellsäßer FJ, Awawdeh M, Al-Rawabdeh A, Almahasneh L, Elberink SO, Abuhamoor D, Asmar YA (2024) Remote Sensing Technologies Using UAVs for Pest and Disease Monitoring: A Review Centered on Date Palm Trees. **Remote Sensing** 16(23):4371. DOI: <https://doi.org/10.3390/rs16234371>

Alencar BAVd (2016) ***Sphenophorus levis* Vaurie, 1978 (Coleoptera: Curculionidae): Caracterização macroscópica e determinação de inseticida e época de aplicação para controle**. 60 f. Tese (Doutorado em Agronomia - Entomologia Agrícola) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

Alves RBdO, Tomasiello DB, Almeida CMd, Rosalen DL, Pereira LH, Silva HPd, Rodrigues CL (2026) Multi-agent simulation of *Sphenophorus levis* infestation and natural biological control with *Beauveria bassiana* and *Steinernema brazilense* in sugarcane cultivation. **Ecological Modelling** 518: 111627. DOI: <https://doi.org/10.1016/j.ecolmodel.2026.111627>

Anandita K, Sinha AK, Jeganathan C (2025) Machine Learning Approach to Biomass Estimation: Integrating Satellite and Ground Data in Sal Forests of Jharkhand.

Journal of the Indian Society of Remote Sensing. 53:1137-1153. DOI: <https://doi.org/10.1007/s12524-024-02061-3>

Aparecido LEdO, Rolim GdS, Moraes JRdSCs, Costa CTS, Souza PSd (2019) Machine learning algorithms for forecasting the incidence of Coffea arabica pests and diseases. **International Journal of Biometeorology** 64:671-688. DOI: <https://doi.org/10.1007/s00484-019-01856-1>

Ardeshirifar R (2024) Automated Classification of Dry Bean Varieties Using XGBoost and SVM Models. **arXiv preprint arXiv:2408.01244**. DOI: <https://doi.org/10.48550/arXiv.2408.01244>

ASPRS (2026) **What is ASPRS?** Definitions. American Society for Photogrammetry and Remote Sensing. Disponível em: <<https://www.asprs.org/Main/Main/About/What-Is-ASPRS.aspx?hkey=1507e202-0f34-4af6-a1ac-073ec6a26051>>. Acesso em: 30 jul. 2026.

Ávila CJ, Parra JBP (2004) Influência de fatores físicos edáficos sobre pragas de solo. In: Salvadori JB, Ávila CB, Silva MTBd (Eds.). **Pragas de Solo no Brasil**. Passo Fundo: Embrapa Trigo, p. 69-98.

Aziz D, Rafiq S, Saini P, Ahad I, Gonal B, Rehman SA, Rashid S, Saini P, Rohela GK, Aalum K, Singh G, Gnanesh BN, Iliya MN (2025) Remote sensing and artificial intelligence: revolutionizing pest management in agriculture. **Frontiers in Sustainable Food Systems** 9:1551460. DOI: <https://doi.org/10.3389/fsufs.2025.1551460>

Bachirou SI, Peixoto PG, Rosalen DL (2026) Spectral response of guava leaves under infestation by *Costalimaita ferruginea* (coleoptera: Chrysomelidae). **Agricultural and Forest Entomology** 28(3):398-409. DOI: <https://doi.org/10.1111%2Fafe.70045>

Badgley G, Field CB, Berry JA (2017) Canopy near-infrared reflectance and terrestrial photosynthesis. **Science Advances** 3:e1602244. DOI: <https://doi.org/10.1126/sciadv.1602244>

Baldo F, Grando J, Weege KM, Bonassa GM (2022) Adaptive Fast XGBoost for Binary Classification. In: Simpósio Brasileiro de Banco de Dados, **Anais...** Porto Alegre: Sociedade Brasileira de Computação, 2022, p. 3-25. DOI: <https://doi.org/10.5753/sbbd.2022.224291>

Baldo F, Grande J, Correa YY, Policarpo DA (2023) Adaptive Fast XGBoost for Multiclass Classification. **Journal of Information and Data Management** 14:1. DOI: <https://doi.org/10.5753/jidm.2023.3150>

Bank D, Koenigstein N, Giryas R (2023) Autoencoders. In: Rokach L, Maimon O, Shmueli E (Eds.). **Machine Learning for Data Science Handbook**. Cham: Springer, p. 353-374. DOI: https://doi.org/10.1007/978-3-031-24628-9_16

Barnes EM, Clarke TR, Richards SE, Colaizzi PD, Haberland J, Kostrzewski M, Waller P, Choi C, Riley E, Thompson T, Lascano RJ, Li H, Moran MS (2000) **Coincident detection of crop water stress, nitrogen status, and canopy density using ground based multispectral data**. In: Robert PC, Rust RH, Larson WE (Eds.) *Proceedings of the 5th International Conference on Precision Agriculture*, Bloomington, Minnesota: ISPA, p. 1-15.

Barros PPdS, Rosalen DL, Filho FHI, Martins GD, Leo ND (2021) Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios. **Revista Brasileira de Cartografia** 73(2):489-515. DOI: <http://dx.doi.org/10.14393/rbcv73n2-56597>

Bending J, Yu K, Aasen H, Bolten A, Bennertz S, Broscheit J, Gnyp ML, Bareth G (2015) Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation** 39:79-87. DOI: <http://dx.doi.org/10.1016/j.jag.2015.02.012>

Bengio Y, Courville A, Vincent P (2014) Representation Learning: A Review and New Perspectives. **arXiv:1206.5538**. DOI: <https://doi.org/10.48550/arXiv.1206.5538>

Birth GS, McVey GR (1968) Measuring the Color of Growing Turf with a Reflectance Spectrophotometer. **Agronomy Journal** 60(6):640-643. DOI: <https://doi.org/10.2134%2Fagronj1968.00021962006000060016x>

Boras D, Petschke D, Staab TEM (2025) A machine learning approach using XGBoost for classification and filtering of 1275/511 pile-up events. **Journal of Physics: Conference Series** 3149:012029. DOI: <https://doi.org/10.1088/1742-6596/3149/1/012029>

Breiman L (2001) Random Forests. **Machine Learning** 45(1):5-32. DOI: <https://doi.org/10.1023/A:1010933404324>

Brito AMC (2023) **Fundamentos de la Ciencia de Datos**. 47 p. Trabajo de Fin de Grado (Grado en Matemáticas) – Facultad de Ciencias, Sección de Matemáticas, Universidad de La Laguna, La Laguna.

Buduma N, Buduma N, Papa J (2022) **Fundamentals of Deep Learning: Designing Next-Generation Machine Learning Intelligence Algorithms**. O'Reilly, 387 p.

Bühlmann P (2012) Bagging, Boosting and Ensemble Methods. In: Gentle J, Härdle W, Mori Y (Eds.) **Handbook of Computational Statistics**. Berlin: Springer, p. 985-1022. DOI: https://doi.org/10.1007/978-3-642-21551-3_33

Burzykowski T, Geubbelmans M, Rousseau A-J, Valkenburg D (2023) Validation of machine learning algorithms. **American Journal of Orthodontics and Dentofacial Orthopedics** 164(2):295-297. DOI: <https://doi.org/10.1016/j.ajodo.2023.05.007>

Caetano LF (2021) **Bioecologia, monitoramento e controle do bicudo-da-cana-de-açúcar (*Sphenophorus levis*): uma revisão bibliográfica**. 42 f. Trabalho de Conclusão de Curso (Bacharel em Engenharia Agrônômica) – Centro de Ciências Agrárias, Universidade Federal de São Carlos, Araras.

Camargo FM (2025) **Monitoramento de pragas na cultura da cana-de-açúcar utilizando Aerofotogrametria de baixa altitude**. 37 f. Trabalho de conclusão de curso (Graduação em Engenharia Agrônômica) - Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho, Jaboticabal.

Canassa F (2014) **Distribuição espacial, efeito do manejo da palha pós-colheita e da aplicação de *Beauveria bassiana* (Balsamo) Vuillemin (Hypocreales: Cordycipitaceae) na ocorrência de *Sphenophorus levis* Vaurie, 1978 (Coleoptera: Curculionidae) em cana-de-açúcar**. 98 f. Dissertação (Mestrado em Ciências - Entomologia) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.

Caregnato M (2018) **Regressão Logística Multinomial: Um modelo à partir do comportamento longitudinal do usuário em rede social para a predição de traços depressivos**. 200 f. Tese (Doutorado em Ciências) – Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo.

Casagrande AA, Vasconcelos ACMd (2008) Fisiologia da Parte Aérea. In: Dinardo-Miranda LL, Vasconcelos ACMd, Landell MGdA (Eds.). **Cana-de-açúcar**. Campinas: Instituto Agrônomo, p. 57-78.

Casteliani A (2019) **Aspectos comportamentais de *Sphenophorus levis* Vaurie, 1978 (Coleoptera: Curculionidae) em cana-de-açúcar e ocorrência natural de nematoides entomopatogênicos na população do inseto**. 50 f. Dissertação (Mestrado em Sanidade, Segurança Alimentar e Ambiental no Agronegócio) - Secretaria de Agricultura e Abastecimento do Estado de São Paulo, Agência Paulista de Tecnologia dos Agronegócios, Instituto Biológico, São Paulo.

Casteliani A, Martins LdF, Cardoso JFM, Silva MSO, Silva RSAd, Chacon-Orozco JG, Casteliani AGB, Půža V, Harakava R, Leite LG (2020) Behavioral aspects of *Sphenophorus levis* (Coleoptera: Curculionidae), damage to sugarcane and its natural infection by *Steinernema carpocapsae* (Nematoda: Rhabditidae). **Crop Protection** 137:105262. DOI: <https://doi.org/10.1016/j.cropro.2020.105262>

Castilho VTd (2023) **Modelagem Matemática da Distribuição Espaço-Temporal de *Sphenophorus levis* Vaurie, 1978 (Coleoptera: Curculionidae)**. 30 f. Trabalho de Conclusão de Curso (Bacharel em Física Médica) – Instituto de Biociências, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu.

CCB (2023) **Diferenças entre o etanol de milho e de cana-de-açúcar**. Centro de Conhecimento em Bioenergia, Universidade Federal de Viçosa. Disponível em: <

<https://ccbioenergia.ufv.br/diferencas-entre-o-etanol-de-milho-e-de-cana-de-acucar/>>. Acesso em: 07 Ago. 2026.

CCRS (2025) **Fundamentals of Remote Sensing**. Canada Centre for Remote Sensing, 258 p. Disponível em: <https://natural-resources.canada.ca/sites/nrcan/files/earthsciences/pdf/resource/tutor/fundam/pdf/fundamentals_e.pdf>. Acesso em 18 Jun. 2026.

Chan KY, Abu-Salih B, Qaddoura R, Al-Zoubi AM, Palade V, Pham D-C, Ser JD, Muhammad K (2023) Deep neural networks in the cloud: Review, applications, challenges and research directions. **Neurocomputing** 545:126327. DOI: <https://doi.org/10.1016/j.neucom.2023.126327>

Chen JM (1996) Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. **Canadian Journal of Remote Sensing** 22(3):229-242. DOI: <https://doi.org/10.1080/07038992.1996.10855178>

Chen T, Guestrin C (2016) XGBoost: A Scalable Tree Boosting System. In: 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining: KDD '16. **Proceedings...** New York: Association for Computing Machinery, p. 785-794. DOI: <https://doi.org/10.1145/2939672.2939785>

Chen T, He T, Benesty M, Tang Y (2018) **Understand your dataset with XGBoost**. Disponível em: <<https://haoen-cui.github.io/SOA-Exam-PA-R-Package-Documentation/xgboost/articles/discoverYourData.html>>. Acesso em: 18 Jun. 2026.

Chen T, He T, Benesty M, Khotilovich V, Tang Y, Cho H, Chen K, Mitchell R, Cano I, Zhou T, Li M, Xie J, Lin M, Geng Y, Li Y, Yuan J, Cortes D (2026) **xgboost: Extreme Gradient Boosting**. DOI: <https://doi.org/10.32614/CRAN.package.xgboost>

Chivasa W, Mutanga O, Biradar C (2020) UAV-Based Multispectral Phenotyping for Disease Resistance to Accelerate Crop Improvement under Changing Climate Conditions. **Remote Sensing** 12(15):2445. DOI: <https://doi.org/10.3390/rs12152445>

Cohen J (1960) A Coefficient of Agreement for Nominal Scales. **Educational and Psychological Measurement** 20:37-46. DOI: <https://doi.org/10.1177/001316446002000104>

Coman C, Coman E, Gherhes V, Bucs A, Rad D (2025) Application of Remote Sensing and Machine Learning in Sustainable Agriculture. **Sustainability** 17(12), 5601. DOI: <https://doi.org/10.3390/su17125601>

CONAB (2026) **Acompanhamento da Safra Brasileira: Cana-de-Açúcar**. 13(7) - Safra 2026/27 - Sétimo Levantamento. Companhia Nacional de Abastecimento, Brasília, DF. Disponível em: <<https://www.gov.br/conab/pt-br/atuacao/informacoes-agropecuarias/safras/safra-de-cana-de-acucar/arquivos-boletins/1o-levantamento-safra-2026-27/1o-levantamento-safra-2026-27>>.

Conrad O, Bechtel B, Bock M, Dietrich H, Fischer E, Gerlitz L, Wehberg J, Wichmann V, Böhner J (2015) System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, **Geoscientific Model Development** 8(7): 1991–2007. DOI: <https://doi.org/10.5194/gmd-8-1991-2015>

Cover TM, Hart PE (1967) Nearest Neighbor Pattern Classification. **IEEE Transactions on Information Theory** 13(1):21-27. DOI: <https://doi.org/10.1109/TIT.1967.1053964>

Cui Z (2021) Machine Learning and Small Data. **Educational Measurement: Issues and Practice** 40(4):8-12. DOI: <https://doi.org/10.1111%2Femip.12472>

Daughtry CST, Walthall CL, Kim MS, Brow de Colstoun E, McMurtrey JE (2000) Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment** 74(2):229-239. DOI: [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)

Degaspari N, Botelho PSM, Almeida LCd, Castilho HJ (1987) Biologia de *Sphenophorus levis* Vaurie, 1978 (Col: Curculionidae), em Dieta Artificial e no Campo. **Pesquisa Agropecuária Brasileira** 22(6):553-558. DOI: <https://doi.org/10.1590/S1678-3921.pab1987.v22.14389>

Deus KAA (2026) **Utilização de Olfatômetro em Y na Atração de *Sphenophorus levis* Vaurie (Coleoptera: Curculionidae) a Diferentes Substratos**. 40 f. Trabalho de Conclusão de Curso (Bacharel em Engenharia Agrônoma) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

Dinardo-Miranda LL (2008) Pragas. In: Dinardo-Miranda LL, Vasconcelos ACMd, Landell MGdA (Eds.). **Cana-de-açúcar**. Campinas: Instituto Agrônomo, p. 349-404.

Dinardo-Miranda LL, Fracasso JV (2012) Sugarcane straw and the populations of pests and nematodes. **Scientia Agricola** 70(5):305-310. DOI: <https://doi.org/10.1590/S0103-90162013000500012>

Dinardo-Miranda LL (2023) **Pragas da cana-de-açúcar**. Campinas: Instituto Agrônomo, 511 p.

Dompieri MHG, Silva MASd (2023) **Análise do cenário sucroenergético no Brasil**. Campinas: Embrapa Territorial, 13 p. (Boletim de Pesquisa e Desenvolvimento, 43). Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1162395>.

Dutta R (2014) Review of Vegetation Indices for Vegetation Monitoring. In: Asian Association on Remote Sensing: Sensing for Reintegration of Societies. **Proceedings...** Nay Pyi Taw: ACRS. 2014. Disponível em: https://acrs-aars.org/proceeding/ACRS2014/Full%20Papers/Session%20A/Session%20A2/OS-008%20Dutta_ACRS2014.pdf. Acesso em: 15 jun. 2026.

Efron B (1982) Cross Validation, the Jackknife and the Bootstrap. In: Efron B (Ed.) **The Jackknife, the Bootstrap, and Other Resampling Plans**. Society for Industrial and Applied Mathematics: 49-59. DOI: <https://doi.org/10.1137/1.9781611970319.ch7>

El-Ghany NMA, El-Aziz SEA, Marei SS (2020) A review: application of remote sensing as a promising strategy for insect pests and diseases management. **Environmental Science and Pollution Research** 27:33503-33515. DOI: <https://doi.org/10.1007/s11356-020-09517-2>

El-Habil AM (2012) An Application on Multinomial Logistic Regression Model. **Pakistan Journal of Statistics and Operation Research** 8(2):271-291. DOI: <https://doi.org/10.18187/pjsor.v8i2.234>

EMBRAPA (2026) **Bioinsumos**. V. 3.0.7. Empresa Brasileira de Pesquisa Agropecuária, Campinas: Embrapa Agricultura Digital.

Ennouri K, Kallel A (2019) Remote Sensing: An Advanced Technique for Crop Condition Assessment. **Mathematical Problems in Engineering** 9404565. DOI: <https://doi.org/10.1155/2019/9404565>

EPE (2026) **Relatório Síntese do Balanço Energético Nacional: Ano Base 2025**. Empresa de Pesquisa Energética, Brasília, DF. Disponível em: < <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2026>>.

Evangelista EFD, Serpa-dos-Santos L, Simone-Zera F, Cruz BeRGd (2017) Controle Químico de *Sphenophorus levis* Vaurie (Coleoptera: Curculionidae) na Cultura da Cana-de-Açúcar. **Entomologia Mexicana** 4:347-352.

Fagerland MW, Hosmer DW, Bonfin AM (2008) Multinomial goodness-of-fit tests for logistic regression models. **Statistics in Medicine** 27(21):4238-4253. DOI: <https://doi.org/10.1002/sim.3202>

Falcioni R, Antunes WC, Demattê JAM, Nanni MR (2023) Reflectance Spectroscopy for the Classification and Prediction of Pigments in Agronomic Crops. **Plants** 12(12):2347. DOI: <https://doi.org/10.3390/plants12122347>

Fan S, He Q, Chen Y, Xu X, Guo W, Lu Y, Liu J, Qiao H (2025) Identification of Cotton Leaf Mite Damage Stages Using UAV Multispectral Images and a Stacked Ensemble Method. **Agriculture** 15(21):2277. DOI: <https://doi.org/10.3390/agriculture15212277>

Filho FHI, Pazini JdB, Medeiros ADd, Rosalen DL, Yamamoto PT (2022) Assessment of Injury by Four Major Pests in Soybean Plants Using Hyperspectral Proximal Imaging. **Agronomy** 12:1516. DOI: <https://doi.org/10.3390/agronomy12071516>

Ferreira PHU, Ferreira MdC (2023) *Sphenophorus levis* Behavior Studies: Evaluating Insect Attractiveness or Repellency to One Insecticide Treatment and Assessing Nocturnal Insect Activity and Location Pattern. **Insects** 14:205. DOI: <https://doi.org/10.3390/insects14020205>

Figueiredo P (2008) Breve História da Cana-de-Açúcar de do Papel do Instituto Agrônômico no seu Estabelecimento no Brasil. In: Dinardo-Miranda LL, Vasconcelos ACMd, Landell MGdA (Eds.). **Cana-de-açúcar**. Campinas: Instituto Agrônômico, p. 31-44.

Fix E, Hodges Jr JL (1951) **Discriminatory Analysis - Nonparametric Discrimination: Consistency Properties**. Randolph Field, Texas: USAF School of Aviation Medicine. (Project 21-49-004, Report 4, Contract AF41(128)-31).

Freitas CASd, Silva ARAd, Bezerra FML, Ferreira CdS, Andrade RRd (2012) Crescimento Vegetativo da Cana-de-Açúcar (*Saccharum officinarum* L.) Irrigada com Água de Esgoto Doméstico Tratado. **Conexões - Ciência e Tecnologia** 6(1):27-43. DOI: <https://doi.org/10.21439/conexoes.v6i1.456>

Freund Y, Schapire RE (1998) Discussion: Arcing classifiers. **The Annals of Statistics** 26(3):824–832.

Friedman JH (2001) Greedy Function Approximation: A Gradient Boosting Machine. **The Annals of Statistics** 29(5):1189-1232. DOI: <https://doi.org/10.1214/aos/1013203451>

Fryda T, LeDell E, Gill N, Aiello S, Fu A, Candel A, Click C, Kraljevic T, Nykodym T, Aboyoun P, Kurka M, Malohlava M, Poirier S, Wong W (2024) **h2o: R Interface for the 'H2O' Scalable Machine Learning Platform**. DOI: <https://doi.org/10.32614/CRAN.package.h2o>

Gao X, Huete AR, Ni W, Miura T (2000) Optical–Biophysical Relationships of Vegetation Spectra without Background Contamination. **Remote Sensing of Environment** 74:609-620. DOI: [https://doi.org/10.1016/S0034-4257\(00\)00150-4](https://doi.org/10.1016/S0034-4257(00)00150-4)

Garcia R, Caltagirone LE, Gutierrez AP (1988) Comments on a Redefinition of Biological Control. **BioScience** 38(10):692-694. DOI: <https://doi.org/10.2307/1310871>

Géron A (2019) **Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow**: Concepts, tools, and Techniques to Build Intelligent Systems. Sebastopol: O'Reilly, 819p.

Gilabert MA, González-Piqueras J, Martínez B (2010) Theory and applications of vegetation indices. In: Maselli F, Menenti M, Brivio PA (Eds.). **Remote sensing optical observations of vegetation properties**. Trivandrum: Research Signpost, p. 1-43

Girón-Pérez K, Nakano O, Silva AC, Oda-Souza M (2009) Atração de Adultos de *Sphenophorus levis* Vaurie (Coleoptera: Curculionidae) a Fragmentos Vegetais em Diferentes Estados de Conservação. **Neotropical Entomology** 38(6):842-846. DOI: <https://doi.org/10.1590/S1519-566X2009000600019>

Gitelson AA, Kaufman YJ, Merzlyak MN (1996) Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS. **Remote Sensing of Environment** 58(3):289-298. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

Gitelson AA, Merzlyak MN, Chivkunova OB (2001) Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. **Photochemistry and Photobiology** 74(1):38-45. DOI: [https://doi.org/10.1562/0031-8655\(2001\)074%3C0038:OPANEO%3E2.0.CO;2](https://doi.org/10.1562/0031-8655(2001)074%3C0038:OPANEO%3E2.0.CO;2)

Gitelson AA, Zur Y, Chivkunova OB, Merzlyak MN (2002) Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochemistry and Photobiology** 75(3):272-281. DOI: [https://doi.org/10.1562/0031-8655\(2002\)0750272ACCIPL2.0.CO2](https://doi.org/10.1562/0031-8655(2002)0750272ACCIPL2.0.CO2)

Gonzalez LdA (2018) **Regressão Logística de suas Aplicações**. 45 p. Monografia (Bacharel em Ciência da Computação) – Centro de Ciências Exatas e Tecnológicas, Universidade Federal do Maranhão, São Luis.

Goodfellow I, Bengio Y, Courville A (2016) **Deep Learning**. The MIT Press, 775p.

Gregorutti B, Michel B, Saint-Pierre P (2017) Correlation and variable importance in random forests. **Statistics and Computing** 27(3):659-678. DOI: <https://doi.org/10.1007/s11222-016-9646-1>

Güral Y (2026) Comparative evaluation of machine learning models for predicting Cimbex quadrimaculata population density across multiple problem formulations. **PLoS One** 21(4):e0346494. DOI: <https://doi.org/10.1371/journal.pone.0346494>

Haboudane D, Miller JR, Pattey E, Zarco-Tejada PJ, Strachan IB (2004) 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** 90(3):337-352. DOI: <https://doi.org/10.1016/j.rse.2003.12.013>

Haboudane D, Miller JR, Tremblay N, Zarco-Tejada PJ, Dextraze L (2002) Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment** 81(2-3):416-426. DOI: [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)

Hamidi M, Safari A, Homayouni S (2020) An auto-encoder based classifier for crop mapping from multitemporal multispectral imagery. **International Journal of Remote Sensing** 42(3):986-1016. DOI: <https://doi.org/10.1080/01431161.2020.1820619>

Harris JK (2021) Primer on binary logistic regression. **Family Medicine and Community Health** 9(1). DOI: <https://doi.org/10.1136/fmch-2021-001290>

Hashimoto EM, Ortega EMM, Cordeiro GM, Suzuki AK, Kattan MW (2020) The multinomial logistic regression model for predicting the discharge status after liver transplantation: estimation and diagnostics analysis. **Journal of Applied Statistics** 47(12):2159-2177. DOI: <https://doi.org/10.1080/02664763.2019.1706725>

Hinton GE, Salakhutdinov RR (2006) Reducing the Dimensionality of Data with Neural Networks. **Science** 313(5786):504-507. DOI: <https://doi.org/10.1126/science.1127647>

Holloway J, Mengersen K (2018) Statistical Machine Learning Methods and Remote Sensing for Sustainable Development Goals: A Review. **Remote Sensing** 10, 1365. DOI: <https://doi.org/10.3390/rs10091365>

Horler DNH, Dockray M, Barber J (1983) The red edge of plant leaf reflectance. **International Journal of Remote Sensing** 4(2):273-288. DOI: <https://doi.org/10.1080/01431168308948546>

Huete AR (1988) A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment** 25(3):295-309. DOI: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)

Hu J, Szymczak S (2023) A review on longitudinal data analysis with random forest. **Briefings in Bioinformatics** 24(2):1-11. DOI: <https://doi.org/10.1093/bib/bbad002>

Izeppi TS (2015) **Distribuição espacial e dinâmica populacional de *Sphenophorus levis* (Coleoptera: Curculionidae) em cana-de-açúcar**. 74 p. Dissertação (Mestrado em Agronomia – Entomologia Agrícola) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

Izeppi TS, Dinardo-Miranda LL, Barbosa JC (2014) Flutuação populacional de *Sphenophorus levis* em cana-de-açúcar. In: VIII Workshop Agroenergia: Matérias Primas. **Anais...** Ribeirão Preto: IAC.

James G, Witten D, Hastie T, Tibshirani R (2021) **An Introduction to Statistical Learning: with applications in R**. Springer. p. 622.

Jensen JR (2009) **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parêntese, 598p.

Jeong B, Cho H, Kim J, Kwon SK, Hong S, Lee C, Kim T, Park MS, Hong S, Heo T-Y (2020) Comparison between Statistical Models and Machine Learning Methods on Classification for Highly Imbalanced Multiclass Kidney Data. **Diagnostics** 10(6):415. DOI: <https://doi.org/10.3390/diagnostics10060415>

Jia L, Limin W, Fei T, Lingbo Y, Jianmeng G, Baomin Y, Fugang Y (2016) Impact of red-edge waveband of RapidEye satellite on estimation accuracy of crop planting area. **Transactions of the Chinese Society of Agricultural Engineering** 32(13):140-148. DOI: <https://dx.doi.org/10.11975/j.issn.1002-6819.2016.13.020>

Johansen K, Sallam N, Robson A, Samson P, Chandler K, Derby L, Eaton A, Jennings J (2018) Using GeoEye-1 Imagery for Multi-Temporal Object-Based Detection of Canegrub Damage in Sugarcane Fields in Queensland, Australia. **GIScience & Remote Sensing** 55(2):285-305. DOI: <https://doi.org/10.1080/15481603.2017.1417691>

Jordan CF (1969) Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. **Ecology** 50(4):663-666. DOI: <https://doi.org/10.2307/1936256>

Kang Y, Meng Q, Liu M, Zou Y, Wang X (2021) Crop Classification Based on Red Edge Features Analysis of GF-6 WFV Data. **Sensors** 21(13):4328. DOI: <https://doi.org/10.3390/s21134328>

Kasinathan T, Singaraju D, Uyyala SR (2020) Insect classification and detection in field crops using modern machine learning techniques. **Information Processing in Agriculture** 8(3):446-457. DOI: <https://doi.org/10.1016/j.inpa.2020.09.006>

Kozmin A, Kalashev O, Chernenko A, Redyuk A (2025) Semi-Supervised Learned Autoencoder for Classification of Events in Distributed Fibre Acoustic Sensors. **Sensors** 25:3730. DOI: <https://doi.org/10.3390/s25123730>

Kuhn M (2008) Building Predictive Models in R Using the caret Package. **Journal of Statistical Software** 28(5), 1-26. DOI: <https://doi.org/10.18637/jss.v028.i05>

Lambin EF (2001) Remote Sensing and Geographic Information Systems Analysis. In: Smelser NJ, Baltes PB (Eds.) **International Encyclopedia of the Social & Behavioral Sciences** Pergamon, p. 13150-13155. DOI: <https://doi.org/10.1016/B0-08-043076-7/04200-5>

Le T-T-H, Oktian YE, Kim H (2022) XGBoost for Imbalanced Multiclass Classification-Based Industrial Internet of Things Intrusion Detection Systems. **Sustainability** 14:8707. DOI: <https://doi.org/10.3390/su14148707>

Leite LG, Tavares FMT, Botelho PSM, Filho AB, Polanczyk RA, Schmidt FS (2012) Eficiência de nematoides entomopatogênicos e inseticidas químicos contra *Sphenophorus levis* e *Leucothyreus* sp. em cana-de-açúcar. **Pesquisa Agropecuária Tropical** 42(1):40-48. Disponível em: <https://revistas.ufg.br/pat/article/view/14348>

Leivas JF, Takemura CM, Teixeira AHdC, Garçon EAM (2022) Análise da dinâmica temporal de índices de vegetação NDVI, EVI, SAVI e IRECI através de imagens Sentinel-2a e MODIS. In: Melo JOF (Ed.) **Ciências Agrárias: O Avanço da Ciência no Brasil** Científica Digital, p. 332-343. DOI: <https://doi.org/10.37885/220709585>

Liaw A, Wiener M (2002) Classification and Regression by Randomforest. **R News** 2(3):18-22. Disponível em: <<https://journal.r-project.org/articles/RN-2002-022/>>

Livingston F (2005) Implementation of Breiman's Random Forest Machine Learning Algorithm. **ECE591Q Machine Learning Journal Paper** 1:1-13.

Loiola TM, Fantinel RA, Santos FDd, Bastos Fd, Schuh MS, Fernandes P, Oliveira BASd, Pereira RS (2023) Use of Machine Learning Algorithms in the Classification of Forest Species. **Anuário do Instituto de Geociências** 46: 50490. DOI: https://doi.org/10.11137/1982-3908_2023_46_50490

López OAM, López AM, Crossa J (2022) Fundamentals of Artificial Neural Networks and Deep Learning. In: **Multivariate Statistical Machine Learning Methods for Genomic Prediction**. Cham: Springer, p. 379-425. DOI: https://doi.org/10.1007/978-3-030-89010-0_10

Lorenzzetti JA (2015) **Princípios Físicos de Sensoriamento Remoto**. Editora Blucher, 292 p.

Louppe G (2014) **Understanding Random Forests: from theory to practice**. 211 f. Thesis (PhD in Computer Sciences) - Department of Electrical Engineering & Computer Science, Faculty of Applied Sciences, University of Liège, Liège.

Lyon RJ, Rattay T (2024) Fundamentals of Machine Learning. In: Kang J, Rattay T, Rosenstein BS (Eds.). **Machine Learning and Artificial Intelligence in Radiation Oncology**. Academic Press, p. 3-28. DOI: <https://doi.org/10.1016/B978-0-12-822000-9.00018-5>

Macedo PMS, Fernandes EdC (2021) Análise de pigmentos e carotenoides como biomarcadores em cana-de-açúcar. **Brazilian Journal of Development** 7(3):30633-30641. DOI: <https://doi.org/10.34117/bjdv7n3-674>

Machado LA, Habib M, Leite LG, Calegari LC, Goulart RM, Tavares FM (2005) Patogenicidade de nematoides entomopatogênicos a ovos e larvas de *Migdolus fryanus* (Westwood, 1863) (Coleoptera: Vesperidae). **Arquivos do Instituto Biológico** 72(2):223-228. DOI: <https://doi.org/10.1590/1808-1657v72p2232005>

Mahajan P, Uddin S, Hajati F, Moni MA (2023) Ensemble Learning for Disease Prediction: A Review. **Healthcare** 11(12):1808. DOI: <https://doi.org/10.3390/healthcare11121808>

MAPA (2026) **Agrofit: Sistemas de Agrotóxicos Fitossanitários**. Ministério da Agricultura e Pecuária, Brasília: DF. Disponível em: <https://agrofit.agricultura.gov.br/agrofit_cons/principal_agrofit_cons>. Acesso em: 28 Mai. 2026.

Marafon AC (2012) **Análise Quantitativa de Crescimento em Cana-de-açúcar: uma Introdução ao Procedimento Prático**. Aracaju: Embrapa Tabuleiros Costeiros, 29 p. (Embrapa. Documentos, 168). Disponível em: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/944871>>.

Martins GD, Galo MdLBT (2015) Caracterização Espectral da Cana-de-Açúcar Infectada por Nematoides e Migdolus Fryanus por Espectrorradiometria de Campo. **BCG - Boletim de Ciências Geodésicas** 21(4):783-796. DOI: <http://dx.doi.org/10.1590/S1982-21702015000400046>

Meneses PR, Almeida Td (2019) Fundamentos de Espectrorradiometria. In: Meneses PR, Almeida Td, Baptista GMdM (Org.). **Reflectância dos materiais terrestres: análise e interpretação**. São Paulo: Oficina de Textos, p. 11-38.

Michelucci U (2022) An Introduction to Autoencoders. **arXiv preprint arXiv:2201.03898**. DOI: <https://doi.org/10.48550/arXiv.2201.03898>

Mirik M, Junior GJM, Kassymzhanova-Mirik S, Elliott NC, Catana V, Jones DB, Bowling R (2006) Using digital image analysis and spectral reflectance data to quantify damage by greenbug (Hemiptera: Aphididae) in winter wheat. **Computers and Electronics in Agriculture** 51:86-98. DOI: <https://doi.org/10.1016/j.compag.2005.11.004>

Mishina Y, Murata R, Yamauchi Y, Yamashita T, Fujiyoshi H (2015) Boosted Random Forest. **IEICE Transactions on Information and Systems** E98D(9):1630-1636. DOI: <https://doi.org/10.1587/transinf.2014OPP0004>

Moraes ECd (2002) **Fundamentos de Sensoriamento Remoto**. São José dos Campos: INPE, 22 p. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf>. Acesso em 18 Jun. 2026.

Moriya EAS, Imai NN, Tommaselli AMG, Honkavaara E, Rosalen DL (2023) Design of Vegetation Index for Identifying the Mosaic Virus in Sugarcane Plantation: A Brazilian Case Study. **Agronomy** 13(6):1542. DOI: <https://doi.org/10.3390/agronomy13061542>

Morón MA (2004) Insetos de solo. In: Salvadori JB, Ávila CB, Silva MTBd (Eds.). **Pragas de Solo no Brasil**. Passo Fundo: Embrapa Trigo, p. 41-68.

Moses-Gonzalez N, Brewer MJ (2021) A Special Collection: Drones to Improve Insect Pest Management. **Journal of Economic Entomology** 114(5):1853-1856. DOI: <https://doi.org/10.1093/jee/toab081>

Mpisane K, Kganyago M, Munghemezulu C, Price R, Nduku L (2025) A systematic review of remote sensing technologies and techniques for agricultural insect pest monitoring: lessons for *locustana pardalina* (Brown Locust) control in South Africa.

Frontiers in Remote Sensing 6:1571149. DOI: <https://doi.org/10.3389/frsen.2025.1571149>

Murer R (2025) **Introdução à Aprendizagem de Máquina: Conceitos, Algoritmos e Aplicações Práticas**. DOI: <https://doi.org/10.5281/ZENODO.18165751>

Murphy KP (2012) **Machine learning: a probabilistic perspective**. The MIT Press. p. 1067.

Murtagh F (1991) Multilayer perceptrons and regression for classification. **Neurocomputing** 2(5-6):183-197. DOI: [https://doi.org/10.1016/0925-2312\(91\)90023-5](https://doi.org/10.1016/0925-2312(91)90023-5)

Myneni RB, Hall FG, Sellers PJ, Marshak AL (1995) The Interpretation of Spectral Vegetation Indexes. **IEEE Transactions on Geoscience and Remote Sensing** 33(2):481-486. DOI: <https://doi.org/10.1109/TGRS.1995.8746029>

Nagar S, Farahbakhsh E, Awange J, Chandra R (2024) Remote sensing framework for geological mapping via stacked autoencoders and clustering. **Advances in Space Research** 74:4502-4516. DOI: <https://doi.org/10.1016/j.asr.2024.09.013>

Nanushi O, Sitokonstantinou V, Tsoumas I, Kontoes C (2022) Pest presence prediction using interpretable machine learning. In: IEEE 14th Image, Video, and Multidimensional Signal Processing Workshop. **Anais...** Náuplia, Grécia, p. 1-5. DOI: <https://doi.org/10.1109/IVMSP54334.2022.9816284>

Netam VS, Madavi AB, Akella SV (2025) The role of Artificial Intelligence and Machine Learning in Pest Behaviour and Pest Forecasting. **Journal of Technology** 13(11): 370-385. ISSN: 10122407.

Nurbek M, Lakshmi PV, Reddy KVS, Patro P (2025) Machine Learning for Pest Detection and Crop Protection Optimization. In: 2nd International Conference on News Frontiers in Communication, Automation, Management and Security. **Anais...** Bangalore, Índia, p. 1-6. DOI: <https://doi.org/10.1109/ICCAM65118.2025.11234458>

ONU (2026) **Objetivos de Desenvolvimento Sustentável**. Organização das Nações Unidas. Disponível em: <<https://brasil.un.org/pt-br/sdgs>>. Acesso em: 02 Ago. 2026.

Parra JRP, Botelho PSM, Pinto AdS (2014) Biological Control of Pests as a Key Component for Sustainable Sugarcane Production. In: Cortez LAB (Coord.) **Sugarcane bioethanol — R&D for Productivity and Sustainability**. São Paulo: Edgard Blücher, p. 441-450.

Patil R, Vanjerkhede K (2024) Random Forest machine learning approach for efficient optimization of Sierpinski carpet fractal antenna. **Journal of Information & Optimization Sciences** 45(4):851-861. DOI: <https://doi.org/10.47974/JIOS-1610>

Pereira DGsS, Santos LAOd (2022) Revisão de literatura: Uso de *Beauveria bassiana* no controle biológico de *Sphenophorus levis* Vaurie 1978 (Coleoptera: Curculionidae) em cana-de-açúcar. In: Silva AP (Org.) **MANEJO DE PRAGAS E DOENÇAS: a busca por formas sustentáveis de controle**. Guarujá: Científica Digital, p. 133-150.

Pinto JRL, Pinhal CVG, Fernandes OA, Rosalen DL (2025) Optimal flight height and spectral indices for detecting insect injury in peanut crops using UAS. *International Journal of Remote Sensing* 46(13). DOI: <https://doi.org/10.1080/01431161.2025.2462197>

Plaia A, Buscemi S, Furnkranz J, Mencía EL (2022) Comparing Boosting and Bagging for Decision Trees of Rankings. *Journal of Classification* 39:78-99. DOI: <https://doi.org/10.1007/s00357-021-09397-2>

Polanczyk RA, Smaniotto G, Gonçalves KC (2025) *Beauveria bassiana* In Vitro Compatibility with Pesticides: A Mixture Efficacy Prediction against the Sugar Cane Weevil, *Sphenophorus levis*. *ACS Omega* 10(30):33837-33842. DOI: <https://doi.org/10.1021/acsomega.5c05193>

Posit Team (2025) **RStudio: Integrated Development Environment for R**. V. 2025.5.1.513. Posit Software, PBC. <https://posit.co/products/open-source/rstudio>

Prudêncio MF, Marciano MC, Figueiredo PAM, Prado EP, Viana RdS (2025) Atualizações no Manejo Integrado das Principais Pragas da Cana-de-Açúcar no Brasil: Uma Revisão dos Últimos 10 Anos. *Revista Aracê* 7(7):35354-35374. DOI: <https://doi.org/10.56238/arev7n7-013>

Queiroz DM, Coelho ALdF, Valente DSM, Schueller K (2020) Sensors applied to Digital Agriculture: A review. *Revista Ciência Agronômica* 51:e20207751. DOI: <https://doi.org/10.5935/2F1806-6690.20200086>

Queiroz JS (2024) ***Beauveria bassiana* Via Endofítica Visando ao Controle de *Sphenophorus levis* Vaurie, 1978 (Coleoptera: Curculionidae)**. 51 f. Tese (Doutorado em Agronomia - Entomologia Agrícola) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

QGIS Development Team (2026) **QGIS Geographic Information System**. V. 3.40.0: Bratislava. Open Source Geospatial Foundation Project. <https://qgis.org/download/>

Quartaroli CF, Vicente LE, Araújo LSd (2014) Sensoriamento Remoto. In: Tôsto SG, Rodrigues CAG, Bolfe EL, Batistela M (Eds.). **Geotecnologias e geoinformação**. Brasília: Embrapa, p. 61-79. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/988056>. Acesso em 18 Jun. 2026.

R Core Team (2026) **R: A language and environment for statistical computing**. V. 4.5.0. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>

Ramirez-Gi JG, León-Rueda WA, Castro-Franco M, Vargas G (2023) Population Dynamics and Estimation of Damage of the Spittlebug *Aeneolamia varia* on Sugarcane in Colombia by Using remote Sensing and Machine Learning Tools. **Sugar Tech** 25(5)1115-1133. DOI:<https://doi.org/10.1007/s12355-023-01247-2>

Ren Q, CHENG H, HAN H (2017) Research on Machine Learning Framework Based on Random Forest Algorithm. **AIP Conference Proceedings** 1820(1): 0800201-0800207. DOI: <https://doi.org/10.1063/1.4977376>

Ribeiro AV, Lacerda LN, Windmuller-Campione MA, Cira TM, Marston ZPD, Alves TM, Hodgson EW, MacRae IV, Mulla DJ, Koch RL (2024) Economic-threshold-based classification of soybean aphid, *Aphis glycines*, infestations in commercial soybean fields using Sentinel-2 satellite data. **Crop Protection** 177:106557. DOI: <https://doi.org/10.1016/j.cropro.2023.106557>.

Ricardo AV, Lacerda LN, Windmuller-Campione MA, Cira TM, Marston ZPD, Alves TM, Hodgson EW, MacRae IV, Mulla DJ, Koch RL (2024) Economic-threshold-based classification of soybean aphid, *Aphis glycines*, infestations in commercial soybean fields using Sentinel-2 satellite data. **Crop Protection** 177:106557. DOI: <https://doi.org/10.1016/j.cropro.2023.106557>

Roberto GG (2015) **Fisiologia da maturação de cana-de-açúcar (*Saccharum spp*): Sinalização e controle do metabolismo de produção e armazenamento de sacarose**. 52 f. Tese (Doutorado em Agricultura Tropical e Subtropical) - Instituto Agrônômico, Campinas.

Rondeaux G, Steven M, Baret F (1996) Optimization of Soil-Adjusted Vegetation Indices. **Remote Sensing of Environment** 55(2):95-107. DOI: [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)

Rosenblatt F (1960) Perceptron simulation experiments. **Proceedings of the IRE** 48(3):301–309. DOI: <https://doi.org/10.1109/JRPROC.1960.287598>

Rosalen DL (2022) Challenges of digital agriculture in pest management. In: Nascimento J, Rocha CMd, Nascimento DDd, Peterlini E, Taguti EA, Soares JRS, Castro MCd, FôNSECA SS, Nascimento VF, Polanczyk RA (Eds.). **Topics in agricultural entomology - XIII**. Ponta Grossa: Atena Editora, p. 123-133. DOI: <https://doi.org/10.22533/at.ed.443220109>

Rosa JO (2022) **Infestação de *Sphenophorus levis* Vaurie, 1978 (Coleoptera: Curculionidae) em relação aos pontos de transferência de cana-de-açúcar**. 28 f. Dissertação (Mestrado em Agronomia - Entomologia Agrícola) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

Vieira AR (2025) **Sensoriamento remoto para caracterização espectral da cana-de-açúcar infestada por *Hyponeuma taltula* (Schaus, 1904) (Lepidoptera: Erebidae).** 54 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrônômica) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

Rossetto R, Dias FLF, Vitti AC, Tavares S (2008) Potássio. In: Dinardo-Miranda LL, Vasconcelos ACMd, Landell MGdA (Eds.). **Cana-de-açúcar**. Campinas: Instituto Agrônômico, p. 289-312.

Rouse JRJW, Hass RH, Schell JA, Deering, DW (1974) Monitoring Vegetation Systems in the Great Plains with ERTS. In: III EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM **Proceedings...** Scientific and Technical Information Office, National Aeronautics and Space Administration.

Rumelhart DE, Hinton GE, Williams RJ (1986) Learning Internal Representations by Error Propagation. In: Rumelhart DE, McClelland JL, PDP Research Group. **Parallel Distributed Processing, Volume 1: Explorations in the Microstructure of Cognition: Foundations.** The MIT Press, p. 318-362. DOI: <https://doi.org/10.7551/mitpress/5236.003.0012>

Rumpf T, Mahlein A-K, Steiner U, Oerke E-C, Dehne H-W, Plümer L (2010) Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. **Computers and Electronics in Agriculture** 74:91-99. DOI: <https://doi.org/10.1016/j.compag.2010.06.009>

SÃO PAULO (2002) **Lei Nº 11.241, de 19 de Setembro de 2002: Dispõe sobre a eliminação gradativa da queima da palha da cana-de-açúcar e dá providências correlatas.** São Paulo, SP: Diário Oficial do Estado de São Paulo.

Santos PdA (2021) **Controle biológico e químico da broca-gigante da cana-de-açúcar (*Telchin licus licus*) (Drury, 1773) (Lepidoptera: Castniidae) em laboratório.** 32 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrônômica) – Campus de Engenharias e Ciências Agrárias, Universidade Federal de Alagoas, Rio Largo.

Sarikaya F (2024) **Validation Strategies in Machine Learning: Critical Analysis of Cross-Validation Techniques and Data Splitting Methods.** DOI: <https://doi.org/10.5281/zenodo.14066212>

Seleglim AR (2020) **Estratégias para o controle da broca peluda, *Hyponeuma taltula* (Schaus, 1904) (Lepidoptera, Erebidae), em cana-de-açúcar.** 58 f. Dissertação (Mestrado em Agronomia - Entomologia Agrícola) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal.

Shaik NB, Pedapati SR, Taqvi SAA, Othman AR, Dzubir FAA (2020) A Feed-Forward Back Propagation Neural Network Approach to Predict the Life Condition of Crude Oil Pipeline. **Processes** 8(6):661. DOI: <https://doi.org/10.3390/pr8060661>

Sharma N, Sindal R, Meher SK (2026) Fuzzy rule-based ELM and autoencoder for hyperspectral remote sensing image classification. **Discover Geoscience** 4:91. DOI: <https://doi.org/10.1007/s44288-026-00419-3>

Shaurub E-SH (2024) Remote sensing and geographic information system applications as early-warning tools in monitoring fall armyworm, *Spodoptera frugiperda*: a review. **International Journal of Tropical Insect Science** 44:2241-2258. DOI: <https://doi.org/10.1007/s42690-024-01327-0>

Shinde PP, Shah S (2018) A Review of Machine Learning and Deep Learning Applications. In: Fourth International Conference on Computing Communication Control and Automation. **Proceedings...** Pune, India, p. 1-6. DOI: <https://doi.org/10.1109/ICCUBEA.2018.8697857>

Sicsú AL, Samartini A, Barth NL (2023) **Técnicas de Machine Learning**. Editora Blucher, 394 p.

Silva LFd, Lopes EMG, Martins SFdA, Jesus FLFd, Maltez MAPdF, Lima CF, Reis MM, Andrade RR, Maciel FdF, Almeida LTd, Menegali I, Vieira AF, Bicalho SF (2024) Sensoriamento Remoto e Índices de Vegetação: Conceitos e Aplicações - Revisão de Literatura. In: Silva LFd, Oliveira JRSd, Jesus FLFd (Eds.). **Cultivando o futuro: tendências e desafios nas ciências agrárias** 5. Atena Editora, p. 19-32. DOI: <https://doi.org/10.22533/at.ed.0692412063>

Solymosi K, Kövér G, Romvári R (2019) The Development of Vegetation Indices: a Short Overview. **Acta Agraria Kaposváriensis** 23(1):75-90. DOI: <https://doi.org/10.31914/aak.2264>

Souza CHWd, Lamparelli RAC, Justina DDD, Rocha JV (2015) Estudo da Banda Red Edge do satélite Rapideye na discriminação da cobertura vegetal. In: XVII Simpósio Brasileiro de Sensoriamento Remoto. **Anais...** João Pessoa: INPE: SBSR, p. 3612-3618.

Souza LFS, Rodriguez BDA, Poffal CA (2026) Redes Neurais Multi Layer Perceptron Aplicadas à Previsão dos Preços de Ações. In: XLIV CNMAX. **Proceedings Series of the Brazilian Society of Computational and Applied Mathematics** 12(1). Rio de Janeiro: Fundação Getúlio Vargas. Disponível em: <<https://proceedings.sbmec.org.br/sbmec/article/view/5148>>.

Sperandei S (2013) Understanding logistic regression analysis. **Biochemia Medica** 24(1):12-18. DOI: <https://doi.org/10.11613/BM.2014.003>

Stanton C, Starek MJ, Elliot N, Brewer M, Maeda MM, Chu T (2017) Unmanned aircraft system-derived crop height and normalized difference vegetation index

metrics for sorghum yield and aphid stress assessment. **Journal of Applied Remote Sensing** 11(2):026035. DOI: <https://doi.org/10.1117/1.JRS.11.026035>

Stenberg JA, Sundh I, Becher PG, Björkman C, Dubey M, Egan PA, Friberg H, Gil JF, Jonsson M, Karlsson M, Khalil S, Ninkovic V, Rehmann G, Vetukuri RR, Viketoft M (2021) When is it biological control? A framework of definitions, mechanisms, and classifications. **Journal of Pest Science** 94:665-676. DOI: <https://doi.org/10.1007/s10340-021-01354-7>

Strobl C, Boulesteix A-L, Zeileis A, Hothorn T (2007) Bias in random forest variable importance measures: Illustrations, sources and a solution. **BMC Bioinformatics** 8:25. DOI: <https://doi.org/10.1186/1471-2105-8-25>

Strobl C, Boulesteix A-L, Kneib T, Augustin T, Zeiss A (2008) Conditional variable importance for random forests. **BMC Bioinformatics** 9:307. DOI: <https://doi.org/10.1186/1471-2105-9-307>

Syriopoulos PK, Kalampalikis NG, Kotsiantis SB, Vrahatis MN (2025) kNN Classification: a review. **Annals of Mathematics and Artificial Intelligence** 93:43-75. DOI: <https://doi.org/10.1007/s10472-023-09882-x>

Tanha J, Abdi Y, Samadi N, Razzaghi N, Asadpour M (2020) Boosting methods for multi-class imbalanced data classification: an experimental review. **Journal of Big Data** 7:70. DOI: <https://doi.org/10.1186/s40537-020-00349-y>

Tahir M, Abdullah A, Udzir NI, Kasmiran KA (2025) A novel approach for handling missing data to enhance network intrusion detection system. **Cyber Security and Applications** 3:1-11. DOI: <https://doi.org/10.1016/j.csa.2024.100063>

Thomas P (2015) Perceptron learning for classification problems. In: 7th International Conference on Neural Computation Theory and Applications. **Anais eletrônicos...** Lisboa: NCTA. Disponível em: <<https://hal.science/hal-01232286v1>>.

Thomas S, Kuska MT, Bohnenkamp D, Brugger A, Alisaac E, Wahabzada M, Behmann J, Mahlein A-K (2018) Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. **Journal of Plant Diseases and Protection** 125:5-20. DOI: <https://doi.org/10.1007/s41348-017-0124-6>

Ualiyeva RM, Kaverina MM, Osipova AV, Faurat AA, Zhagazin SB, Iksat NN (2025) Hyperspectral Imaging and Machine Learning for Automated Pest Identification in Cereal Crops. **Biology** 14:1715. DOI: <https://doi.org/10.3390/biology14121715>

UNESCO (2020) **Water and Climate Change**. United Nations World Water Development Report 2020. United Nations Educational, Scientific and Cultural Organization, Paris. DOI: <https://doi.org/10.54679/ULUD7700>

Venables WN, Ripley BD (2002) **Modern Applied Statistics with S**. Fourth Edition. New York: Springer, 495 p.

Vilela EF, Ferreira WPM, Castro GDMd, Faria ALRd, Leite DH, Lima IA, Matos CdSMd, Silva RA, Venzon M (2023) New Spectral Index and Machine Learning Models for Detecting Coffee Leaf Miner Infestation Using Sentinel-2 Multispectral Imagery. **Agriculture** 13:388. DOI: <https://doi.org/10.3390/agriculture13020388>

Vinha FB, Delfanti LAdA, Pagliarani VD, Ferreira VS, Pinto AdS (2020) Entomopathogenic Fungi on the Control of *Sphenophorus levis* in Sugarcane Crop. **Scientia Agraria Paranaensis** 19(3):280-288.

Vitti AC, Cantarella H, Ocheuze PC, Rossetto R (2008) Nitrogênio. In: Dinardo-Miranda LL, Vasconcelos ACMd, Landell MGdA (Eds.). **Cana-de-açúcar**. Campinas: Instituto Agrônômico, p. 239-270.

Volovăt SR, Popa TO, Rusu D, Ochiuz L, Vasincu D, Agop M, Buzea CG, Volovăt CC (2024) Comparative Performance of Autoencoders and Traditional Machine Learning Algorithms in Clinical Data Analysis for Predicting Post-Staged GKRS Tumor Dynamics. **Diagnostics** 14(18):2091. DOI: <https://doi.org/10.3390/diagnostics14182091>

Wang C, Deng C, Wang S (2020) Imbalance-XGBoost: leveraging weighted and focal losses for binary label-imbalanced classification with XGBoost. **Pattern Recognition Letters** 136:190-197. DOI: <https://doi.org/10.1016/j.patrec.2020.05.035>

Wang C, Sun Y, Wang W, Liu H, Wang B (2023) Hybrid Intrusion Detection System Based on Combination of Random Forest and Autoencoder. **Symmetry** 15(3):568. DOI: <https://doi.org/10.3390/sym15030568>

Waters EK, Chen CC-M, Azghadi MR (2025) Sugarcane health monitoring with satellite spectroscopy and machine learning: A review. **Computers and Electronics in Agriculture** 229:109686. DOI: <https://doi.org/10.1016/j.compag.2024.109686>

Wiens M, Verone-Boyle A, Henscheid N, Podichetty JT, Burton J (2025) A Tutorial and Use Case Example of the eXtreme Gradient Boosting (XGBoost) Artificial Intelligence Algorithm for Drug Development Applications. **Clinical and Translational Science** 18(3):e70172. DOI: <https://doi.org/10.1111/cts.70172>

Witten IH, Frank E, Hall MA, Pal CJ (2017) Ensemble Learning. In: **Data Mining**. Morgan Kaufmann, p. 479-501.

Wright MN, Ziegler A (2017) ranger: A Fast Implementation of Random Forests for High Dimensional Data in C++ and R. **Journal of Statistical Software** 77(1), 1-17. DOI: <https://doi.org/10.18637/jss.v077.i01>

Xavier GG, Farias EdS, Carmo DdGd, Guedes AG, Samuels RI, Freitas DRd, Pereira EJG, Lima E, Picanço MC (2024) Determining Factors and Economic Injury Levels for *Sphenophorus levis* for Chemical and Biological Control in Irrigated and Non-

irrigated Sugarcane Crops. **Neotropical Entomology** 53:955-963. DOI: <https://doi.org/10.1007/s13744-024-01175-0>

Yan Y (2023) Machine Learning Fundamentals. In> Zhang Q (Ed.). **Encyclopedia of Smart Agriculture Technologies**. Cham: Springer, p. 1-7. DOI: https://doi.org/10.1007/978-3-030-89123-7_69-1

Yaghoubi E, Yaghoubi E, Khamees A, Razmi D, Lu T (2024) A systematic review and meta-analysis of machine learning, deep learning, and ensemble learning approaches in predicting EV charging behavior. **Engineering Applications of Artificial Intelligence** 135(108789):1-19. DOI: <https://doi.org/10.1016/j.engappai.2024.108789>

Yang Z, Willis P, Mueller R (2008) Impact of band-ratio enhanced AWIFS image to crop classification accuracy. In: Pecora – The Future of Land Imaging... Going Operational, 17, **Anais...** Denver, Colorado.

Yulita IN, Prabuwno AS, Ardiansyah F, Rejito J, Sholahuddin A, Rosadi R (2024) Pest Detection in Agricultural Farms using SqueezeNet and Multi-Layer Perceptron Model. **International Journal of Advanced Computer Science and Applications** 15(6):802-808. DOI:<https://dx.doi.org/10.14569/IJACSA.2024.0150680>

Zarbin PHG, Arrigoni EdB, Reckziegel A, Moreira JA, Baraldi PT, Vieira PC (2003) Identification of male-specific chiral compound from the sugarcane weevil *Sphenophorus levis*. **Journal of Chemical Ecology** 23(2):377-386. DOI: <https://doi.org/10.1023/A:1022634012212>

Zhang Y, Fan Z, Yan W, Ge C, Sun H (2025) A Practical Method for Red-Edge Band Reconstruction for Landsat Image by Synergizing Sentinel-2 Data with Machine Learning Regression Algorithms. **Sensors** 25(11):3570. DOI: <https://doi.org/10.3390/s25113570>

Zhang J, Huang Y, Pu R, Gonzalez-Moreno P, Yuan L, Wu K, Huang W (2019) Monitoring plant diseases and pests through remote sensing technology: A review. **Computers and Electronics in Agriculture** 165:104943. DOI: <https://doi.org/10.1016/j.compag.2019.104943>

Zhao J, Hu L, Dong Y, Huang L, Weng S, Zhang D (2021) A combination method of stacked autoencoder and 3D deep residual network for hyperspectral image classification. **International Journal of Applied Earth Observation and Geoinformation** 102:102459. DOI: <https://doi.org/10.1016/j.jag.2021.102459>

Zhou Z-H (2021) **Machine Learning**. Springer Singapore, 459 p. DOI: <https://doi.org/10.1007/978-981-15-1967-3>

Zhu L, Suomalainen J, Liu J, Hyypä J, Kaartinen H, Haggren H (2017) A Review: Remote Sensing Sensors. In: Rustamov RB, Hasanova S, Zeynalova MH (Eds.)

Multi-Purposeful Application of Geospatial Data. IntechOpen, p. 19-42. DOI: <http://dx.doi.org/10.5772/intechopen.71049>

Zhu X, Fang H, Zhao X (2025) Study on Classification Models Utilizing the Multilayer Perceptron Feature Selection and Ensemble Voting Classifier. In: 5th International Conference on Computer Science and Management Technology. **Proceedings...** Xiamen Guangdong: ICCSMT, p. 221-225. DOI: <https://doi.org/10.1145/3708036.3708074>

Zuriati Z, Saputra K, Qomariyah N (2026) Early detection of coffee plant disease using the k-nearest neighbour (KNN) algorithm. **AIP Conference Proceedings** 3228:040017. DOI: <https://doi.org/10.1063/5.0307604>