

**UNIVERSIDADE DE SÃO PAULO
FACULDADE DE FILOSOFIA, LETRAS E CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA**

AMANDA GOBATTO

**Uso de índices de vegetação para avaliar a influência das classes de solo na
produtividade da cana-de-açúcar**

Use of vegetation indices to assess the influence of soil classes on sugarcane productivity

**São Paulo
2025**

**UNIVERSIDADE DE SÃO PAULO
FACULDADE DE FILOSOFIA, LETRAS E CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
BACHARELADO EM GEOGRAFIA**

**Uso de índices de vegetação para avaliar a influência das classes de solo na
produtividade da cana-de-açúcar**

Use of vegetation indices to assess the influence of soil classes on sugarcane productivity

Trabalho de Graduação Individual apresentado à Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo, como requisito para obtenção do título de Bacharel em Geografia.

Área de Concentração: Geografia Física

Orientadora: Prof^ª Dr^ª Déborah de Oliveira

Coorientador: Prof Dr. Raul Roberto Poppiel

**SÃO PAULO
2025**

AMANDA GOBATTO

**Uso de índices de vegetação para avaliar a influência das classes de solo na
produtividade da cana-de-açúcar**

Trabalho de Graduação Individual apresentado
à Faculdade de Filosofia, Letras e Ciências
Humanas da Universidade de São Paulo, como
requisito para obtenção do título de Bacharel
em Geografia.

BANCA EXAMINADORA

Profª Drª Déborah de Oliveira
Faculdade de Filosofia, Letras e Ciências Humanas (FFLCH)
Universidade de São Paulo (USP)

Prof. Dr. Raul Roberto Poppiel
Escola Superior de Agricultura Luiz de Queiroz (ESALQ)
Universidade de São Paulo (USP)

Prof. Dr. Fellipe Alcantara de Oliveira Mello
Escola Superior de Agricultura Luiz de Queiroz (ESALQ)
Universidade de São Paulo (USP)

SÃO PAULO
2025

Dedico este trabalho à minha avó, Maria Aparecida da Silva Longo, que, com suas palavras, me deu forças ao longo de toda a minha trajetória. Mesmo não estando mais presente, ela continua a me inspirar a seguir de forma sólida.

AGRADECIMENTOS

À Profª Drª Déborah de Oliveira e à Profª Drª Natalia Nunes Patucci, que despertaram em mim a paixão pela ciência dos solos, apoiando-me academicamente e estando presentes em momentos difíceis.

Ao Prof. Dr. José Demattê e ao Prof. Dr. Raul Roberto Poppiel que contribuíram de maneira sólida e impecável para a construção deste o projeto, compartilhando seus conhecimentos de forma inspiradora.

Aos meus amigos, que me acolheram com tanto carinho nos momentos mais desafiadores da minha trajetória, agradeço por terem acreditado em mim a cada passo.

E, especialmente, aos meus pais, Alexandre Marcos Gobatto e Luciana Longo Gobatto, que tornaram tudo isso possível à sua maneira, ensinando-me a ter força e coragem.

À Faculdade de Filosofia, Letras e Ciências Humanas, minha profunda gratidão pela oportunidade de cursar essa área e realizar um sonho que carrego com orgulho.

“É necessário sempre acreditar que o sonho é possível. Que o céu é o limite e você, truta, é imbatível. Que o tempo ruim vai passar; é só uma fase. Que o sofrimento alimenta mais a sua coragem. “(Racionais MC’s, A Vida É Desafio)

RESUMO

Este trabalho analisa a influência das classes de solo sobre a produtividade da cana-de-açúcar utilizando índices de vegetação derivados de sensoriamento remoto óptico e por radar. Foram estudadas duas áreas agrícolas do estado de São Paulo, Rafard e Barra Bonita com base em mapas pedológicos detalhados e dados dos satélites Sentinel-1, Sentinel-2 e Landsat 8, processados no Google Earth Engine. Índices de vegetação (NDVI, LAI, CIRE e RVI) foram analisados dentro das unidades de mapeamento (média, percentis) mediante testes estatísticas (ANOVA, Kruskal-Wallis e MANOVA) e aprendizado de máquina (Random Forest) para investigar a sua relação com classes de solo em dois níveis taxonômicos. Os resultados indicaram forte associação entre o solo e os índices de vegetação (produtividade), especialmente para dados de radar, que apresentou maior poder discriminatório entre as classes de solo. O uso de estatísticas temporais, como o percentil 97, mostrou-se mais eficiente na identificação das diferenças edáficas. O estudo evidencia o potencial do sensoriamento remoto como ferramenta de baixo custo e alta cobertura espacial para o monitoramento da produtividade agrícola e para o aprimoramento das práticas de agricultura de precisão no Brasil.

Palavras-chave: sensoriamento remoto; estudo do solo; agricultura

ABSTRACT

This work analyzes the influence of soil classes on sugarcane productivity using vegetation indices derived from optical and radar remote sensing. Two agricultural areas in the state of São Paulo, Rafard and Barra Bonita, were studied based on detailed pedological maps and data from the Sentinel-1, Sentinel-2, and Landsat 8 satellites, processed in Google Earth Engine. Vegetation indices (NDVI, LAI, CIRE, and RVI) were analyzed within the mapping units (mean, percentiles) through statistical tests (ANOVA, Kruskal-Wallis, and MANOVA) and machine learning (Random Forest) to investigate their relationship with soil classes at two taxonomic levels. The results indicated a strong association between soil and vegetation indices (productivity), especially for radar data, which showed greater discriminatory power among soil classes. The use of temporal statistics, such as the 97th percentile, proved to be more efficient in identifying edaphic differences. The study highlights the potential of remote sensing as a low-cost and large spatial coverage tool for monitoring agricultural productivity and for improving precision agriculture practices in Brazil.

Key-words: *Remote sensing; soil study and agriculture.*

LISTA DE FIGURAS

Figura 1: Áreas de estudo - Rafard e Barra Bonita

Figura 2: Mapa Pedológico - Rafard

Figura 3: Mapa Pedológico detalhado - Rafard

Figura 4: Mapa Pedológico - Barra Bonita

Figura 5: Mapa de Talhões

Figura 6: Mapa Pedológico de Rafard: Classes de Solo por Interseção de Talhões

Figura 7: Classes de Solos por Interseção de Talhões (Rafard)

Figura 8: Classes de Solos por Interseção de Talhões (Barra Bonita)

Figura 9: Boxplot da Distribuição dos Índices Espectrais (RVI, NDVI, LAI, CIRE) – Rafard

Figura 10: Boxplot do Efeito da Agregação Temporal (6 e 12 meses) – Rafard

Figura 11: Boxplots das Associações entre Classes de Solo e Índices de Vegetação – Barra Bonita

Figura 12: Boxplots de Índices de Vegetação por Classes de Solo – Barra Bonita

LISTA DE TABELAS

Tabela 1: Especificações dos Sensores e Bandas Utilizados

Tabela 2: Associações Solo-Índice com maior correlação E_{ta}^2

Tabela 3: Top 5 Combinações (por Acurácia)

LISTA DE ABREVIATURAS

ANOVA: Análise de Variância

CIRE: Chlorophyll Index Red Edge

Eta²: Coeficiente Eta Quadrado

EVI: Índice de Vegetação Aprimorado 2

GEE: Google Earth Engine

IBGE: Instituto Brasileiro de Geografia e Estatística

LAI: Índice de Área Foliar

MANOVA: Análise de Variância Multivariada

MSI: MultiSpectral Instrument

NDVI: Normalized Difference Vegetation Index

NIR: Infravermelho Próximo

OLI: Operational Land Imager

PCA: Análise de Componentes Principais

PIB: Produto Interno Bruto

RVI: Índice de Vegetação por Radar

SAR: Radar de Abertura Sintética

SiBCS: Sistema Brasileiro de Classificação de Solos

SIG: Sistemas de Informações Geográficas

SOIL_1: Nível de Classificação Categórico Geral

SOIL_2: Nível de Classificação de Subordem Detalhado

SWIR: Infravermelho de Ondas Curtas

TCC: Trabalho de Conclusão de Curso

VH: Vertical-Horizontal (polarização)

VV: Vertical-Vertical (polarização)

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Justificativa	15
1.2 Hipótese	16
1.4 Objetivos Específicos	16
2 REVISÃO DE LITERATURA	17
3 MATERIAIS E MÉTODOS	21
3.1 Áreas de Estudo	21
3.1.2 Fazenda Barra Bonita	26
3.5 Análises Estatísticas	34
4 RESULTADOS E DISCUSSÃO	35
4.1 Análises univariadas (ANOVA/Kruskal-Wallis e η^2)	35
4.2 Análise Multivariada – MANOVA	37
4.3 Análise Boxplot - Rafard	38
4.4. Análise Boxplot - Barra Bonita	40
4.5 Classificação Supervisionada – Random Forest	43
5 CONCLUSÕES	44
6 REFERÊNCIAS BIBLIOGRÁFICAS	45

1 INTRODUÇÃO

O termo solo, originário do latim *solum*, representa simultaneamente um fundamento físico e simbólico. Em sentido poético, constitui o alicerce das gerações e da memória coletiva; no plano natural, é um corpo dinâmico cuja formação lenta resulta do intemperismo químico, físico e biológico atuando sobre as rochas ao longo de milhares de anos. Esse conjunto de processos, modulado pelo clima, relevo, vegetação e pela passagem do tempo, leva à diferenciação em horizontes pedogenéticos. A consolidação desses materiais gera propriedades particulares que determinam a fertilidade e a capacidade de sustentar a vida (PÉREZ et al., 2016).

No Brasil, onde a diversidade ambiental e geológica é vasta, os solos apresentam grande variabilidade em características físicas, químicas e morfológicas. Isso consolida o território como um verdadeiro laboratório natural para estudos de pedogênese, manejo e uso sustentável (SANTOS et al., 2018). Nesse contexto, compreender como atributos pedológicos influenciam o desenvolvimento vegetal tornou-se fundamental, sobretudo diante das mudanças recentes nos sistemas produtivos. Propriedades como textura, estrutura, teor de matéria orgânica, capacidade de retenção de água e fertilidade determinam diretamente o crescimento radicular, a disponibilidade de nutrientes e a produtividade de culturas agrícolas. Conforme apontam Demattê (2004) e Rossi (2017), práticas inadequadas de manejo podem comprometer essa funcionalidade e afetar o desempenho produtivo.

A cana-de-açúcar é um exemplo emblemático dessa relação, tendo grande importância histórica e cultural para o Brasil. Desde o período colonial, sua expansão esteve condicionada à escolha de solos profundos, bem drenados e com boa estrutura, o que moldou a organização espacial das fazendas e consolidou regiões produtivas ao longo dos séculos (RODRIGUES, 2020; ROSSI, 2017). Latossolos e argissolos, a princípio dominantes no cultivo de cana na região nordeste e litorânea, e mais recentemente na mancha de latossolos derivados dos derrames basálticos no Sudeste, figuram entre as classes mais favoráveis ao cultivo. Historicamente, esses solos estão associados a ambientes bem estruturados e de maior estabilidade física, o que dialoga também com fatores climáticos brasileiros, já que se trata de um país localizado entre o trópico e o equador, resultando em clima mais quente e solos mais complexos; portanto, o desenvolvimento da cultura está diretamente condicionado a esses atributos.

Nas últimas décadas, os avanços em sensoriamento remoto e Sistemas de Informação Geográfica (SIG) ampliaram as possibilidades de investigação da interação solo-planta. O monitoramento contínuo a partir de dados orbitais permite extrair informações espectrais que refletem o estado fisiológico e estrutural da vegetação (NANNI; DEMATTÊ, 2006). Índices como NDVI, LAI e RVI têm sido amplamente empregados para inferir o vigor vegetativo e sua relação com condições edáficas, subsidiando estratégias de manejo localizado, uso racional de insumos e práticas de agricultura de precisão (ACORSI AMORIM et al., 2022; SILVA DE ALMEIDA et al., 2023).

Apesar desses avanços, a quantificação da influência do solo sobre o desempenho agrícola ainda enfrenta desafios, sobretudo devido à variabilidade espacial dos atributos edáficos e ao elevado custo de amostragem em campo (BEN-DOR et al., 2008). Nesse cenário, o uso integrado de dados orbitais e análises estatísticas surge como alternativa estratégica para investigar padrões espaciais e temporais de produtividade.

Diante desse contexto, o presente trabalho propõe uma abordagem baseada em séries temporais de índices espectrais processados no Google Earth Engine (GORELICK et al., 2017), aplicada às fazendas Rafard e Barra Bonita, ambas localizadas no estado de São Paulo e dedicadas ao cultivo de cana-de-açúcar. O objetivo central é avaliar como diferentes classes de solo, classificadas segundo o Sistema Brasileiro de Classificação de Solos (SiBCS), influenciam o vigor vegetativo da cultura ao longo do tempo. A integração entre pedologia, sensoriamento remoto e métodos estatísticos busca contribuir para a agricultura de precisão, oferecendo subsídios técnicos para práticas de manejo mais eficientes, sustentáveis e orientadas por evidências.

Por fim, vale destacar que a cana-de-açúcar desempenha papel estratégico na economia brasileira, seja pela produção de açúcar e etanol, seja pela relevância social e territorial de sua cadeia produtiva. A compreensão da relação entre solo e desempenho da cultura é, portanto, não apenas um exercício científico, mas um elemento essencial para aprimorar a produtividade, reduzir impactos ambientais e orientar políticas agrícolas mais sustentáveis. Vale ressaltar que toda análise detalhada do solo e de sua produtividade é deveras onerosa; assim, o uso de ferramentas espectrais atreladas ao sensoriamento remoto democratiza esse processo de análise, o que tem impacto relevante nas questões ambientais, uma vez que existe um uso ativo do solo independentemente dessas limitações

1.1 Justificativa

O agronegócio é um dos pilares da economia brasileira, representando uma parcela expressiva do Produto Interno Bruto (PIB). Em 2021, a cadeia produtiva completa do setor alcançou 27,4% do PIB, a maior participação em quase duas décadas (CEPEA/CNA, 2022). Nesse contexto, a produção de cana-de-açúcar se destaca por sua relevância socioeconômica e energética, colocando o Brasil como o maior produtor e exportador mundial da cultura (UNICA, 2023).

Apesar da consolidação do uso de sensoriamento remoto para o monitoramento agrícola (XU et al., 2022), ainda persiste um desafio para estudos que buscam relacionar produtividade e variabilidade de solos: a escassez de dados pedológicos detalhados em alta densidade espacial. Como observam Demattê et al. (2010), o mapeamento pedológico de maior nível taxonômico, equivalente aqui às Subordens do SiBCS, frequentemente se limita a áreas restritas, o que reduz o tamanho amostral e compromete a aplicação de métodos estatísticos robustos.

Diante dessa limitação prática, este trabalho busca não apenas analisar a relação entre solo e desenvolvimento da cana-de-açúcar, mas também propor uma solução metodológica para cenários de baixa disponibilidade de dados pedológicos. A inclusão de uma classificação menos detalhada, equivalente às ordens do SiBCS, aumenta a representatividade amostral e permite a aplicação de testes estatísticos e modelos de aprendizado de máquina com maior consistência. Assim, o estudo se orienta pela seguinte questão central:

Em que medida diferentes níveis de detalhamento taxonômico do solo influenciam a variabilidade espacial e temporal do desenvolvimento da cana-de-açúcar, observada por índices de vegetação derivados de séries temporais de imagens de satélite?

A pesquisa contribui tanto para o entendimento científico das interações entre solo e vigor vegetativo quanto para a validação de uma abordagem metodológica que pode ser replicada em estudos de larga escala.

1.2 Hipóteses

- As diferentes classes de solo exercem influência significativa e diferenciada sobre o desenvolvimento e a produtividade da cana-de-açúcar, influência essa detectável pela variabilidade espacial e temporal de índices de vegetação multiespectrais e de radar.
- Classificações de solo em níveis taxonômicos mais detalhados (Subordens) possibilitam identificar com maior precisão as variações espaciais no desenvolvimento da cultura, quando comparadas a classificações mais gerais (Ordens).
- Diferentes índices espectrais e diferentes estatísticas temporais (médias, percentis e janelas de agregação) apresentam sensibilidades distintas para detectar variações no desenvolvimento da cana associadas às classes de solo.

1.3 Objetivo geral

Avaliar a influência de diferentes classes de solo, em vários níveis de detalhamento taxonômico, sobre o desenvolvimento da cana-de-açúcar, utilizando séries temporais de índices de vegetação derivados de sensores ópticos e de radar, combinados com análises estatísticas e técnicas de aprendizado de máquina.

1.4 Objetivos específicos

- Obter mapas pedológicos e séries temporais de índices de vegetação para representar o desenvolvimento da cana-de-açúcar em duas fazendas do estado de São Paulo.
- Analisar a relação entre classes de solo e desempenho vegetativo da cultura por meio de testes univariados e multivariados (ANOVA, Kruskal-Wallis e MANOVA), avaliando diferenças significativas nos índices entre as classes taxonômicas.
- Identificar quais índices espectrais e quais intervalos de agregação temporal apresentam maior sensibilidade para discriminar diferenças de desenvolvimento associadas às classes de solo.
- Treinar um algoritmo de classificação supervisionada (Random Forest) utilizando diferentes combinações de índices e janelas temporais, a fim de verificar quais variáveis e parâmetros apresentam maior acurácia na predição das classes de solo, fornecendo uma validação independente aos métodos estatísticos.

2 REVISÃO DE LITERATURA

A agricultura moderna enfrenta o desafio de otimizar a produção de forma sustentável, e o sensoriamento remoto emergiu como uma ferramenta crucial para superar essa barreira. Desde os primeiros levantamentos com aeronaves até a era dos satélites multiespectrais, a tecnologia revolucionou o monitoramento de culturas ao permitir a coleta de dados de forma não destrutiva, em larga escala e com alta frequência temporal (SILVA DE ALMEIDA et al., 2023). Essa evolução tecnológica substituiu parte dos métodos tradicionais, que são caros, lentos e limitados a pequenas áreas (DEMATTÊ et al., 2004).

Uma das grandes contribuições do sensoriamento remoto é a capacidade de monitorar a saúde e o vigor da vegetação por meio de índices de vegetação. Esses índices funcionam como combinações matemáticas de bandas espectrais que geram um número capaz de refletir a condição da planta. O mais conhecido, o Normalized Difference Vegetation Index (NDVI), utiliza a luz refletida na banda do infravermelho próximo (NIR) e absorvida na banda do vermelho para quantificar a biomassa e a atividade fotossintética, servindo como um indicador robusto de produtividade (TUCKER, 1979).

Avanços como o satélite Sentinel-2 expandiram essas possibilidades. Sua banda de borda vermelha (red-edge) é extremamente sensível a alterações sutis no teor de clorofila, permitindo a criação de índices como o Chlorophyll Index Red Edge (CIRED), que detecta estresse na planta de forma mais precisa. A partir desses índices, também é possível estimar parâmetros biofísicos da cultura, como o Leaf Area Index (LAI), indicador fundamental da área foliar por unidade de solo (WATSON, 1947; ACORSI AMORIM et al., 2022).

Complementando os sensores ópticos, o uso de dados de radar, como os do satélite Sentinel-1, permite a coleta contínua de informações sobre a estrutura física da vegetação, independente de condições climáticas. O sensor SAR emite pulsos de energia e mede o sinal que retorna, capturando informações sobre a estrutura física dos objetos no solo (WOODHOUSE, 2017). O RVI (Índice de Vegetação Radar), derivado do Sentinel-1, demonstrou alta capacidade de discriminação estatística das classes de solo nas fazendas Rafard e Barra Bonita. Isso se explica porque sensores SAR medem a retrodifusão, influenciada pela rugosidade superficial, teor de umidade e geometria das partículas do solo — propriedades que o RVI capta além da contribuição da vegetação (Szigarski, 2018; Stanyer et al., 2025).

A capacidade de gerar informações densas e de alta resolução a partir do sensoriamento remoto demonstrou ser mais eficaz para a avaliação da variabilidade em campos agrícolas do que métodos de amostragem de campo tradicionais (SILVA DE ALMEIDA et al., 2023). Estudos de espectrorradiometria já demonstraram correlação entre mapas de solo obtidos de forma remota e mapas convencionais, validando essa abordagem (DEMATTÊ et al., 2004). Essa metodologia supera limitações de análises pontuais e consolida o sensoriamento remoto como ferramenta indispensável para o manejo agrícola.

A relação entre variabilidade da vegetação e propriedades do solo fundamenta esta pesquisa. Para compreender essa complexidade, a taxonomia de solos moderna, como o Sistema Brasileiro de Classificação de Solos (SiBCS), organiza os solos em um sistema hierárquico que vai do mais geral ao mais específico (EMBRAPA, 2018). No nível mais alto da hierarquia (Ordem), os solos são diferenciados pelo grau de intemperismo. Em níveis mais detalhados, a classificação incorpora características como cor, fertilidade e presença de horizontes diagnósticos.

O entendimento de terminologias como Háptico (estágio inicial de desenvolvimento), Eutrófico (alta fertilidade) e Distrófico (baixa fertilidade) é fundamental para descrever a aptidão agrícola de cada classe (LEPSCH, 2013). Um exemplo é o Neossolo Litólico, variação de Neossolo desenvolvida sobre rocha contínua, o que limita a profundidade do perfil a menos de 50 cm e compromete o desenvolvimento radicular (LEPSCH, 2013).

Na área de estudo, foram identificadas classes de solos com aptidões agrícolas distintas, cujas características morfológicas e processos de formação influenciam diretamente o desenvolvimento da cana-de-açúcar. Latossolos, por serem solos antigos e evoluídos, são profundos e bem drenados, embora de baixa fertilidade natural. Nitossolos apresentam alta fertilidade natural, com estrutura em blocos que favorece a aeração. Argissolos possuem horizonte subsuperficial mais argiloso, podendo dificultar a infiltração. Cambissolos, por serem mais rasos e pouco desenvolvidos, limitam o volume de solo disponível para o sistema radicular (LEPSCH, 2010).

O processamento de grandes volumes de dados de satélite, especialmente séries temporais, ainda representa desafio significativo (GORELICK et al., 2017). Métodos tradicionais exigem conhecimento técnico especializado, infraestrutura robusta e softwares específicos. Para

democratizar o processamento, surgiram plataformas de computação em nuvem, como o Google Earth Engine (GEE).

O GEE combina um vasto catálogo de dados geoespaciais com um serviço de computação de alto desempenho, eliminando a necessidade de downloads e pré-processamentos manuais (GORELICK et al., 2017). Sua capacidade de processamento paralelo o torna ideal para análises de séries temporais e para estudos que correlacionam variabilidade de solos com índices de vegetação.

A análise de grandes volumes de dados de sensoriamento remoto, especialmente em estudos de correlação complexa como a relação entre solo e planta, exige ferramentas estatísticas e de aprendizado de máquina. Modelos de aprendizado de máquina identificam padrões e relações não-lineares, essenciais para classificação em geociências (PEDREGOSA et al., 2011). Nesse contexto, o modelo Random Forest (Breiman, 2001) é amplamente utilizado por sua robustez ao combinar diferentes árvores de decisão de maneira independente.

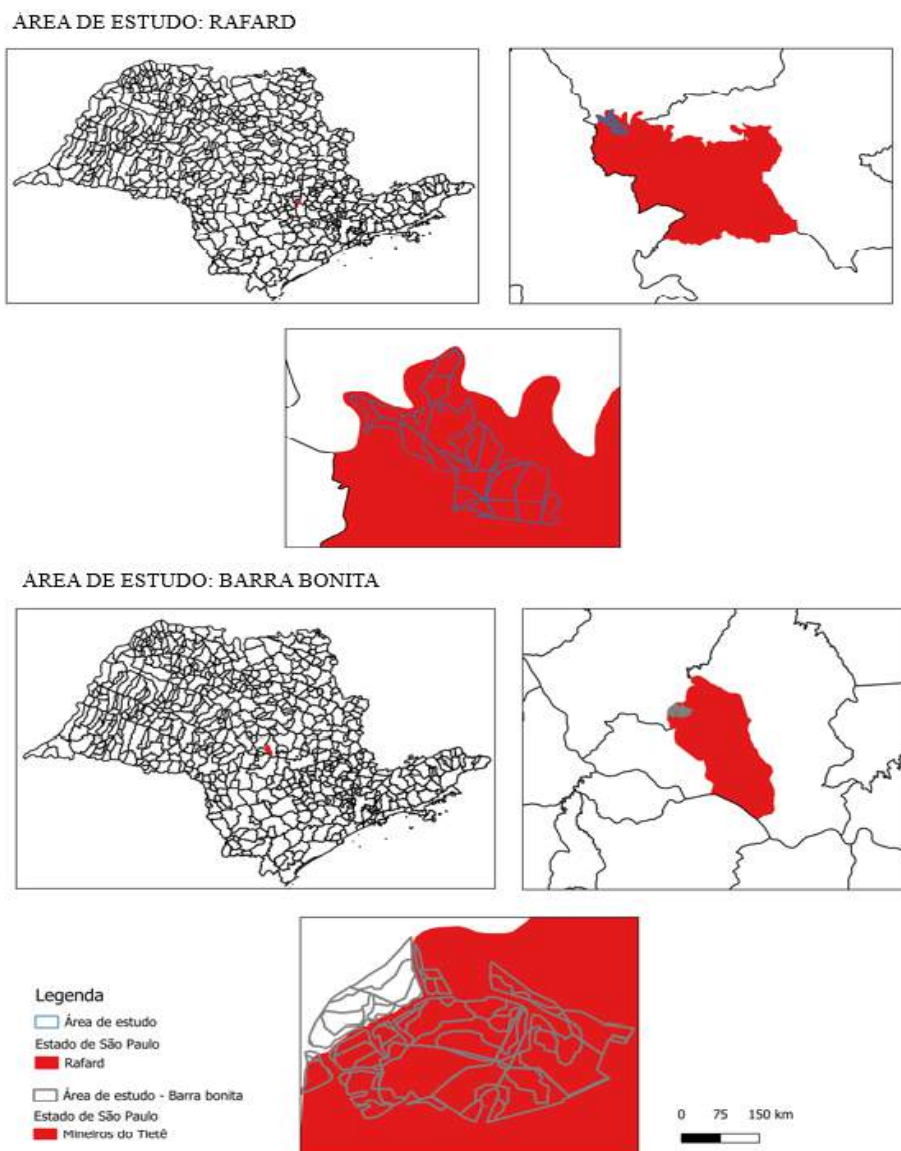
Para garantir a confiabilidade das análises, testes estatísticos como ANOVA e Kruskal-Wallis verificam se diferenças entre classes de solo são estatisticamente significativas. O desempenho do classificador é avaliado por métricas como matriz de confusão, acurácia e F1-score, assegurando rigor metodológico e evitando que o modelo apenas memorize os dados (PEDREGOSA et al., 2011).

3 MATERIAIS E MÉTODOS

3.1 Áreas de estudo

As áreas de estudo deste trabalho correspondem às fazendas localizadas nos municípios de Rafard e Barra Bonita, no Estado de São Paulo. Essas áreas apresentam solos considerados representativos da região e são tradicionalmente utilizadas para o cultivo de cana-de-açúcar, atividade predominante na porção central do estado (Figura 1).

Figura 01: Áreas de estudo - Rafard e Barra Bonita



Fonte: Elaboração própria (2025) com base em dados de malhas territoriais do Instituto Brasileiro de Geografia e Estatística (IBGE).

3.1.1 Fazenda Rafard

A área da Fazenda Rafard possui uma extensão de 175,54 hectares, localizada no município de Rafard, na porção centro-leste do estado de São Paulo (coordenadas: 22,9959° S; 47,6309° O) (Figura 1).

O município está inserido na província geomorfológica da Depressão Periférica Paulista, caracterizada por colinas amplas e suavemente onduladas, resultantes de longos processos erosivos sobre rochas sedimentares da Bacia do Paraná (ROSS, 1992; IBGE, 2019).

A geologia local é composta predominantemente por sedimentos do subgrupo Itararé, pertencente ao grupo Tubarão, com litologia diversificada: arenitos ($\approx 40\%$), siltitos e lamitos ($\approx 30\%$), diamictitos ($\approx 15\%$) e intrusões de diabásio ($\approx 14\%$) (VAMIER et al., 2005). Essa heterogeneidade geológica influencia diretamente a pedogênese regional, resultando em solos argilosos, profundos e bem drenados, classificados principalmente como Latossolos Roxos Eutróficos segundo o Sistema Brasileiro de Classificação de Solos – SiBCS (EMBRAPA, 2018). Internacionalmente, correspondem a Ferralsols, Nitisols e Lixisols, de acordo com a FAO (2015).

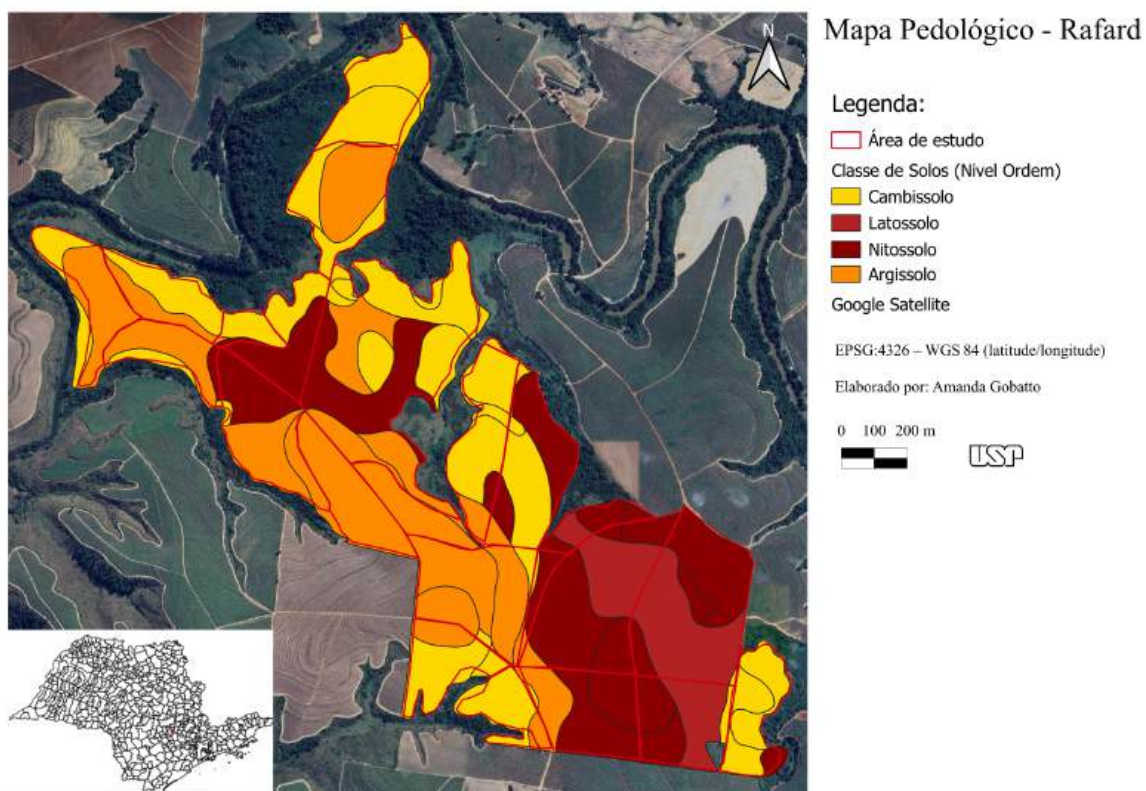
O clima é classificado, segundo Köppen, como Cfa – subtropical úmido, com verões quentes e invernos amenos, sem estação seca definida (PREFEITURA MUNICIPAL DE RAFARD, 2024). No entanto, outras fontes, como o CEPAGRI (2014) e a EMBRAPA (2014), descrevem o clima local como Aw – Tropical com inverno seco. A temperatura média anual é de $21,9\text{ }^{\circ}\text{C}$, com mínima média de $10,9\text{ }^{\circ}\text{C}$ em julho e máxima de $30,5\text{ }^{\circ}\text{C}$ em fevereiro. A precipitação anual média é de $1.232,2\text{ mm}$, concentrada entre outubro e março (CEPAGRI, 2014).

Em termos hidrográficos, Rafard pertence à UGRHI-5 – Bacias PCJ (Piracicaba, Capivari, Jundiá), segundo a Fundação Agência das Bacias PCJ (2013). O município é drenado principalmente pelo Rio Capivari e pelo Córrego São Francisco, e utiliza o Sistema Aquífero Tubarão para abastecimento público, reforçando a relevância dos recursos hídricos subterrâneos (VAMIER et al., 2005).

O uso e ocupação do solo no município é majoritariamente agrícola, destacando-se o cultivo de cana-de-açúcar, conforme o MapBiomias (2024).

A classificação dos solos foi baseada em dois níveis de análise disponíveis na legenda dos mapas utilizados. No nível de ordem, foram identificadas as seguintes classes: Cambissolos, Latossolos, Nitossolos e Argissolos (Figura 2).

Figura 02: Mapa Pedológico - Rafard. As classes de solos apresentadas neste mapa estão no 1º nível categórico (Ordens) do Sistema Brasileiro de Classificação de Solos (SiBCS).



Fonte: ADAPTADO DE NANNI et al. (2012).

A seguir, serão descritas as principais classes de solos identificadas na área de estudo, com base em suas características morfológicas e nos processos de formação que influenciam a aptidão agrícola.

Os Latossolos, por exemplo, são solos muito antigos e evoluídos, comuns em climas quentes e úmidos. Sua principal característica é um horizonte B latossólico, homogêneo, profundo e sem acúmulo de argila. O processo de laterização, que envolve a lavagem de minerais, os torna porosos e bem drenados, mas com baixa fertilidade natural e acidez, conforme descrito por Lepsch (2010).

Em contraste, os Nitossolos também possuem horizonte B, mas com estrutura em blocos, conferindo maior estabilidade, aeração e permeabilidade. Esses solos, de grande importância

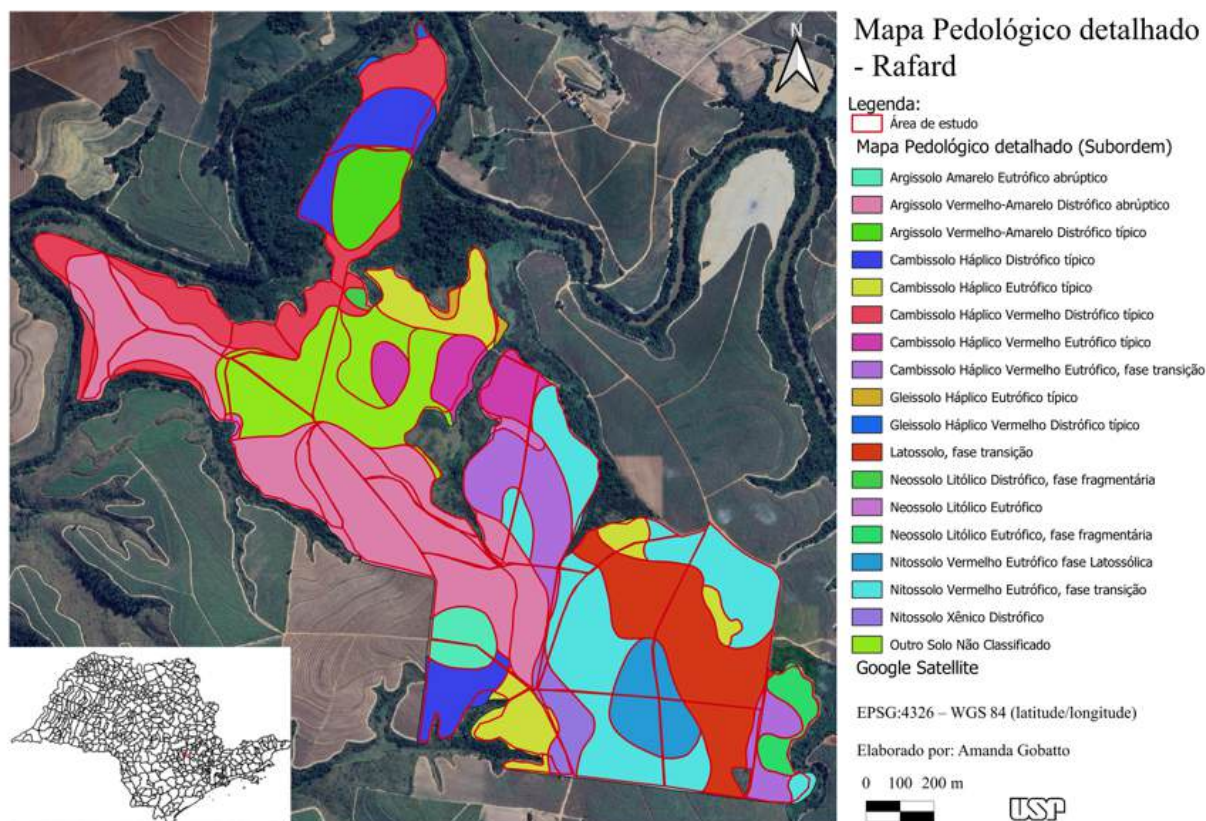
agrícola, são formados pelo processo de nitrificação e apresentam alta fertilidade natural (LEPSCH, 2010).

Outra classe de solo relevante são os Argissolos, que se distinguem pela presença de um horizonte B textural com maior teor de argila do que o horizonte A. A argiluviação, processo que transporta argila para as camadas inferiores, torna essa camada mais compacta, podendo dificultar a infiltração de água e o desenvolvimento radicular (LEPSCH, 2010).

Por fim, os Cambissolos representam um estágio inicial de formação, sem horizonte B textural bem desenvolvido. Formados pela alteração direta da rocha-mãe, são geralmente rasos a moderadamente profundos e com baixa mobilidade de argila, o que limita o desenvolvimento das raízes (LEPSCH, 2010).

A próxima figura apresenta o mapa pedológico detalhado em escala 1:10.000 da Fazenda Rafard (Figura 3), revelando a ocorrência de unidades mais homogêneas classificadas no nível de subordem, como Argissolo Amarelo, Cambissolo Háplico e Latossolo Vermelho. Mapas pedológicos detalhados possuem maior precisão taxonômica, permitindo analisar com mais detalhe a influência de cada tipo de solo sobre o desenvolvimento da cana-de-açúcar.

Figura 03: Mapa Pedológico detalhado - Rafard. As classes de solos apresentadas neste mapa estão no 4º nível categórico (Ordens) do Sistema Brasileiro de Classificação de Solos (SiBCS).



Fonte: ADAPTADO DE NANNI et al. (2012).

Quanto aos aspectos sociais, o município de Rafard, com população estimada de 9.076 habitantes em 2019 e densidade demográfica de 70,80 hab/km² (2010) (PREFEITURA MUNICIPAL DE RAFARD, 2024), possui Índice de desenvolvimento humano municipal (IDHM) de 0,745 (2010), considerado alto. A economia é marcada pelo setor de serviços, responsável por 15,69% dos empregos formais, com salário médio de 2,4 salários mínimos em 2017 (PREFEITURA MUNICIPAL DE RAFARD, 2024).

A cidade, conhecida como “Cidade Coração”, tem uma história ligada à agricultura e à imigração italiana, iniciada com a fundação de uma usina de açúcar por Júlio Henrique Raffard em 1876 (PREFEITURA MUNICIPAL DE RAFARD, 2024). A taxa de escolarização para crianças de 6 a 14 anos é elevada (98,3% em 2010) e o município conta com esgotamento sanitário adequado para 90,8% da população, indicando bom nível de infraestrutura (PREFEITURA MUNICIPAL DE RAFARD, 2024).

3.1.2 Fazenda Barra Bonita

O presente trabalho teve como segunda área de estudo a Fazenda Barra Bonita, localizada no município de Mineiros do Tietê, na porção central do estado de São Paulo (coordenadas: 22,42531° S; 48,50309° O). O município situa-se em uma zona de transição entre a Depressão Periférica Paulista e a Bacia do Paraná, pertencendo à microrregião de Jaú, conhecida como Vale do Médio Tietê (PREFEITURA MUNICIPAL DE MINEIROS DO TIETÊ, [s.d.]).

O clima local, segundo a classificação de Köppen, é do tipo Cwa (subtropical de altitude), caracterizado por verões quentes e chuvosos e invernos secos (SEPLAN, 2012). O IBGE, no entanto, descreve o município como apresentando clima tropical úmido, com altitude média de 639 metros (IBGE, 2024).

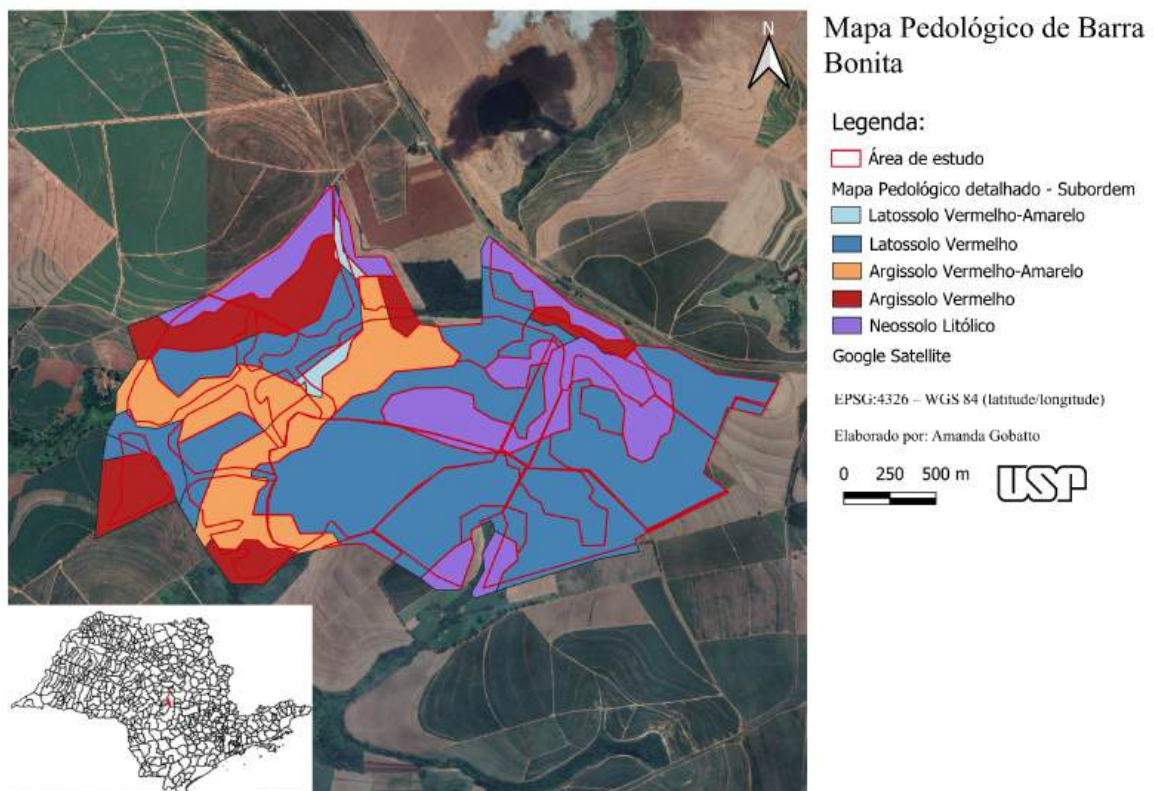
Do ponto de vista geológico e geomorfológico, a área estudada está assentada sobre rochas sedimentares e vulcânicas do Grupo Bauru, formadas no Cretáceo Superior. A geologia é dominada por arenitos das formações Adamantina e Marília (IPT, 1981). O relevo apresenta chapadões e colinas amplas, formas típicas da Depressão Periférica Paulista (ROSS, 1992; IBGE, 2019). A pedologia regional é bastante variada, incluindo Latossolos Vermelhos distróficos, Nitossolos Vermelhos e Argissolos, classes equivalentes aos Lixisols na classificação FAO (2015). Também ocorrem manchas de “terra roxa”, tradicionalmente associadas à elevada fertilidade (PREFEITURA MUNICIPAL DE MINEIROS DO TIETÊ, [s.d.]). Essa variabilidade pedológica influencia a retenção de água e a fertilidade, afetando diretamente a produtividade da cana-de-açúcar (ACORSI AMORIM et al., 2022).

A hidrografia municipal é marcada pelo rio Tietê, que funciona como divisa com São Manuel e foi represado para a formação do reservatório da Usina Hidrelétrica de Barra Bonita. A área conta ainda com ribeirões como São João da Prata e Três Barras, além de diversos córregos que integram a bacia hidrográfica do Tietê.

Em relação à pedologia em escala 1:50.000 (Figura 4), destaca-se a ocorrência de Neossolos, solos com pouca ou nenhuma diferenciação de horizontes e considerados jovens. Segundo Lepsch (2013), esses solos herdam suas características diretamente da rocha-mãe. Uma variação importante é o Neossolo Litólico, desenvolvido sobre rocha dura e contínua. Por apresentar profundidade inferior a 50 cm, com o horizonte A assentado diretamente sobre o

horizonte R — esse solo é extremamente raso, limitando significativamente o desenvolvimento radicular das culturas.

Figura 4: Mapa pedológico da área da fazenda Barra Bonita. As classes de solos apresentadas neste mapa estão no 2º nível categórico (Subordens) do Sistema Brasileiro de Classificação de Solos – SiBCS (SANTOS et al., 2018).



Fonte: ADAPTADO DE ARRUDA et al. (2013).

Quanto aos aspectos socioeconômicos, Mineiros do Tietê possui uma população estimada de 11.349 habitantes em 2024, com densidade demográfica de 52,66 hab/km² (IBGE, 2024). O Índice de Desenvolvimento Humano Municipal (IDHM) é de 0,730 (2010), considerado alto (ATLAS BRASIL, 2010). A taxa de escolarização de crianças entre 6 e 14 anos alcança 99,59% (IBGE, 2024), enquanto a taxa de mortalidade infantil é de 16,95 óbitos por mil nascidos vivos.

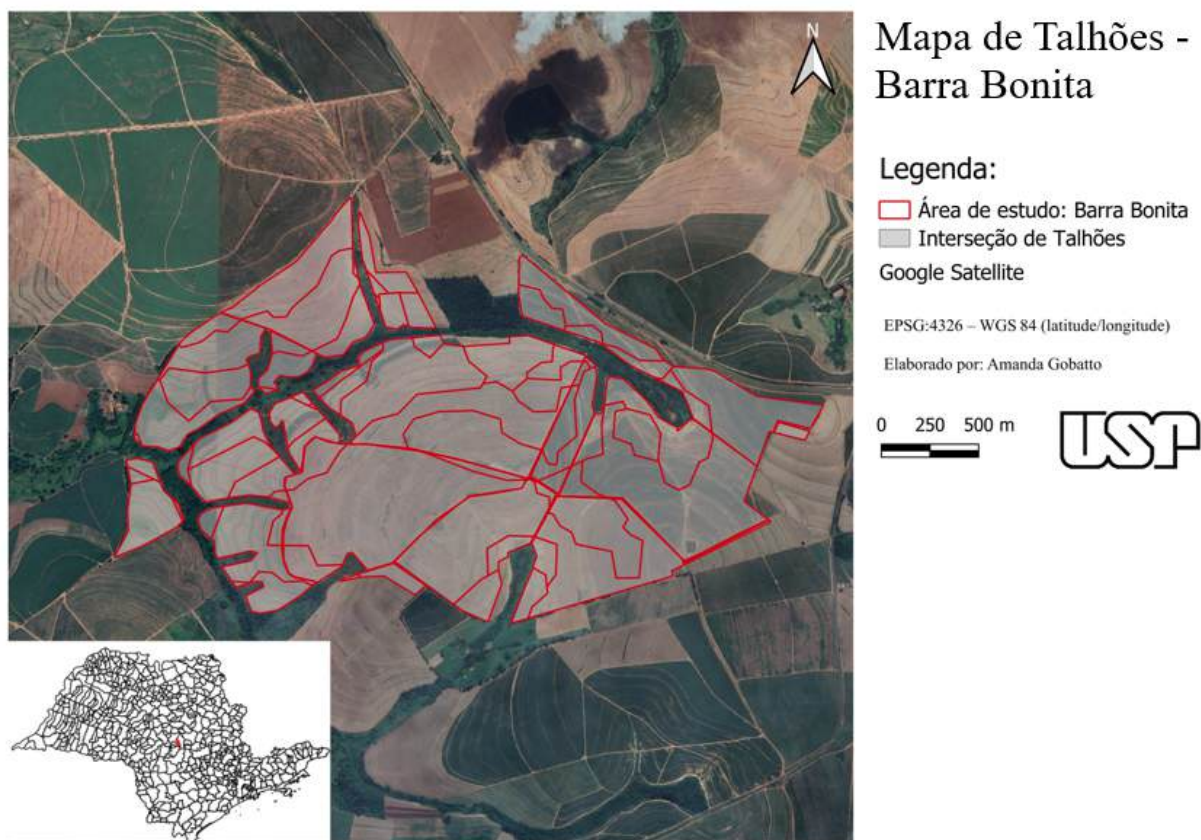
A economia municipal é fortemente ligada à agricultura, com destaque para a produção de cana-de-açúcar. O setor industrial, embora menos expressivo, inclui curtumes e alambiques (CÂMARA MUNICIPAL DE MINEIROS DO TIETÊ, 2017). O PIB per capita municipal foi

de R\$ 17.373,68 em 2021 (IBGE, 2024). No que diz respeito à infraestrutura de saneamento, o município conta com coleta de lixo, aterro sanitário e serviços de tratamento de água e esgoto (CÂMARA MUNICIPAL DE MINEIROS DO TIETÊ, 2017).

3.2 Delimitação de talhões e interseção com mapa pedológico

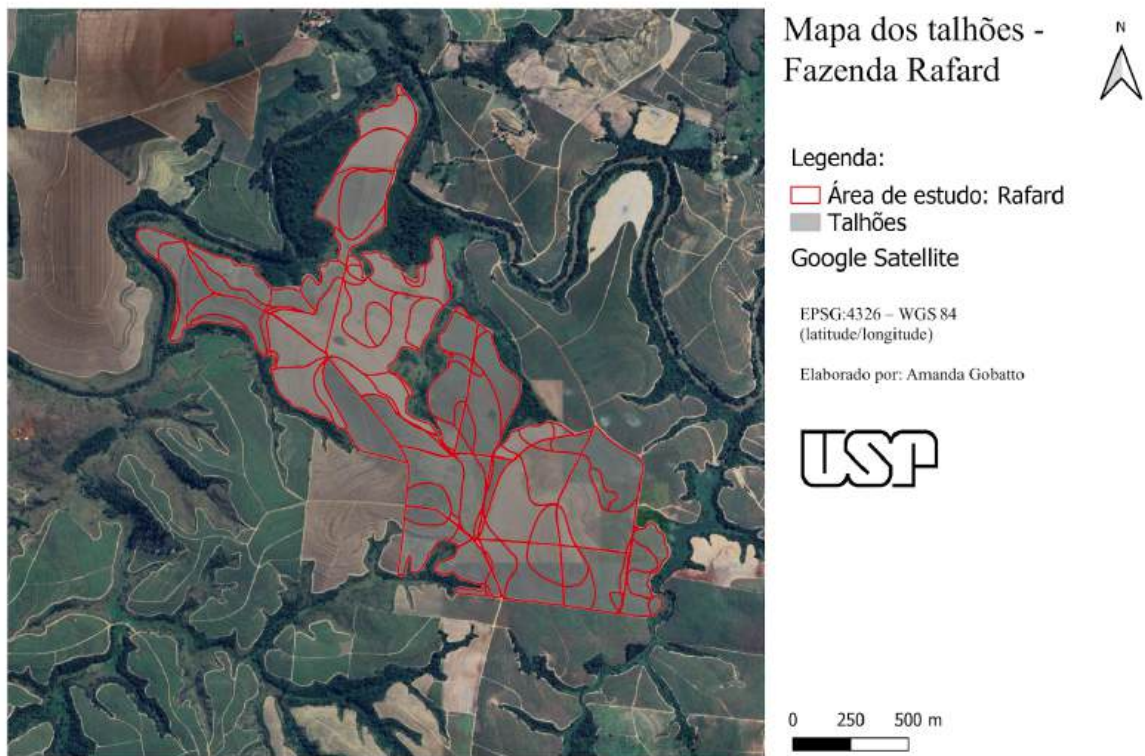
Considerando que as unidades de mapeamento dos mapas pedológicos abrangem áreas sob diferentes usos e manejos, e que, inversamente, áreas conduzidas sob um mesmo manejo podem apresentar distintas classes de solos, a delimitação dos talhões em ambas fazendas constituiu uma etapa fundamental. Essa delimitação permitiu a interseção com os mapas pedológicos e, conseqüentemente, a obtenção de unidades de análise espacial mais homogêneas, permitindo a correlação entre o desenvolvimento da cultura e as classes de solos presentes nas fazendas de Rafard e Barra Bonita. O processo foi realizado com apoio do software de geoprocessamento de código aberto QGIS (QGIS.org, 2024).

Figura 05: Mapa de Talhões



Fonte: ADAPTADO DE ARRUDA et al. (2013).

Figura 06: Mapa Pedológico de Rafard: Classes de Solos por Interseção de Talhões



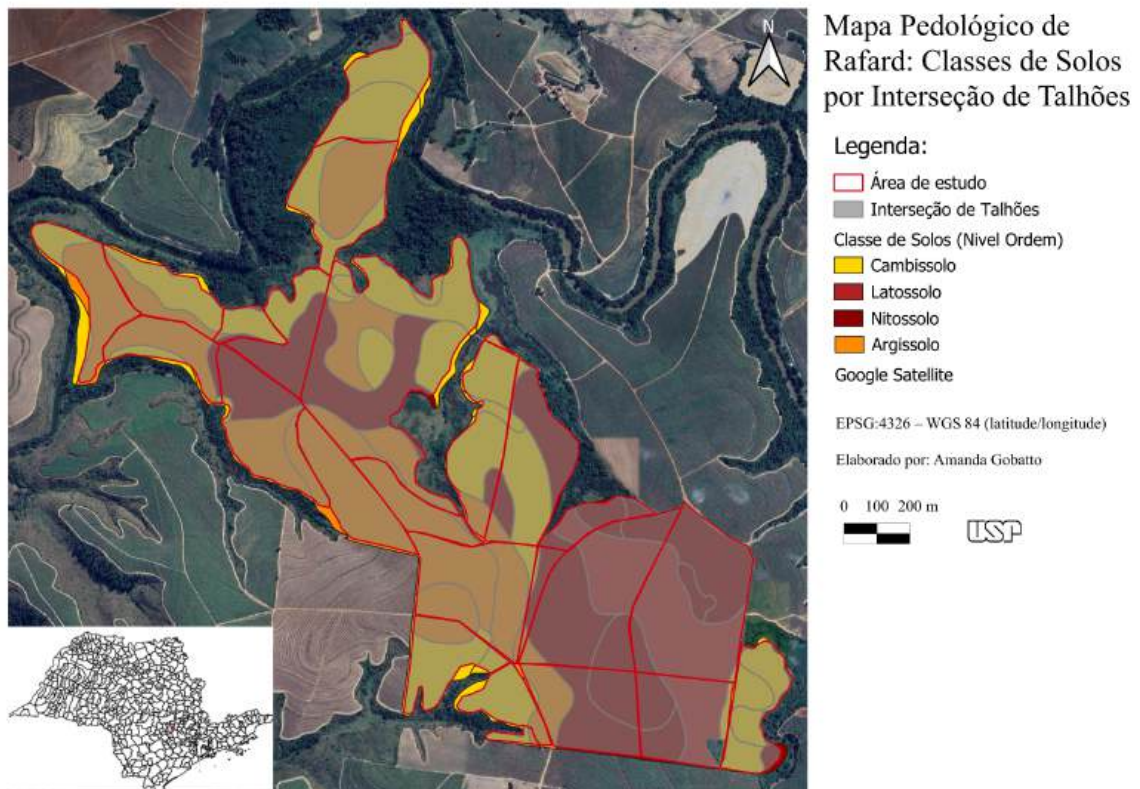
Fonte: ADAPTADO DE NANNI et al. (2012).

Para ambas as fazendas, a etapa inicial consistiu na criação de uma nova camada vetorial, do tipo polígono, denominada "Talhões". A delimitação manual dos limites de cada talhão foi realizada por meio de um processo de digitalização ponto a ponto, utilizando como base de visualização o geoportal Google Satellites, uma ferramenta do QGIS que fornece imagens de alta resolução espacial. A partir da interpretação visual dessas imagens, foram identificados conjuntos de plantações de cana-de-açúcar que formavam uma área contínua, sem interrupção por carreadores, estradas ou outras feições de manejo. Esse processo resultou na criação de figuras homogêneas para as análises subsequentes.

O mapa pedológico, fornecido por Nanni e Demattê (2006), foi o ponto de partida para a integração dos dados. Para refinar a análise e criar unidades de estudo mais homogêneas, os polígonos dos talhões foram interligados com o mapa pedológico por meio da ferramenta de interseção do QGIS. Essa operação de geoprocessamento gerou uma terceira camada vetorial, na qual cada novo polígono representa a porção de um talhão que se sobrepunha a uma classe de solo específica. O objetivo foi fragmentar a área total de estudo em unidades menores e

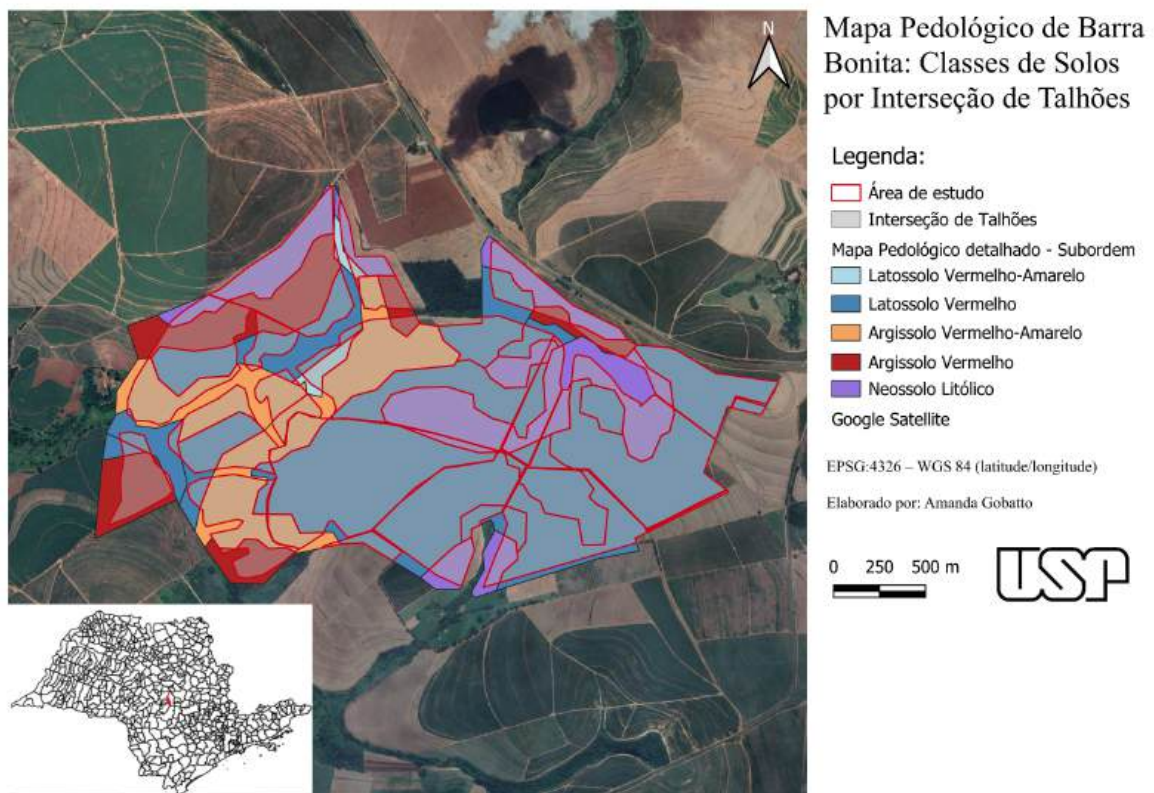
homogêneas, o que permitiu que as análises fossem mais precisas, assegurando que o desenvolvimento da cultura fosse avaliado em relação às classes de solos predominantes em cada subárea.

Figura 7: Mapa pedológico da área da Fazenda Rafard. As classes de solos apresentadas neste mapa estão no 1º nível categórico (Ordens) do Sistema Brasileiro de Classificação de Solos (SiBCS).



Fonte: ADAPTADO DE NANNI et al. (2012).

Figura 08: Classes de solos por interseção de talhões. As classes de solos apresentadas neste mapa estão no 2º nível categórico (Subordens) do Sistema Brasileiro de Classificação de Solos (SiBCS).



Fonte: ADAPTADO DE ARRUDA et al. (2013).

Essa camada de interseção, contendo as informações combinadas de talhões e solos, foi exportada como um conjunto de shapefiles para ser utilizada no Google Earth Engine (GEE) (Gorelick et al., 2017). A escolha dessa plataforma se deu pelas suas vantagens em relação ao QGIS, pois o GEE, sendo uma plataforma de computação em nuvem, permitiu processamentos em larga escala e de forma eficiente, eliminando a necessidade de downloads e de uma infraestrutura local robusta (GOOGLE, 2023). Além disso, sua capacidade de integrar dados de diversos satélites em um único ambiente agilizou a análise temporal, crucial para esta pesquisa.

3.3 Aquisição e pré-processamento de imagens de satélite

O monitoramento da cana-de-açúcar por sensoriamento remoto é essencial para analisar o desenvolvimento da planta ao longo do ciclo de cultivo (ACORSI AMORIM et al., 2022). Este estudo utilizou dados de sensores imageadores ópticos e de radar, das missões Landsat 8,

Sentinel-2 e Sentinel-1, para representar a biomassa aérea da cultura no período de janeiro de 2019 a maio de 2025.

As imagens ópticas dos satélites Sentinel-2 e Landsat 8 foram obtidas com valores de reflectância de superfície, um nível de processamento que transforma os dados brutos em uma medida real da luz que o solo e a vegetação refletem, removendo distorções causadas pela atmosfera (GORELICK et al., 2017). Para garantir a qualidade da análise, a remoção de nuvens e suas sombras foi feita com as bandas de controle de qualidade nativas dos satélites (a banda QA_PIXEL do Landsat e a QA60 do Sentinel-2), o que é essencial para que os resultados reflitam a realidade da superfície (ZHU, 2017). As imagens já pré-processadas foram extraídas diretamente dos catálogos de dados no GEE. Para o Landsat 8, foi utilizada a coleção LANDSAT/LC08/C02/T1_L2 (USGS, 2024). Para o Sentinel-2, empregou-se a coleção COPERNICUS/S2_SR_HARMONIZED, que contém o produto Sentinel-2 level-2A surface reflectance, harmonizado entre os satélites Sentinel-2A e 2B (COPERNICUS, 2024).

Em contraste, as imagens de radar do Sentinel-1 operam com um sensor de Radar de Abertura Sintética (SAR) e não são afetadas por nuvens (WOODHOUSE, 2017). O sensor SAR emite pulsos de energia e mede o sinal que retorna, capturando informações sobre a estrutura física dos objetos no solo (WOODHOUSE, 2017). Para preparar os dados, a plataforma GEE aplicou automaticamente a correção de órbita; no entanto, a aplicação de filtros de redução de ruído, conhecidos como *speckle filtering*, não foi realizada. Essa foi uma decisão metodológica, pois a análise de séries temporais de longa duração tende a minimizar o impacto desse ruído na interpretação dos resultados. Os dados de radar foram obtidos da coleção COPERNICUS/S1_GRD, que corresponde ao satélite Sentinel-1 Ground range detected (GRD), (ESA, 2024).

Tabela 1: Especificações dos Sensores e bandas utilizados

Missão de Satélite	Sensor	Nível de Processamento	Tipo de Banda	Nome da Banda	Comprimento de Onda Central (nm)	Resolução Espacial (m)
Sentinel-2	MSI	L2A (SR)	Óptico	B4 (Vermelho)	665 nm	10
			Óptico	B8 (NIR)	842 nm	10
			Óptico	B5 (Red-edge 1)	705 nm	20
			Óptico	B6 (Red-edge 2)	740 nm	20
			Óptico	B7 (Red-edge 3)	783 nm	20
			Óptico	B8A (NIR)	865 nm	20
			Óptico	B11 (SWIR 1)	1610 nm	20
			Óptico	B12 (SWIR 2)	2190 nm	20
Landsat 8	OLI	L2 (SR)	Óptico	B4 (Vermelho)	636-673 nm	30
			Óptico	B5 (NIR)	851-879 nm	30
			Óptico	B6 (SWIR 1)	1566-1651 nm	30
			Óptico	B7 (SWIR 2)	2107-2294 nm	30
Sentinel-1	C-SAR	GRD	Radar	VV e VH (Banda C)	~ 5,6 cm	10

3.4 Cálculo de índices espectrais e obtenção de mosaicos

Para avaliar a produtividade da cultura de cana-de-açúcar e sua relação com a classificação dos solos, foram calculados diversos índices espectrais de vegetação a partir das séries temporais de imagens de satélite. A análise utilizou a plataforma Google Earth Engine (GEE).

Os seguintes índices foram calculados, conforme suas formulações originais e aplicações consolidadas na literatura científica:

NDVI (Normalized Difference Vegetation Index) : O NDVI estima a densidade e o vigor da vegetação a partir da razão entre as reflectâncias do infravermelho próximo (NIR) e do vermelho (RED), sendo amplamente utilizado em estudos de sensoriamento remoto (TUCKER, 1979). É expresso pela equação:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Esse índice serve como indicador robusto da biomassa fotossinteticamente ativa e da cobertura vegetal (HUETE et al., 2002).

LAI (Leaf Area Index): O LAI representa a área foliar total por unidade de área de solo e é um parâmetro biofísico fundamental no monitoramento da vegetação (WATSON, 1947). Neste estudo, o LAI foi estimado indiretamente por meio de uma relação empírica com o NDVI, conforme modelo proposto e validado por Boegh et al. (2002):

$$LAI = 3.618 \times NDVI + 0.118$$

CIRE (Chlorophyll Index Red Edge): O CIRE utiliza bandas espectrais localizadas na região da borda vermelha (*red edge*), sensível à concentração de clorofila nas folhas, sendo uma métrica precisa para avaliação do estado fisiológico da vegetação (GITELSON et al., 2003).

$$CIRE = \frac{NIR}{RedEdge} - 1$$

RVI (Radar Vegetation Index): O RVI é derivado de dados de radar de abertura sintética (SAR), sensível à estrutura e à biomassa da vegetação. É calculado a partir das polarizações VV (vertical-vertical) e VH (vertical-horizontal) do Sentinel-1 (TRIPATHI et al., 2018; SZIGARSKI et al., 2018), segundo a fórmula.

$$RVI = \frac{4 \times VH}{VV + VH}$$

Antes do cálculo, os valores das bandas VV e VH foram convertidos de escala decibel (dB) para linear, conforme a expressão:

$$\text{Linear} = 10^{\left(\frac{\sigma_{dB}}{10}\right)}$$

Essa conversão é necessária, pois o produto Sentinel-1 GRD fornece os coeficientes de retroespalhamento em dB, enquanto o índice requer valores lineares para resultados consistentes. O RVI varia entre 0 e 1, em que valores mais altos indicam maior densidade e biomassa da vegetação.

Estudos recentes apontam que o RVI também pode discriminar classes de solo, mesmo em áreas com baixa cobertura vegetal, devido à sensibilidade do sinal SAR à rugosidade superficial e ao teor de umidade (SZIGARSKI et al., 2018; STANYER et al., 2025).

As séries temporais dos índices foram integradas em mosaicos compostos em diferentes janelas temporais (3, 6 e 12 meses) e com diferentes estatísticas (média e percentil 97). A utilização do percentil 97 (P97) foi uma decisão metodológica para representar o pico de desenvolvimento da cultura em cada ciclo, reduzindo a influência de pixels com baixa vegetação ou interferências de manejo.

3.5 Análises estatísticas

A análise estatística foi estruturada para verificar o nível de relação e significância entre os mosaicos de índices de vegetação e classes de solos. O processo foi organizado em etapas, incluindo testes de hipótese univariados, análises multivariadas e a aplicação de um modelo de aprendizado de máquina.

Na primeira etapa, buscou-se identificar diferenças entre as classes de solo a partir dos índices de vegetação (como NDVI e EVI2). Para isso, foram aplicados os testes de Análise de Variância (ANOVA) e o teste não paramétrico de Kruskal-Wallis. A ANOVA foi escolhida por permitir comparar as médias dos índices entre mais de dois grupos e verificar se as diferenças observadas são estatisticamente significativas, desde que os dados atendam aos pressupostos de normalidade e homogeneidade de variâncias (MONTGOMERY, 2019; SOKAL; ROHLF, 2012). Quando esses pressupostos não foram satisfeitos, verificados por meio dos testes de Shapiro-Wilk e Levene, utilizou-se o teste de Kruskal-Wallis, que é uma alternativa robusta por não depender da distribuição normal dos dados (FIELD; MILES; FIELD, 2012).

Para quantificar a capacidade de separação de cada índice em relação às classes de solo, foi utilizada a estatística Eta ao Quadrado (η^2). Essa métrica representa uma medida do tamanho do efeito (effect size), indicando a proporção da variância total do índice espectral atribuída às diferenças entre as classes de solo (COHEN, 1988). Valores mais elevados refletem maior capacidade discriminante dos índices em relação às classes pedológicas. Nos cenários não paramétricos, utilizou-se a forma η^2 derivada de Kruskal-Wallis.

Após a detecção de diferenças significativas, aplicaram-se testes post-hoc para identificar quais classes de solo se diferenciavam entre si. Para os casos paramétricos, foi utilizado o Tukey HSD, enquanto nas análises não-paramétricas aplicou-se o teste de Dunn (FIELD; MILES; FIELD, 2012).

Em uma segunda etapa, a Análise de Variância Multivariada (MANOVA) foi utilizada para avaliar simultaneamente o efeito de múltiplos índices espectrais, evitando erros associados à execução de várias ANOVAs independentes em variáveis correlacionadas (TABACHNICK; FIDELL, 2019).

Por fim, para a etapa de predição, foi aplicado o modelo de aprendizado de máquina Random Forest, baseado em múltiplas árvores de decisão (BREIMAN, 2001). Para evitar sobreajuste (overfitting) e garantir a robustez do modelo, foi utilizada a validação cruzada k-fold. O desempenho foi avaliado por meio da matriz de confusão, bem como pelas métricas de acurácia e F1-score, assegurando uma avaliação abrangente da qualidade do classificador (PEDREGOSA et al., 2011).

4 RESULTADOS

4.1 Análises estatísticas univariadas (ANOVA/Kruskal-Wallis e Eta^2)

As análises univariadas confirmaram a presença de diferenças estatisticamente significativas entre as classes de solo e o desenvolvimento da cana-de-açúcar, representado pelas séries temporais de índices de vegetação. Foram avaliados 156 cenários distintos, resultantes das combinações entre quatro índices espectrais (NDVI, LAI, CIRE e RVI), três intervalos temporais de agregação (3, 6 e 12 meses), duas estatísticas descritivas (média e percentil 97), dois níveis de classificação pedológica (ordem e subordem) e duas áreas de estudo (fazenda Rafard e fazenda Barra Bonita).

Essa estrutura permitiu avaliar, de forma sistemática, como diferentes condições de solo e janelas temporais influenciam a resposta espectral da vegetação ao longo do ciclo produtivo. Nos testes de Kruskal–Wallis, 108 cenários apresentaram valores de p inferiores a 0,05, indicando diferenças estatisticamente significativas entre as classes de solo. O limiar de $p < 0,05$, amplamente utilizado na literatura, permite rejeitar a hipótese nula de igualdade entre grupos com 95% de confiança (FIELD; MILES; FIELD, 2012). Esses resultados reforçam que os índices espectrais respondem de maneira diferenciada às variações de solo, corroborando a hipótese de que propriedades edáficas influenciam o vigor e o desenvolvimento da cana-de-açúcar (Nanni et al., 2022; Ben-Dor et al., 2008).

Em seguida, foi calculado o Eta ao Quadrado (η^2), utilizado como medida da força de associação entre classes de solo e índices de vegetação. No contexto dos testes não paramétricos, essa estatística pode assumir valores superiores a 1, sendo interpretada como tamanho de efeito e categorizada conforme Tomczak e Tomczak (2014), que consideram valores acima de 0,80 como efeitos muito grandes

Tabela 2: Cenários com maiores valores de η^2 (Kruskal–Wallis) para a Fazenda Rafard. O índice RVI do Sentinel-1 apresentou o maior poder de distinção entre classes de solo, especialmente nos intervalos de 6 e 12 meses.

Fazenda	Satélite	Intervalo	Índice	Estatística	Solo	η^2
Rafard	Sentinel-1	6 meses	RVI	Média	Ordem	5.382
Rafard	Sentinel-1	12 meses	RVI	Média	Ordem	4.955
Rafard	Sentinel-1	6 meses	RVI	P97	Ordem	4.078
Rafard	Sentinel-1	6 meses	RVI	Média	Subordem	3.015
Rafard	Sentinel-1	12 meses	RVI	P97	Subordem	2.828

Fonte: elaborado pela autora (2025)

A Tabela 2 apresenta os cenários com maiores valores de η^2 para a fazenda Rafard. Verifica-se que o índice RVI do Sentinel-1 apresentou o maior poder discriminante, com valores variando entre 2,828 e 5,382. A sensibilidade do RVI a parâmetros estruturais do dossel, como biomassa, rugosidade superficial e umidade, favorece a detecção de diferenças relacionadas às condições edáficas, comportamento compatível com evidências de que características do solo influenciam processos fisiológicos ao longo do ciclo produtivo (Nanni et al., 2022). Nota-se também que janelas temporais mais longas (12 meses) apresentaram alguns dos maiores valores, sugerindo que séries anuais conseguem capturar efeitos cumulativos do solo sobre o desenvolvimento da planta, especialmente em períodos de maior expressão fenológica (Tucker, 1979; Watson, 1947).

Tabela 3: Cenários com maiores valores de Eta^2 para a Fazenda Barra Bonita. Assim como em Rafard, o RVI do Sentinel-1 mostrou maior separação entre solos nas janelas de 6 e 12 meses.

Fazenda	Satélite	Intervalo	Índice	Estatística	Solo	Eta^2
Barra Bonita	Sentinel-1	12 meses	RVI	Média	Ordem	4.316
Barra Bonita	Sentinel-1	6 meses	RVI	Média	Ordem	4.291
Barra Bonita	Sentinel-1	12 meses	RVI	P97	Ordem	3.991
Barra Bonita	Sentinel-1	6 meses	RVI	P97	Ordem	3.850
Barra Bonita	Sentinel-1	12 meses	RVI	Média	Ordem	3.759

Fonte: elaborado pela autora (2025)

Ao comparar a fazenda Rafard com a fazenda Barra Bonita (Tabela 3), observa-se que ambas apresentaram seus maiores valores de Eta^2 no índice RVI do sentinel-1, especialmente nas janelas de 6 e 12 meses. Em Barra Bonita, os valores variaram entre 3,759 e 4,316, também classificados como efeitos muito grandes. Embora ligeiramente inferiores aos de Rafard, o padrão geral se repete, indicando desempenho consistente do RVI na distinção entre classes de solo nas duas áreas.

Entretanto, mesmo com valores elevados de Eta^2 , a separação visual nas figuras subsequentes mostrou-se menos pronunciada em Barra Bonita, resultado que será discutido adiante, já que diferenças de manejo, relevo e homogeneidade pedológica podem reduzir a expressividade visual dos grupos.

4.2 Análise multivariada – MANOVA

A Análise multivariada de variância (MANOVA) foi empregada com o objetivo de avaliar, de forma conjunta, a influência das classes de solo sobre múltiplos índices de vegetação. Essa abordagem é especialmente útil quando as variáveis dependentes são correlacionadas, pois permite verificar padrões multivariados que poderiam não aparecer em análises univariadas, além de reduzir o risco de erros do tipo I decorrentes da execução de diversas ANOVAs independentes (TABACHNICK; FIDELL, 2019).

Apesar de as análises univariadas (ANOVA e Kruskal–Wallis) terem identificado diferenças estatisticamente significativas entre classes de solo para diversos índices isolados, a

MANOVA não encontrou significância estatística em nenhuma das 63 combinações avaliadas ($p > 0,05$). Conforme sintetizado no Anexo 1, isso indica que, quando os índices são avaliados simultaneamente, o conjunto das variáveis não apresenta contraste multivariado forte o suficiente para discriminar as classes de solo.

Dois fatores ajudam a explicar essa ausência de significância em nível multivariado. O primeiro é a elevada correlação entre os índices espectrais. NDVI, LAI, CIRE e RVI derivam de bandas relacionadas ao vigor vegetativo, biomassa ou estrutura do dossel, o que cria redundância entre as variáveis. Assim, diferenças que foram claras em análises univariadas tendem a se diluir quando avaliadas em conjunto, conforme já relatado na literatura de sensoriamento remoto agrícola (DEMATTE et al., 2010).

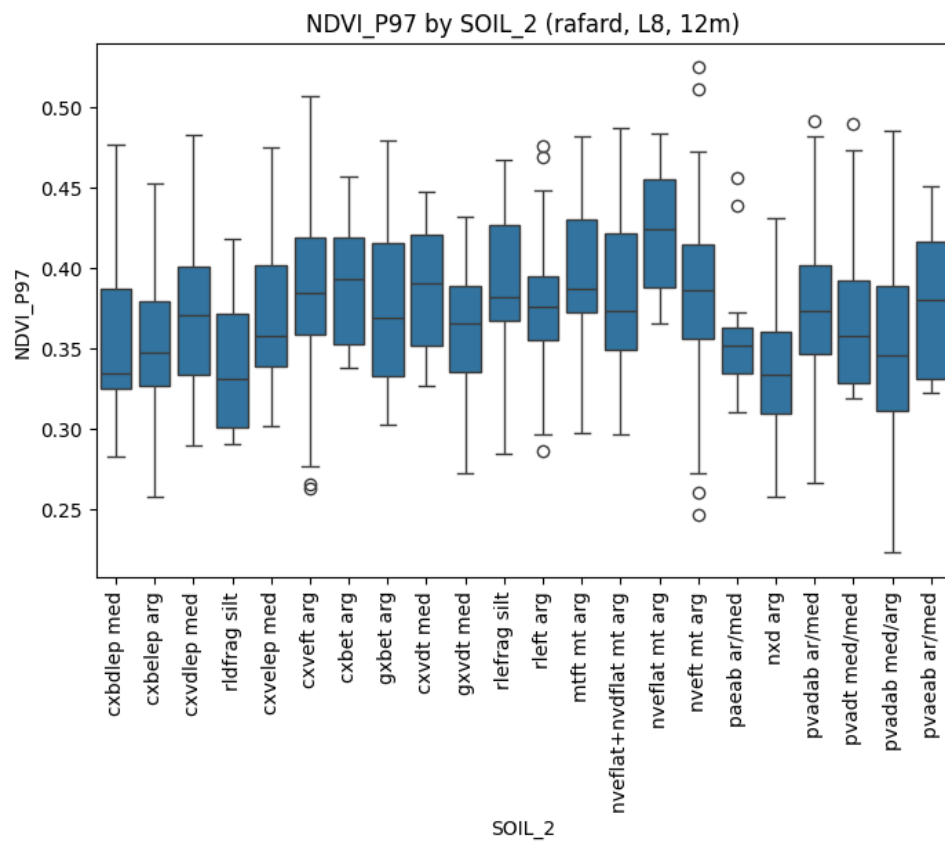
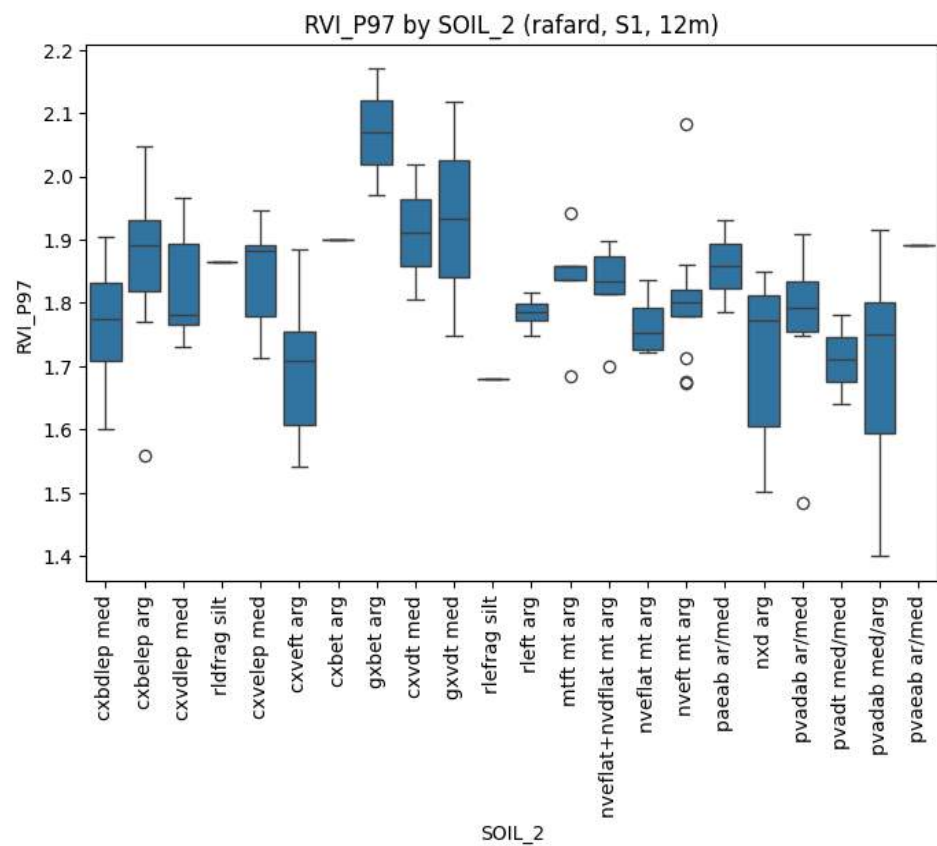
O segundo fator está associado à variabilidade não controlada do experimento, como diferenças de manejo, micro relevo ou condições microclimáticas específicas de cada área. Esses fatores introduzem dispersão adicional aos dados e podem reduzir a capacidade de a MANOVA detectar um sinal pedológico consistente, já que a técnica depende diretamente da relação entre variância explicada e variância residual.

Embora a MANOVA não tenha identificado significância estatística global, alguns resultados indicam tendências relevantes. Em especial, algumas combinações envolvendo RVI e NDVI em janelas de 12 meses apresentaram valores marginais de significância (próximos de 0,10). Isso sugere que, ainda que insuficiente para atingir o limiar convencional de 5%, a integração entre índices ópticos e de radar pode reforçar padrões pedológicos mais sutis. Além disso, as janelas de 12 meses voltaram a se destacar como as mais sensíveis, reforçando a importância de considerar o ciclo fenológico completo para detectar efeitos cumulativos do solo.

Assim, embora a MANOVA não tenha confirmado diferenças multivariadas robustas entre os grupos de solo, os resultados sugerem que determinadas combinações de índices, especialmente aquelas envolvendo o RVI, possuem potencial para discriminação conjunta. Esses achados oferecem subsídios para investigações futuras, incluindo o uso de modelos multivariados com maior capacidade discriminante ou a incorporação de variáveis auxiliares que reduzam a redundância entre os índices espectrais.

4.3 Análise boxplot - Rafard

As Figuras 9 e 10 apresentam boxplots selecionados com base nos cenários que exibiram os maiores valores de Eta^2 para a fazenda Rafard. Para assegurar consistência metodológica, foram priorizados os índices com melhor desempenho estatístico nas análises univariadas, considerando: (i) o uso da estatística Percentil 97 (P97), que representa o pico de vigor da cultura, e (ii) agregações temporais longas, especialmente 12 meses, que se mostraram mais robustas para reduzir ruídos fenológicos e destacar diferenças entre as classes de solo. Embora os maiores valores de Eta^2 tenham ocorrido no nível de ordem, optou-se por apresentar os boxplots no nível de Subordem, de forma a evidenciar a capacidade de separação mesmo em agrupamentos pedológicos mais específicos e desafiadores.








Figura 9: Boxplots dos índices RVI (Sentinel-1), NDVI e LAI (Landsat-8), calculados com o Percentil 97 (P97) e agregação temporal de 12 meses para o nível de Subordens da Fazenda Rafard. A figura reúne os índices espectrais que apresentaram os maiores valores de Eta^2 nas análises univariadas, refletindo a maior capacidade de discriminar as classes pedológicas. A distribuição das séries por classe de solo evidencia diferenças consistentes no vigor e na estrutura do dossel, com destaque para a separação pronunciada obtida pelo RV

O RVI (Sentinel-1, P97, 12 meses) apresentou a separação visual mais marcada entre as classes. A classe gbet.arg (Gleissolo háplico eutrófico típico, textura argilosa) e gxvflt.med (Gleissolo Háplico distrófico típico, textura média) são maior aptidão agrícola exibiu mediana superior e intervalo interquartilico mais elevado, com pouca sobreposição entre os bigodes (*whiskers*). Esse comportamento reforça a sensibilidade do radar a parâmetros estruturais do dossel, biomassa, rugosidade e umidade, que respondem diretamente às limitações impostas por solos mais restritivos.

O NDVI (Landsat-8, P97, 12 meses) também mostrou tendência de maior vigor nas classes de melhor aptidão, mas com maior dispersão e sobreposição entre os quartis. Isso é compatível com a saturação espectral típica de índices ópticos em dosséis densos, que reduz sua capacidade de diferenciar restrições pedológicas mais sutis.

O LAI (Landsat-8, P97, 12 meses) apresentou comportamento semelhante ao NDVI, sugerindo menor acúmulo de biomassa em solos mais limitantes, embora com distinção menos clara do que a observada no RVI. O padrão reforça que atributos estruturais captados pelo radar são mais sensíveis a diferenças de solo do que medidas estritamente ópticas.



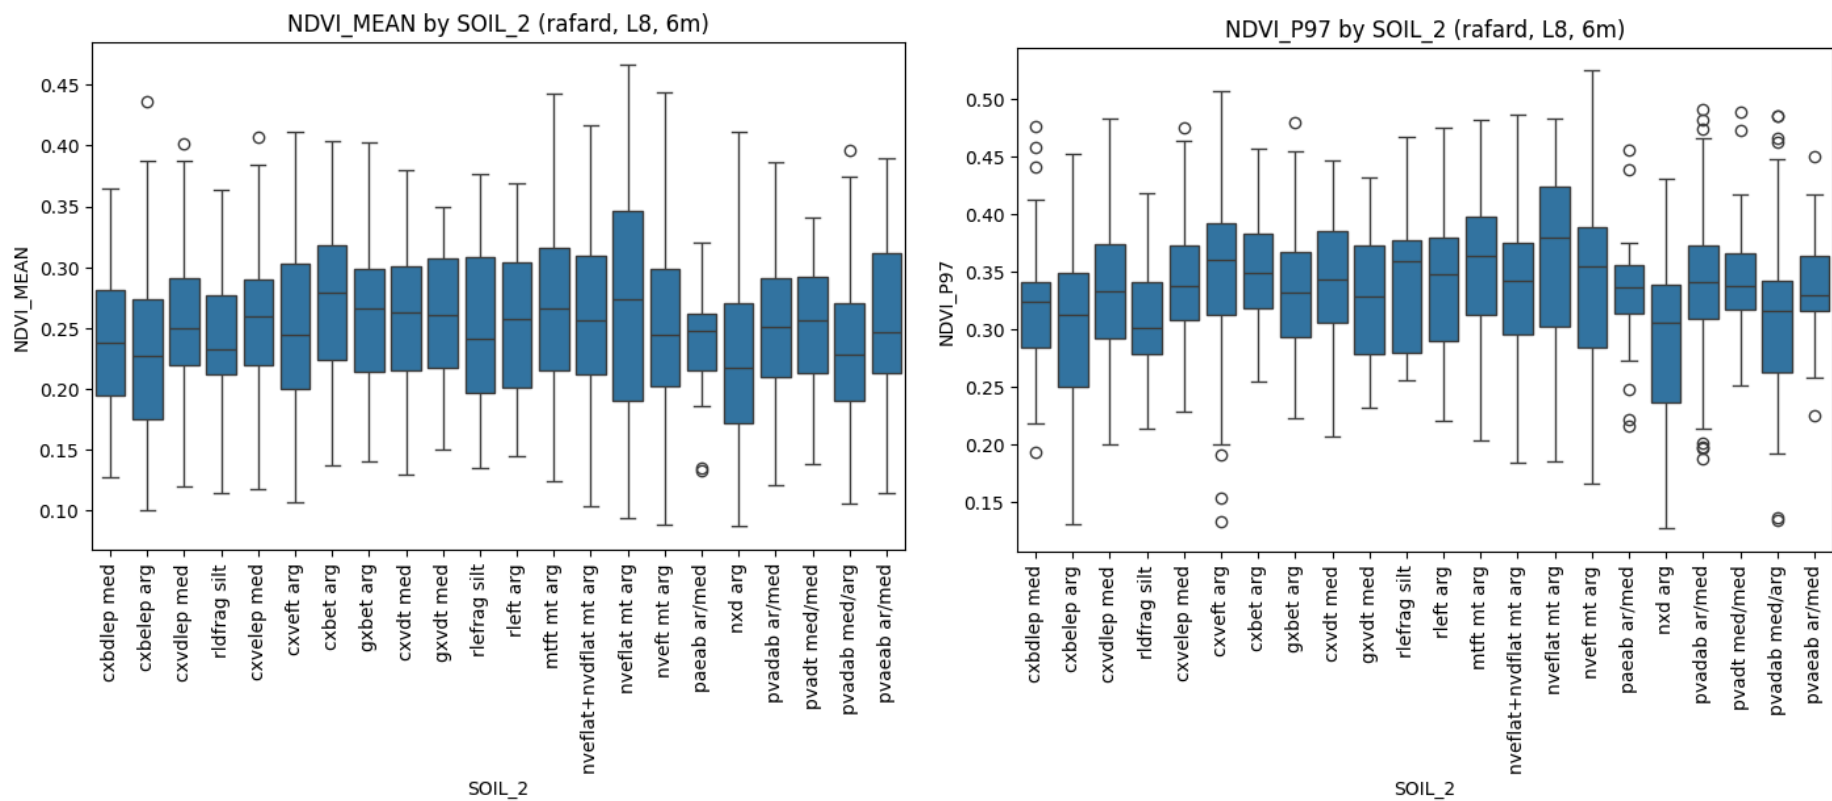


Figura 10: Boxplots comparando a influência da estatística descritiva (Média vs. Percentil 97) e da agregação temporal (6 meses) sobre os índices RVI (Sentinel-1) e NDVI (Landsat-8) na Fazenda Rafard. A figura mostra como diferentes escolhas de processamento afetam a separação entre as classes de solo no nível subordem. Os gráficos destacam que o Percentil 97 proporciona maior distinção entre solos, enquanto a Média apresenta maior sobreposição entre quartis. As diferenças observadas demonstram o impacto da seleção dos parâmetros no realce do efeito pedológico.

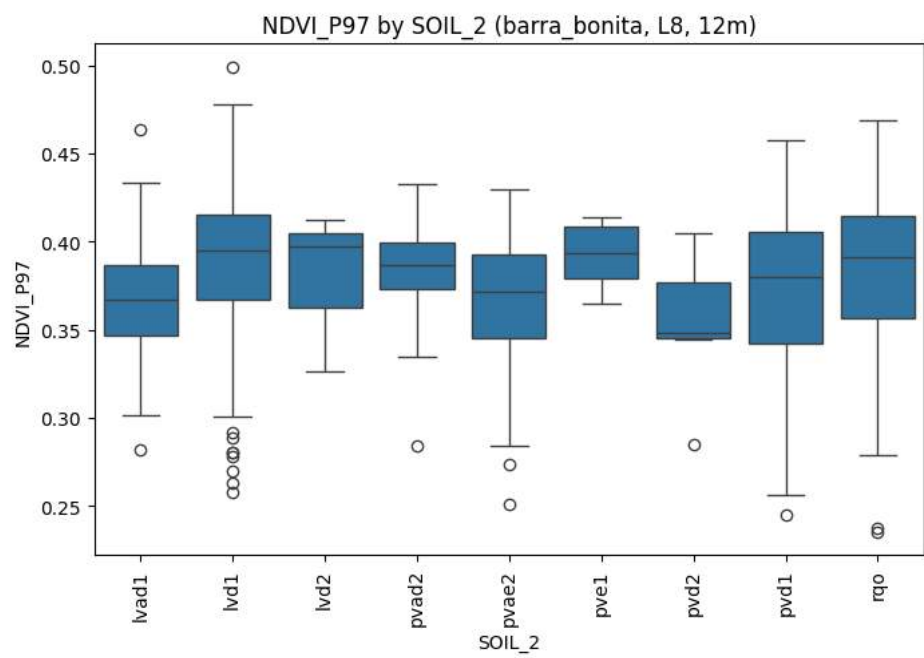
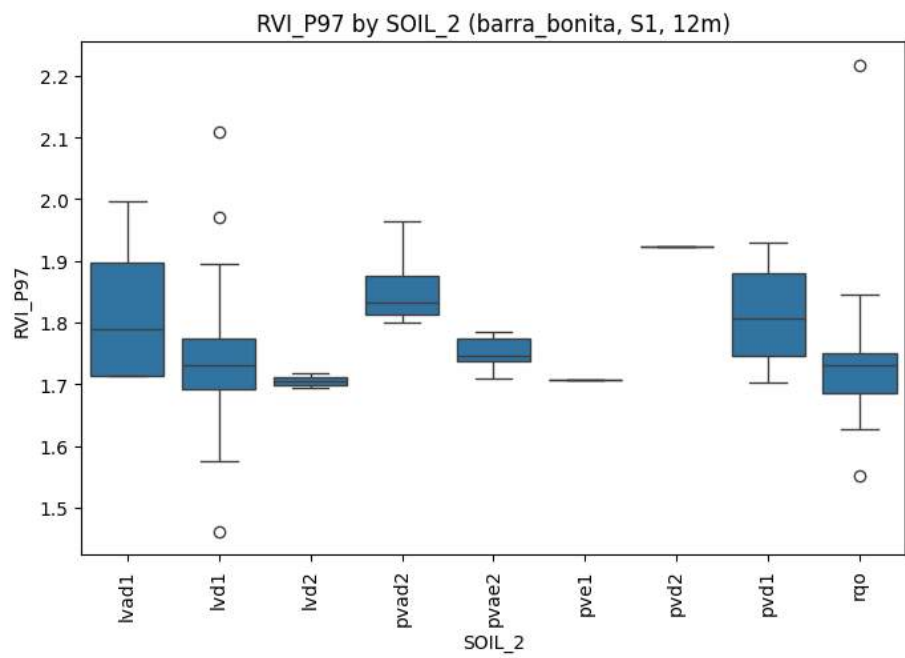
No RVI – Média vs. P97 (6 meses), o P97 isolou melhor o efeito do solo sobre o vigor máximo, enquanto a Média diluiu as diferenças pedológicas ao incluir momentos de baixo desenvolvimento vegetativo.

No NDVI – Média vs. P97 (6 meses), o mesmo padrão se repetiu: o P97 exibiu separação mais robusta, enquanto a Média apresentou maior dispersão e menor contraste entre as classes.

Os resultados confirmam que o RVI é o índice mais sensível para discriminar diferenças pedológicas entre as classes de solo, superando limitações de saturação frequentemente observadas em NDVI e LAI. Além disso, o uso do P97 mostrou desempenho superior à Média ao capturar o potencial máximo de desenvolvimento da cultura, evidenciando diferenças que permanecem encobertas em medidas mais agregadas. As janelas temporais longas, especialmente 12 meses, também contribuíram para reduzir ruídos fenológicos e organizar melhor os padrões espectrais. Esses achados estão em linha com a literatura, que destaca que solos de menor aptidão limitam a capacidade da cultura atingir seu vigor máximo, sobretudo em indicadores estruturais do dossel.

4.4. Análise boxplot - Barra Bonita

As Figuras 11 e 12 apresentam os boxplots selecionados para a fazenda Barra Bonita, seguindo o mesmo critério adotado para Rafard: preferência pela estatística P97, que captura o pico de vigor da cultura, e por agregações temporais mais longas, quando disponíveis. Foram escolhidos os índices que mostraram maior organização visual e melhor capacidade de distinguir padrões entre as classes de solo.



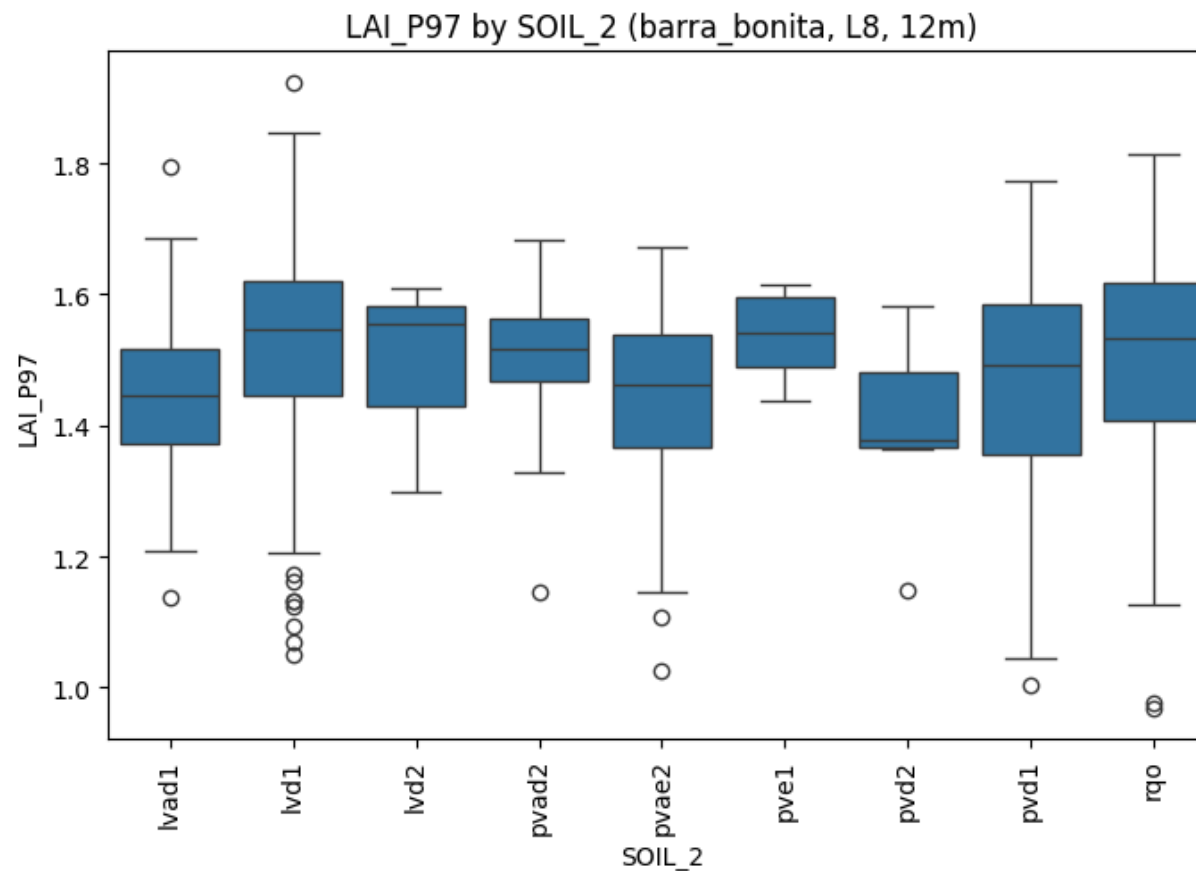
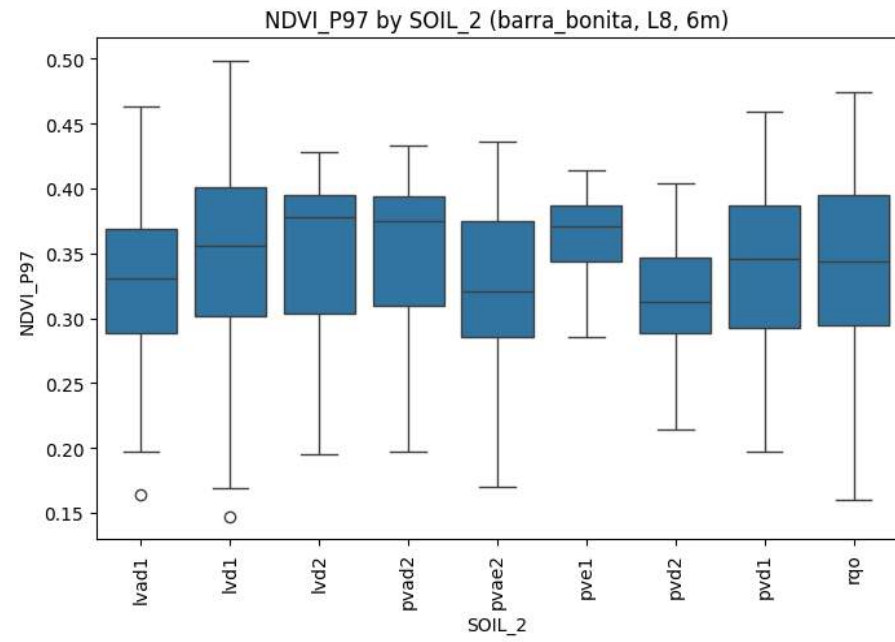
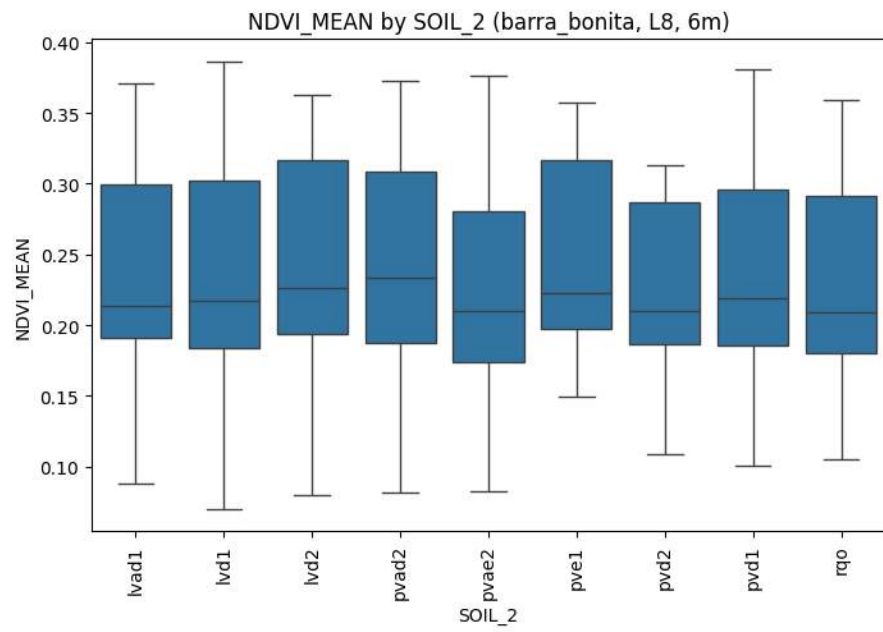


Figura 11 – Boxplots dos índices RVI, NDVI e LAI (estatística P97, agregação de 12 meses) para as classes de solo da Fazenda Barra Bonita. A figura apresenta a distribuição dos valores espectrais por classe de solo, permitindo comparar o comportamento do índice de radar (RVI), sensível à estrutura do dossel, e dos índices ópticos (NDVI e LAI), relacionados ao vigor fotossintético. Os boxplots evidenciam que, embora a separação entre as classes seja menos pronunciada que em Rafard, o RVI mantém maior capacidade discriminante em relação aos índices ópticos, destacando diferenças estruturais do dossel associadas à aptidão dos solos.

O NDVI (Landsat-8, P97, 12 meses) apresentou diferenças moderadas entre as classes, mas com maior dispersão do que em Rafard. Isso reforça a menor sensibilidade dos índices ópticos diante de dosséis densos e homogêneos, devido à saturação espectral no infravermelho próximo.

O LAI (P97, 12 meses) exibiu tendência semelhante: diferenças presentes, mas com sobreposição considerável entre as classes. Ainda assim, classes mais restritivas, geralmente associadas a menor profundidade ou drenagem, concentraram valores mais baixos de LAI.

O RVI (P97, 12 meses) manteve-se como o índice de maior estabilidade. Embora a separação entre as classes seja mais discreta em Barra Bonita, observa-se que classes associadas a melhor estrutura física do solo apresentam intervalos interquartílicos mais elevados. Isso reforça que o radar responde de maneira sensível a diferenças estruturais do dossel.



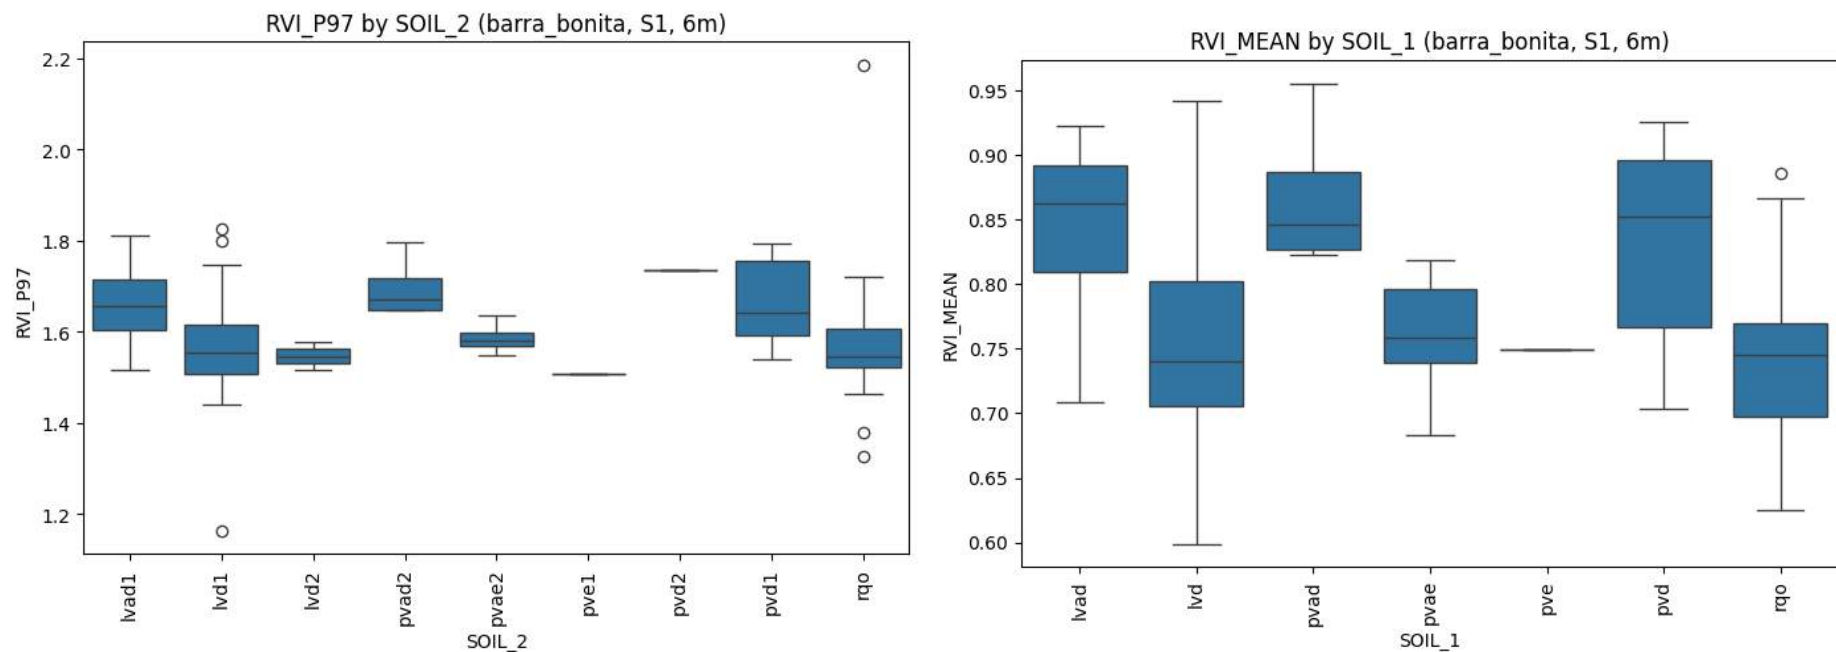


Figura 12 – Boxplots comparando a estatística Média e o Percentil 97 (P97) para os índices RVI e NDVI (agregação de 6 meses) na Fazenda Barra Bonita A figura mostra os efeitos das diferentes escolhas de estatística descritiva sobre a separação entre classes de solo. O P97, por representar o pico de vigor da cultura, apresenta maior contraste entre as classes quando comparado à Média, especialmente no índice RVI. Os resultados reforçam que estatísticas que capturam o máximo desenvolvimento da cultura são mais adequadas para evidenciar diferenças pedológicas em sistemas canavieiros.

RVI – Média vs. P97 (6 meses), o P97 destacou melhor as diferenças entre as classes, mesmo que com intensidade inferior à observada em Rafard.

No NDVI – Média vs. P97 (6 meses), o comportamento foi similar: o P97 revelou padrões mais estáveis, enquanto a Média apresentou maior dispersão e menor distinção entre as classes.

Os resultados obtidos em Barra Bonita confirmam tendências, ou seja, a tendência de que o RVI é o índice que melhor separa as classes de solo, observadas em Rafard, mas com menor intensidade, isto é, com diferenças menos evidentes entre as classes, como medianas mais próximas, intervalos interquartílicos mais curtos, maior sobreposição entre os boxplots e contrastes mais sutis. O RVI permanece como o índice mais robusto para discriminar diferenças entre classes de solo, embora com desempenho inferior ao registrado em Rafard. Essa menor separação pode estar relacionada a práticas de manejo mais homogêneas, à variabilidade pedológica naturalmente mais restrita na área ou a limitações no detalhamento do mapa pedológico disponível.

Ainda assim, a estatística Percentil 97 (P97) voltou a ser a mais adequada para captar diferenças pedológicas, reforçando que medidas baseadas no vigor máximo da cultura evidenciam padrões que se perdem quando se utilizam métricas mais agregadas. De forma semelhante, as janelas temporais longas reduziram ruídos fenológicos e organizaram melhor a resposta espectral.

Esses resultados sugerem que, embora os índices espectrais consigam refletir diferenças edáficas em Barra Bonita, o contraste entre as classes é menos pronunciado do que em Rafard, exigindo cautela interpretativa e reforçando a importância de integrar variáveis auxiliares em análises futuras.

4.5 Classificação supervisionada

A etapa de classificação supervisionada, realizada por meio do algoritmo Random Forest, trouxe evidências que confirmam apenas parcialmente a segunda hipótese do estudo. Quando o modelo foi aplicado às classes mais amplas de solo, correspondentes ao nível de Ordem no Sistema Brasileiro de Classificação de Solos (SiBCS), o desempenho foi consistentemente superior ao obtido para o nível mais detalhado de classificação, referente às Subordens.

Assim, a predição das Ordens apresentou resultados mais estáveis, enquanto a classificação das Subordens mostrou acurácia consideravelmente inferior.

Na fazenda Rafard, as melhores combinações associadas ao nível de ordem alcançaram acurácia máxima de aproximadamente 52,8%, especialmente para a combinação envolvendo o Landsat 8 com agregação temporal de 12 meses. Em Barra Bonita, o desempenho foi semelhante: as melhores combinações de Ordens atingiram valores próximos de 47,0%, novamente destacando o Landsat 8 (12 meses) e, em segundo plano, o Sentinel-2 também com agregação de 12 meses. De modo geral, os cenários com janelas temporais mais longas, 6 e 12 meses, concentraram as maiores acurácias, sugerindo que a integração temporal prolongada suaviza variações episódicas (como manejo e clima) e realça padrões médios associados ao solo.

Por outro lado, quando o modelo foi aplicado ao nível de subordem, a acurácia diminuiu de forma expressiva. Em Rafard, os valores oscilaram entre 13% e 18%, enquanto em Barra Bonita algumas combinações alcançaram no máximo cerca de 42%, com média geral próxima de 27%. O desempenho relativamente mais alto em Barra Bonita pode estar associado ao fato de algumas Subordens apresentarem comportamento espectral mais semelhante e agrupamentos mais homogêneos na área, o que reduz a complexidade da classificação. Mesmo nos melhores cenários, esses números mostram que as Subordens apresentam diferenças espectrais muito sutis, frequentemente insuficientes para serem distinguíveis apenas a partir das séries temporais de índices de vegetação.

Esse comportamento é amplamente relatado na literatura de mapeamento digital de solos: à medida que o número de classes aumenta, a dificuldade de separação também cresce, reduzindo naturalmente a acurácia global dos modelos. Em geral, a predição de unidades pedológicas mais específicas exige variáveis auxiliares, como atributos do relevo, derivados de modelos digitais de elevação, informações geofísicas ou dados espectrais em alta resolução, para complementar os índices de vegetação e melhorar a discriminação (DEMATTÊ et al., 2010; NANNI et al., 2022). No contexto deste trabalho, os resultados indicam que os índices ópticos e de radar capturam com consistência apenas os contrastes mais amplos entre Ordens, não sendo suficientes para discriminar Subordens de forma robusta.

Além disso, o fato de as melhores acurácias terem sido obtidas com agregações temporais de 6 e 12 meses reforça que períodos mais longos permitem integrar as fases fenológicas da cultura e diminuir ruídos associados a práticas pontuais de manejo. Ainda assim, mesmo com esse refinamento temporal, as acurácias permaneceram em níveis moderados, variando de cerca de 40% a pouco mais de 50%, o que evidencia que os índices espectrais são mais adequados para indicar tendências gerais de vigor e aptidão relativa do que para realizar classificações pedológicas detalhadas.

Tabela 4 : A tabela apresenta as cinco melhores combinações de satélite, intervalo temporal e nível de solo na classificação realizada com o modelo Random Forest, considerando o nível de agrupamento em ordem. A acurácia representa a proporção de amostras de solo corretamente previstas a partir das séries temporais de índices de vegetação para cada fazenda

Fazenda	Satélite	Intervalo	Solo	Acurácia
Rafard	Landsat 8	12	Ordem	52,8
Barra Bonita	Landsat 8	12	Ordem	47,0
Barra Bonita	Sentinel-2	12	Ordem	45,5
Rafard	Landsat 8	6	Ordem	45,1
Rafard	Sentinel-2	12	Ordem	44,5

Fonte: elaborado pela autora (2025)

Em síntese, os resultados confirmam que a classificação supervisionada é mais eficaz para distinguir Ordens de solo do que Subordens, e que a agregação temporal mais longa contribui para estabilizar o sinal espectral associado ao solo. Todavia, mesmo nas melhores condições, a capacidade de predição permanece moderada, reforçando a necessidade de integrar variáveis adicionais caso o objetivo seja alcançar detalhamento pedológico mais refinado.

5 CONCLUSÕES

Este trabalho investigou como diferentes classes de solo influenciam o desenvolvimento da cana-de-açúcar em duas fazendas localizadas em São Paulo, integrando mapas pedológicos, séries temporais de sensoriamento remoto (2019–2025), métodos estatísticos como ANOVA, Kruskal–Wallis, MANOVA e algoritmo de aprendizado de máquina Random Forest. Os resultados mostram que classes de solos distintas influenciam de forma diferente a

produtividade da cultura de cana-de-açúcar representada por índices espectrais derivados de imagens de satélite, especialmente nas séries temporais longas.

As análises univariadas apresentaram as evidências mais claras: 108 dos 156 cenários exibiram diferenças significativas entre classes de solo, com destaque para o RVI do Sentinel-1, cuja sensibilidade a parâmetros estruturais do dossel reforça sua capacidade de captar pequenos efeitos relacionados com a classe de solo. Os maiores valores de E_{ta}^2 ocorreram em janelas temporais de 6 e 12 meses, indicando que intervalos longos captam efeitos cumulativos do solo na cultura, enquanto intervalos curtos são mais suscetíveis a alterações provocadas pelo manejo e clima.

Os boxplots corroboram essa interpretação. Em Rafard, onde o mapa de solos é mais detalhado e a diversidade pedológica é maior, a separação entre subordens foi mais nítida, sobretudo no RVI. Em Barra Bonita, o padrão se repetiu, mas com menor intensidade, possivelmente devido à menor heterogeneidade pedológica e à escala mais geral do mapeamento. O P97 separou melhor os solos porque capta o máximo desenvolvimento da planta, enquanto a média suaviza ou atenua parte dessas diferenças.

A MANOVA não encontrou diferença significativa entre as classes, e isso faz sentido porque os índices espectrais são muito parecidos entre si (altamente correlacionados) e ainda sofrem influência de fatores externos, como manejo, micro relevo e microclima. Quando as variáveis estão muito correlacionadas e existe muita variação que não vem do solo, a MANOVA perde força estatística. Por isso, ela não funciona tão bem nesse tipo de dado. Mesmo assim, esse resultado não anula as análises feitas separadamente para cada índice; ele apenas mostra que métodos multivariados tradicionais podem não ser adequados aqui e que técnicas mais flexíveis ou não lineares podem capturar melhor essas diferenças

A classificação com Random Forest reforçou essa interpretação, a de que os índices, especialmente o RVI, conseguem diferenciar classes amplas de solo, mas têm dificuldade para separar níveis mais detalhados da classificação pedológica; ou seja, a interpretação de que os índices, especialmente o RVI, conseguem diferenciar classes amplas de solo, mas têm dificuldade para separar níveis mais detalhados da classificação pedológica. As ordens apresentaram acurácia moderada no valores de 52,8% em Rafard e 47,0% em Barra Bonita, enquanto as subordens exibiram desempenho inferior. Os índices mostram os contrastes

grandes entre solos, mas não chegam a separar detalhes mais finos sem dados extras. O modelo não identifica atributos do solo, mas sim expressões espectrais de processos condicionados por ele, como acúmulo de biomassa e padrões de umidade.

Rafard apresentou melhor separação devido à maior variabilidade pedológica e ao mapa de solos mais detalhado; Barra Bonita mostrou padrões semelhantes, porém menos pronunciados. Isso reforça que a qualidade, entendida aqui como o nível de detalhamento e precisão taxonômica das classes representadas na legenda do mapa, e a escala do dado pedológico (1:10.000 em Rafard e 1:50.000 em Barra Bonita) influenciam diretamente a quantidade de informação do mapa, permitindo distinguir zonas com diferente potencial produtivo..

A análise dos boxplots permitiu identificar os solos mais produtivos em cada área. Em Barra Bonita, destacaram-se Cambissolos eutróficos (cbelep.arg, cabet.arg, cxhvelep.med), seguidos por Nitossolos argilosos e muito argilosos (nveflt.mt.arg, nvflat+nvdtlat.mt.arg, nslftt.arg) e por Argissolos eutróficos. Neossolos litólicos e Gleissolos concentraram os menores valores. Em Rafard, o padrão foi ainda mais evidente: Cambissolos eutróficos e Nitossolos vermelhos argilosos apresentaram os maiores valores nos índices de vegetação calculados, incluindo NDVI, LAI, CIRE e RVI, os quais refletem vigor, biomassa e desenvolvimento do dossel da cultura. Por outro lado, Neossolos e Gleissolos apresentaram os menores valores, indicando menor desempenho produtivo nessas classes de solo.s.

Algumas limitações estão relacionadas com que as áreas possuem mapas pedológicos em escalas distintas; não foram incorporados atributos de relevo de alta resolução; ou seja, essas variáveis não foram incluídas nas análises do trabalho, embora pudessem ajudar a explicar parte da variabilidade observada; o Sentinel-1 foi utilizado sem filtros de speckle; e não houve validação com registros temporais de produtividade de cana medida a campo. Esses fatores ajudam a contextualizar os resultados e indicam caminhos claros para aprimoramento metodológico.

Em síntese, este estudo demonstra que a influência do solo no desenvolvimento da cana-de-açúcar se manifesta de forma clara quando analisada por meio de séries temporais amplas e índices estruturais sensíveis, especialmente o RVI. A principal contribuição consiste em mostrar que essa influência depende diretamente da escala do mapa de solos, da escolha

do índice e da duração da série temporal, oferecendo bases sólidas para diagnósticos agrícolas mais precisos e para o avanço das práticas de manejo em sistemas canavieiros.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ACORSI AMORIM, M. T. et al. Impact of soil types on sugarcane development monitored over time by remote sensing. *Precision Agriculture*, v. 23, p. 1532–1552, 2022. DOI: 10.1007/s11119-022-09896-1.

AGÊNCIA DAS BACIAS PCJ. Plano das Bacias Hidrográficas dos Rios Piracicaba, Capivari e Jundiaí 2010–2020. [S. l.]: Agência das Bacias PCJ, [s. d.].

AGÊNCIA DAS BACIAS PCJ. Relatório de situação dos recursos hídricos das Bacias PCJ 2013. [S. l.]: Agência das Bacias PCJ, 2013.

ALMEIDA, F. F. M. Fundamentos geológicos do relevo paulista. *Boletim do Instituto de Geografia*, v. 2, p. 1–28, 1964.

ATLAS BRASIL. Índice de Desenvolvimento Humano Municipal de Mineiros do Tietê. [S. l.]: Atlas Brasil, [s. d.]. Disponível em: <http://www.atlasbrasil.org.br/2010/perfil/mineiros-do-tiete-sp>. Acesso em: 10 jul. 2025.

BEN-DOR, E. et al. Imaging spectrometry for soil applications. *Advances in Agronomy*, v. 97, p. 321–392, 2008. DOI: 10.1016/S0065-2113(07)00008-9.

BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001.

CEPEA/CNA. PIB do Agronegócio Brasileiro. [S. l.]: CEPEA/CNA, [s. d.]. Disponível em: <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>. Acesso em: 25 jul. 2025.

CEPAGRI/UNICAMP. Dados estimados de temperatura e precipitação do Município de Rafard. [S. l.]: CEPAGRI/UNICAMP, [s. d.].

COPERNICUS. Sentinel-2: Level-2A reflectance data. *Google Earth Engine*, 2024. Disponível em: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED. Acesso em: 15 jul. 2025.

COHEN, J. Statistical power analysis for the behavioral sciences. 2. ed. Hillsdale: Lawrence Erlbaum Associates, 1988.

DEMATTE, J. A. M.; ARRUDA, G. P. Mapeamento digital de solos da região de Barra Bonita, SP, com uso de redes neurais artificiais. Relatório de pesquisa. Piracicaba: ESALQ/USP, [s. d.]. Não publicado.

DEMATTE, J. A. M. et al. Comparação entre mapas de solos obtidos por sensoriamento remoto espectral e pelo método convencional. *Pesquisa Agropecuária Brasileira*, v. 39, n. 12, p. 1219–1229, 2004.

DEMATTE, J. A. M. et al. Mapeamento da variabilidade espacial do solo por sensoriamento remoto em áreas agrícolas. *Revista Brasileira de Ciência do Solo*, v. 34, n. 4, p. 1109–1120, 2010. DOI: 10.1590/S0100-06832010000400008.

DEMATTE, J. A. M.; NANNI, M. Mapa de solos detalhado da região de Rafard, SP, por meio de sensoriamento remoto. 2000. (Mapa temático).

EMBRAPA. Sistema Brasileiro de Classificação de Solos. 3. ed. rev. e ampl. Brasília: Embrapa, 2013.

EMBRAPA. Sistema Brasileiro de Classificação de Solos. 5. ed. Rio de Janeiro: Embrapa Solos, 2018.

EMBRAPA. Sistema de Classificação de Köppen. [S. l.]: Embrapa, [s. d.].

ESA (European Space Agency). Sentinel-1: Ground Range Detected data. *Google Earth Engine*, 2024. Disponível em:

https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S1_GRD.

Acesso em: 18 jul. 2025.

FAO. World Reference Base for Soil Resources. Rome: FAO, 2015. Disponível em: <http://www.fao.org/3/i3794en/i3794en.pdf>. Acesso em: 20 ago. 2025.

GITELSON, A. A.; MERZLYAK, M. N. Remote estimation of chlorophyll content in leaves using red-edge spectral measurements. *Journal of Plant Physiology*, v. 143, n. 5, p. 568–578, 1994.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18–36, 2017. DOI: 10.1016/j.rse.2017.06.031.

IBGE. Malhas territoriais. Rio de Janeiro, 2024. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>. Acesso em: 05 ago. 2025.

IBGE. Manual técnico de geomorfologia. 3. ed. Rio de Janeiro: IBGE, 2019.

IBGE. Mineiros do Tietê (SP): Cidades e Estados. [S. l.]: IBGE, [s. d.]. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/sp/mineiros-do-tiete.html>. Acesso em: 22 jul. 2025.

INSTITUTO DE PESQUISAS TECNOLÓGICAS (IPT). Mapa Geológico do Estado de São Paulo. São Paulo: IPT, 1981. (Monografias, n. 5).

LEPSCH, I. F. Formação e conservação dos solos. São Paulo: Oficina de Textos, 2010.

LEPSCH, I. F. Solos: guia prático para o seu reconhecimento e classificação. São Paulo: Companhia Editora Nacional, 2013.

MANDAL, D. et al. Dual polarimetric Radar Vegetation Index for crop growth monitoring using Sentinel-1 SAR data. *Remote Sensing of Environment*, v. 247, art. 111954, 2020. DOI: 10.1016/j.rse.2020.111954.

MAPBIOMAS. Coleção 8 da série histórica de mapeamento da cobertura e uso do solo no Brasil. [S. l.]: MapBiomass, 2024. Disponível em: <https://mapbiomas.org>. Acesso em: 14 jul. 2025.

NANNI, M. R.; DEMATTÊ, J. A. M. Mapeamento de solos por sensoriamento remoto. *Revista Brasileira de Ciência do Solo*, v. 30, n. 4, p. 573–582, 2006.

NANNI, M. R. et al. Mapping soil classes and their properties using Sentinel-2 imagery and machine learning. *Computers and Electronics in Agriculture*, v. 195, p. 106821, 2022. DOI: 10.1016/j.compag.2022.106821.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

PÉREZ, D. V. et al. Solo, da origem da vida ao alicerce das civilizações: uso, manejo e gestão. *Pesquisa Agropecuária Brasileira*, v. 51, n. 9, p. i–iv, 2016. DOI: 10.1590/S0100-204X201600090000i.

PREFEITURA MUNICIPAL DE MINEIROS DO TIETÊ. Localização. [S. l.]: Prefeitura Municipal de Mineiros do Tietê, [s. d.]. Disponível em: <https://www.mineirosdotiete.sp.gov.br/pagina/2/localizacao>. Acesso em: 20 jul. 2025.

PREFEITURA MUNICIPAL DE RAFARD. Geografia do município. [S. l.]: Prefeitura Municipal de Rafard, [s. d.]. Disponível em: <https://rafard.sp.gov.br/a-cidade/geografia/>. Acesso em: 12 ago. 2025.

QGIS. QGIS Geographic Information System: versão 3.34.11. QGIS Association, 2024.

RODRIGUES, J. A. A trajetória da cana-de-açúcar no Brasil. SciELO Livros, 2020. Disponível em: <https://books.scielo.org/id/2hfey/pdf/rodrigues-9786558240112.pdf>. Acesso em: 29 ago. 2025.

RODRIGUES, L. F. Geomorfologia do Estado de São Paulo. São Paulo: USP, 2003.

ROSS, J. L. S. Geomorfologia: ambiente e planejamento. 6. ed. São Paulo: Contexto, 1992.

SEPLAN (São Paulo). Diagnóstico da Região Administrativa de Jaú. São Paulo: Secretaria de Planejamento e Meio Ambiente, 2012.

SEPLAN (São Paulo). Plano Diretor do Município de Mineiros do Tietê. São Paulo: Secretaria de Planejamento e Meio Ambiente, 2012.

SILVA DE ALMEIDA, G. et al. Monitoring soil–plant interactions and maize yield by satellite vegetation indexes, soil electrical conductivity and management zones. *Precision Agriculture*, v. 24, p. 1380–1400, 2023. DOI: 10.1007/s11119-023-10023-3.

SOUSA JUNIOR, J. G. A. Sensoriamento remoto e sistema de informações geográficas na caracterização de solos e quantificação de seus atributos. 2006. Dissertação (Mestrado) – ESALQ/USP, Piracicaba, 2006.

SOUSA JUNIOR, J. G. A. et al. Comportamento espectral dos solos na paisagem a partir de dados coletados por sensores terrestre e orbital. *Revista Brasileira de Ciência do Solo*, v. 32, n. 2, p. 727–738, 2008.

STANYER, C. et al. Soil texture, soil moisture, and Sentinel-1 backscattering: Towards the retrieval of field-scale soil hydrological properties. *Remote Sensing*, v. 17, n. 3, art. 542, 2025. DOI: 10.3390/rs17030542.

SZIGARSKI, C. et al. Analysis of the Radar Vegetation Index and potential improvements. *Remote Sensing*, v. 10, n. 11, art. 1776, 2018. DOI: 10.3390/rs10111776.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127–150, 1979.

TZIOLAS, N. et al. Earth observation data-driven cropland soil monitoring: A review. *Remote Sensing*, v. 13, n. 7, art. 1340, 2021. DOI: 10.3390/rs13071340.

UNICA. Boletins e dados de safra. [S. l.]: União da Indústria de Cana-de-Açúcar e Bioenergia, [s. d.]. Disponível em: <https://www.unica.com.br/>. Acesso em: 29 jul. 2025.

USGS (United States Geological Survey). Landsat 8: Surface reflectance data. *Google Earth Engine*, 2024. Disponível em: https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C02_T1_L2

[SR](#).

Acesso em: 16 ago. 2025.

VAMIER, R. L. et al. Plano da Bacia Hidrográfica dos Rios Piracicaba, Capivari e Jundiá. [S. l.]: Agência das Bacias PCJ, 2005.

WATSON, D. J. Comparative physiological studies on the growth of field crops: I. Variation in net assimilation rate and leaf-area index with season and level of nitrogen supply. *Annals of Botany*, v. 11, n. 42, p. 41–76, 1947.

WOODHOUSE, I. H. Introduction to microwave remote sensing. 2. ed. Boca Raton: CRC Press, 2017.

XU, Y. et al. A new approach for soil texture mapping using multi-temporal Sentinel-2 data and machine learning. *Remote Sensing*, v. 14, n. 1, p. 1–19, 2022. DOI: 10.3390/rs14010156.

ZHANG, Y.; XU, Y.; SHEN, H. Monitoring vegetation dynamics using dual-polarization SAR data: A review. *Remote Sensing of Environment*, v. 251, art. 112103, 2020. DOI: 10.1016/j.rse.2020.01.001.

ANEXOS

Anexo 1 : rf_summary.csv - **Resultados da Análise MANOVA (manova_summary)**

Tabela 02 – Resultados da Análise MANOVA (manova_summary)

Fazenda	Satélite	Intervalo	Solo	Acurácia
rafard	L8	12	12	12
rafard	L8	6	6	6
barrabonita	S2	12	12	12
rafard	S2	6	6	6
barrabonita	S2	3	3	3
rafard	L8	3	3	3
rafard	S2	12	12	12
rafard	S2	3	3	3

barrabonita	S2	12	12	12
barrabonita	L8	12	12	12
barrabonita	S2	6	6	6
barrabonita	S2	3	3	3
barrabonita	S1	3	3	3
barrabonita	S2	6	6	6
barrabonita	S1	12	12	12
barrabonita	L8	12	12	12
rafard	S1	3	3	3
barrabonita	S1	12	12	12
barrabonita	S1	6	6	6
rafard	S1	12	12	12
barrabonita	S1	3	3	3
rafard	S1	6	6	6
barrabonita	L8	6	6	6
barrabonita	S1	6	6	6
barrabonita	L8	3	3	3
barrabonita	L8	6	6	6
rafard	L8	12	12	12
rafard	L8	6	6	6
rafard	S2	12	12	12
rafard	S2	3	3	3
rafard	S1	12	12	12
rafard	L8	3	3	3

rafard	S2	6	6	6
rafard	S1	6	6	6
rafard	S1	3	3	3
barrabonita	L8	3	3	3

Anexo 2 - manova_summary.csv - Importância das Variáveis – Random Forest (rf_summar)

Tabela 3 – Importância das Variáveis – Random Forest (rf_summar)

Farm	satellite	interval_months	soil_column	pillai_p	significant
rafard	L8	3	SOIL_1	24745052897639.09	FALSE
rafard	L8	12	SOIL_1	20564381860140.25	FALSE
barrabonita	L8	12	SOIL_1	35.363.954.671.136. 400	FALSE
rafard	L8	6	SOIL_1	15.987.219.124.485. 900	FALSE
barrabonita	S2	3	SOIL_1	15.532.331.875.728. 900	FALSE
rafard	L8	6	SOIL_2	10.586.741.014.045. 000	FALSE
rafard	S2	3	SOIL_1	10.189.139.428.439. 000	FALSE

				6.282.923.587.301.4	
barrabonita	S2	3	SOIL_2	20	FALSE
				5.203.465.773.968.3	
rafard	L8	3	SOIL_2	70	FALSE
				3.057.433.555.590.7	
rafard	S2	3	SOIL_2	80	FALSE
				1.459.317.464.567.3	
barrabonita	S2	6	SOIL_1	60	FALSE
				1.380.117.561.719.5	
barrabonita	S2	6	SOIL_2	10	FALSE
				795.548.423.843.16	
rafard	L8	12	SOIL_2	5	FALSE
				527.365.936.843.47	
barrabonita	L8	6	SOIL_1	3	FALSE
				223.066.979.396.10	
barrabonita	L8	12	SOIL_2	1	FALSE
rafard	S2	6	SOIL_1	40.232.371.770.258	FALSE
rafard	S2	6	SOIL_2	3.864.954.860.985	FALSE
barrabonita	S2	12	SOIL_2	417.758.761	FALSE
barrabonita	S2	12	SOIL_1	417.154.611	FALSE
rafard	S2	12	SOIL_1	263.102.068	FALSE
rafard	S2	12	SOIL_2	25.613.554	FALSE
barrabonita	S1	12	SOIL_2	2.786.117	FALSE
barrabonita	S1	12	SOIL_1	2.772.159	FALSE
rafard	S1	12	SOIL_2	3.6591	FALSE
barrabonita	S1	6	SOIL_2	1.605.215	FALSE
barrabonita	S1	6	SOIL_1	1.600.662	FALSE
rafard	S1	3	SOIL_2	2.6041	FALSE

barrabonita	S1	3	SOIL_2	1.101.135	FALSE
barrabonita	S1	3	SOIL_1	1.099.008	FALSE
rafard	S1	12	SOIL_1	295.365	FALSE
rafard	S1	6	SOIL_1	275.283	FALSE
rafard	S1	6	SOIL_2	3.2099	FALSE
rafard	S1	3	SOIL_1	23.798	FALSE
barrabonita	L8	3	SOIL_1	6.939	FALSE
barrabonita	L8	3	SOIL_2	1.546	FALSE
barrabonita	L8	6	SOIL_2	26	TRU

Anexo 3 : statistical_summary.csv - Estatísticas Descritivas dos Índices de Vegetação (statistical_summary)

Tabela 3 – Estatísticas Descritivas dos Índices de Vegetação (statistical_summary)

farm	satellite	interv al_m onths	index	stat	soil_colu mn	anova _p	kruska l_p	levene _p	eta2	effect_ strengt h	signifi cant_ est	t_ _test	posthoc
rafard	S2	3	CIRE	ME AN	SOIL_1		0.0	0.0	267	small	al	Dunn	Krusk
rafard	S2	3	CIRE	ME AN	SOIL_N M		0.0	0.0	254	small	al	Dunn	Krusk
rafard	S2	3	CIRE	ME AN	SOIL_2		0.0	0.0	547	small	al	Dunn	Krusk
rafard	S2	3	CIRE	ME AN	SOLO		0.0	0.0	594	small	al	Dunn	Krusk

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significant_test	posthoc_test
rafard	S2	3	CIRE	P97	SOIL_1		0.0	0.0	0.04	small	Kruskal	Dunn
rafard	S2	3	CIRE	P97	SOIL_N M		0.0	0.0	339	small	Kruskal	Dunn
rafard	S2	3	CIRE	P97	SOIL_2		0.0	0.0	685	moderate	Kruskal	Dunn
rafard	S2	3	CIRE	P97	SOLO		0.0	0.0	721	moderate	Kruskal	Dunn
rafard	S2	3	NDVI	AN	ME SOIL_N M		0.0	0.0	14	small	Kruskal	Dunn
rafard	S2	3	NDVI	AN	ME SOIL_2		0.0	0.0	355	small	Kruskal	Dunn
rafard	S2	3	NDVI	AN	ME SOLO		0.0	0.0	419	small	Kruskal	Dunn
rafard	S2	3	LAI	AN	ME SOIL_N M		0.0	0.0	136	small	Kruskal	Dunn
rafard	S2	3	LAI	AN	ME SOIL_2		0.0	0.0	343	small	Kruskal	Dunn
rafard	S2	3	LAI	AN	ME SOLO		0.0	0.0	404	small	Kruskal	Dunn
rafard	S2	6	CIRE	AN	ME SOIL_1		0.0	0.0	337	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levener_p	eta2	effect_strength	significant_test	posthoc_test
rafard	S2	6	CIRE	AN	ME SOIL_N M	0.0	0.0	323	small	Kruskal	Dunn	
rafard	S2	6	CIRE	AN	ME SOIL_2	0.0	0.0	692	moderate	Kruskal	Dunn	
rafard	S2	6	CIRE	AN	ME SOLO	0.0	0.0	751	moderate	Kruskal	Dunn	
rafard	S2	6	CIRE	P97	SOIL_1	0.0	0.0	571	small	Kruskal	Dunn	
rafard	S2	6	CIRE	P97	ME SOIL_N M	0.0	0.0	454	small	Kruskal	Dunn	
rafard	S2	6	CIRE	P97	SOIL_2	0.0	0.0	105	moderate	Kruskal	Dunn	
rafard	S2	6	CIRE	P97	SOLO	0.0	0.0	1.109	moderate	Kruskal	Dunn	
rafard	S2	6	NDVI	P97	SOIL_2	0.0	0.0	1.165	moderate	Kruskal	Dunn	
rafard	S2	6	NDVI	P97	SOLO	0.0	0.0	0.13	moderate	Kruskal	Dunn	
rafard	S2	6	LAI	P97	SOIL_2	0.0	0.0	1.165	moderate	Kruskal	Dunn	
rafard	S2	6	LAI	P97	SOLO	0.0	0.0	0.13	moderate	Kruskal	Dunn	

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levens_p	eta2	effect_strength	significant_test	posthoc_test
rafard	S2	12	NDVI	ME AN	SOIL_1		1	0.0	404	small	Kruskal	Dunn
rafard	S2	12	NDVI	ME AN	SOIL_N M		1	0.0	428	small	Kruskal	Dunn
rafard	S2	12	LAI	ME AN	SOIL_1		2	0.0	391	small	Kruskal	Dunn
rafard	S2	12	LAI	ME AN	SOIL_N M		1	0.0	414	small	Kruskal	Dunn
rafard	L8	3	NDVI	ME AN	SOIL_1		2	0.0	98	negligible	Kruskal	Dunn
rafard	L8	3	NDVI	ME AN	SOIL_2		0.0	0.0	264	small	Kruskal	Dunn
rafard	L8	3	NDVI	ME AN	SOLO		0.0	0.0	302	small	Kruskal	Dunn
rafard	L8	3	LAI	ME AN	SOIL_1		2	0.0	98	negligible	Kruskal	Dunn
rafard	L8	3	LAI	ME AN	SOIL_2		0.0	0.0	264	small	Kruskal	Dunn
rafard	L8	3	LAI	ME AN	SOLO		0.0	0.0	302	small	Kruskal	Dunn
rafard	S2	12	LAI	ME AN	P97 SOIL_2		0.0	0.01	2.259	large	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significant_test	posthoc_test
rafard	L8	12	NDVI	ME AN	SOLO		0.0	0.96	1.413	large	Kruskal	Dunn
rafard	L8	12	LAI	ME AN	SOLO		0.0	0.96	1.413	large	Kruskal	Dunn
rafard	S2	3	NDVI	ME AN	SOIL_1		0.0	1	134	small	Kruskal	Dunn
rafard	L8	3	NDVI	ME AN	SOIL_N M		1	1	102	small	Kruskal	Dunn
rafard	L8	3	NDVI	P97	SOIL_1		0.0	1	145	small	Kruskal	Dunn
rafard	L8	3	NDVI	P97	SOIL_2		0.0	1	324	small	Kruskal	Dunn
rafard	L8	3	NDVI	P97	SOLO		0.0	1	371	small	Kruskal	Dunn
rafard	L8	3	LAI	ME AN	SOIL_N M		1	1	102	small	Kruskal	Dunn
rafard	L8	3	LAI	P97	SOIL_1		0.0	1	145	small	Kruskal	Dunn
rafard	L8	3	LAI	P97	SOIL_2		0.0	1	324	small	Kruskal	Dunn
rafard	L8	3	LAI	P97	SOLO		0.0	1	371	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levens_p	eta2	effect_strength	significant_test	posthoc_test
rafard	L8	6	NDVI	ME AN	SOIL_1		198	1	125	small	Kruskal	Dunn
rafard	L8	6	LAI	ME AN	SOIL_1		198	1	125	small	Kruskal	Dunn
rafard	L8	6	NDVI	P97	SOIL_N M		0.0	1.068	19	small	Kruskal	Dunn
rafard	L8	6	LAI	P97	SOIL_N M		0.0	1.068	19	small	Kruskal	Dunn
barra	bonita_L8	3	NDVI	P97	SOIL_2		1.504	1.072	49	negligible		Dunn
barra	bonita_L8	3	LAI	P97	SOIL_2		1.504	1.072	49	negligible		Dunn
barra	bonita_S2	12	CIRE	P97	SOIL_T AXON		61	1.083	368	small		Dunn
barra	bonita_S2	6	NDVI	P97	SOIL_T AXON		92	1.107	183	small		Dunn
barra	bonita_S2	6	LAI	P97	SOIL_T AXON		92	1.107	183	small		Dunn
rafard	S2	12	CIRE	P97	SOLO		0.0	1.157	2.069	large	Kruskal	Dunn
rafard	L8	3	STB10	ME AN	SOIL_1		179	1.288	56	negligible	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	12	LAI	P97	SOIL_T AXON		635	1.452	325	small		Dunn
barra	bonita_S2	12	NDVI	P97	SOIL_T AXON		635	1.454	325	small		Dunn
rafard	L8	12	STB10	P97	SOIL_N M		11	1.455	307	small	al	Dunn
rafard	L8	6	NDVI	P97	SOLO		0.0	1.636	822	moderate	al	Dunn
rafard	L8	6	LAI	P97	SOLO		0.0	1.636	822	moderate	al	Dunn
barra	bonita_L8	12	NDVI	P97	SOIL_1		12	1.656	457	small	al	Dunn
barra	bonita_L8	12	LAI	P97	SOIL_1		12	1.656	457	small	al	Dunn
barra	bonita_L8	12	NDVI	P97	SOIL_2		28	1.666	476	small	al	Dunn
barra	bonita_L8	12	LAI	P97	SOIL_2		28	1.666	476	small	al	Dunn
rafard	S1	6	RVI	P97	SOIL_1		138	1.698	141	large	al	Dunn
barra	bonita_L8	6	NDVI	P97	SOIL_1		94	1.897	18	small	al	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levens_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_L8	6	LAI	P97	SOIL_1		94	1.897	18	small	Kruskal	Dunn
rafard	S2	3	NDVI	P97	SOIL_1		0.0	1.912	26	small	Kruskal	Dunn
rafard	S2	3	LAI	P97	SOIL_1		0.0	1.912	26	small	Kruskal	Dunn
rafard	S2	12	NDVI	P97	SOIL_N M		0.0	1.974	944	moderate	Kruskal	Dunn
rafard	S2	3	LAI	ME AN	SOIL_1		0.0	2	13	small	Kruskal	Dunn
rafard	L8	6	NDVI	ME AN	SOIL_2		17	2	384	small	Kruskal	Dunn
rafard	L8	6	NDVI	ME AN	SOLO		19	2	45	small	Kruskal	Dunn
rafard	L8	6	LAI	ME AN	SOIL_2		17	2	384	small	Kruskal	Dunn
rafard	L8	6	LAI	ME AN	SOLO		19	2	45	small	Kruskal	Dunn
barra	bonita_S2	3	CIRE	ME AN	SOIL_T AXON		3.066	2.004	53	negligible		Dunn
barra	bonita_S2	3	NDVI	P97	SOIL_2		866	2.091	56	negligible		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	3	LAI	P97	SOIL_2		866	2.091	56	negligible		Dunn
barra	bonita_S2	3	CIRE	P97	SOIL_T AXON		1.254	2.157	77	negligible		Dunn
rafard	S2	6	NDVI	P97	SOIL_1		0.0	2.183	492	small	Kruskal	Dunn
rafard	S2	6	LAI	P97	SOIL_1		0.0	2.183	492	small	Kruskal	Dunn
barra	bonita_S2	3	NDVI	P97	SOIL_1		952	2.335	43	negligible		Dunn
barra	bonita_S2	3	LAI	P97	SOIL_1		952	2.335	43	negligible		Dunn
rafard	S1	12	RVI	P97	SOIL_1		2.063	2.364	832	moderate		Dunn
rafard	S1	6	RVI	P97	SOIL_N M		19	2.399	1.875	large	Kruskal	Dunn
barra	bonita_L8	12	STB10	AN	ME SOIL_1		18	2.455	356	small	Kruskal	Dunn
rafard	L8	3	STB10	AN	ME SOLO		859	2.637	16	small		Dunn
barra	bonita_L8	6	NDVI	P97	SOIL_2		184	2.915	192	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significant_test	posthoc_test
barra	bonita_L8	6	LAI	P97	SOIL_2		184	2.915	192	small	Kruskal	Dunn
barra	bonita_S2	3	CIRE	AN	SOIL_1	ME	1.625	2.931	56	negligible		Dunn
rafard	S2	3	NDVI	P97	SOIL_N M		0.0	3.093	235	small	Kruskal	Dunn
rafard	S2	3	LAI	P97	SOIL_N M		0.0	3.093	235	small	Kruskal	Dunn
rafard	L8	6	NDVI	P97	SOIL_2		0.0	3.139	702	moderate	Kruskal	Dunn
rafard	L8	6	LAI	P97	SOIL_2		0.0	3.139	702	moderate	Kruskal	Dunn
barra	bonita_L8	6	STB10	AN	SOIL_1	ME	307	3.493	143	small	Kruskal	Dunn
rafard	S1	3	RVI	AN	SOIL_1	ME	1.004	3.614	753	moderate		Dunn
barra	bonita_S2	6	NDVI	P97	SOIL_2		302	3.658	177	small	Kruskal	Dunn
barra	bonita_S2	6	LAI	P97	SOIL_2		302	3.658	177	small	Kruskal	Dunn
barra	bonita_S2	6	CIRE	P97	SOIL_1		73	3.719	204	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
rafard	L8	12	STB10	AN	SOIL_1		0.0	3.778	273	small	Kruskal	Dunn
barra	bonita_L8	6	STB10	P97	SOIL_T AXON		8.092	3.794	51	negligible		Dunn
rafard	S1	3	RVI	AN	ME SOIL_N M	511		3.797	927	moderate		
barra	bonita_L8	12	STB10	P97	SOIL_T AXON		1	3.831	763	moderate	Kruskal	Dunn
rafard	L8	3	STB10	AN	ME SOIL_2		2.015	3.918	112	small		Dunn
barra	bonita_L8	12	NDVI	P97	SOIL_T AXON		46	4.088	459	small	Kruskal	Dunn
barra	bonita_L8	12	LAI	P97	SOIL_T AXON		46	4.088	459	small	Kruskal	Dunn
rafard	S2	6	NDVI	P97	SOIL_N M		0.0	4.182	403	small	Kruskal	Dunn
rafard	S2	6	LAI	P97	SOIL_N M		0.0	4.182	403	small	Kruskal	Dunn
rafard	S1	12	RVI	AN	ME SOIL_2		84	4.238	3.987	large	Kruskal	Dunn
rafard	L8	12	NDVI	P97	SOIL_1		0.0	4.296	508	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significant_test	posthoc_test
rafard	L8	12	LAI	P97	SOIL_1		0.0	4.296	508	small	Kruskal	Dunn
barra	bonita_S2	6	NDVI	P97	SOIL_1		226	4.505	149	small	Kruskal	Dunn
barra	bonita_S2	6	LAI	P97	SOIL_1		226	4.505	149	small	Kruskal	Dunn
barra	bonita_S2	6	CIRE	P97	SOIL_2		157	4.541	222	small	Kruskal	Dunn
barra	bonita_L8	12	STB10	P97	SOIL_1		9	4.545	477	small	Kruskal	Dunn
barra	bonita_S1	12	RVI	ME AN	SOIL_2		326	4.558	2.173	large	Kruskal	Dunn
rafard	S1	12	RVI	P97	SOIL_N M		1.224	4.632	119	moderate		Dunn
barra	bonita_S2	12	CIRE	P97	SOIL_1		72	4.634	424	small	Kruskal	Dunn
rafard	S1	6	RVI	ME AN	SOIL_2		114	4.863	4.056	large	Kruskal	Dunn
barra	bonita_S2	3	NDVI	ME AN	SOIL_T AXON		6.585	4.887	33	negligible		Dunn
rafard	S2	6	NDVI	ME AN	SOLO		0.0	5	619	moderate	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
				ME						moderate	Kruskal	
rafard	S2	12	LAI	AN	SOIL_2		0.0	5	1.076			Dunn
				ME	SOIL_N						Kruskal	
rafard	L8	6	NDVI	AN	M		91	5	138	small		Dunn
				ME	SOIL_N						Kruskal	
rafard	L8	6	LAI	AN	M		91	5	138	small		Dunn
	bonita			ME							Kruskal	
barra	_S1	12	RVI	AN	SOIL_1		18	5.035	2.073	large		Dunn
	bonita										Kruskal	
barra	_S2	12	CIRE	P97	SOIL_2		108	5.043	47	small		Dunn
				ME	SOIL_N					moderate		
rafard	S1	12	RVI	AN	M		3.463	5.061	672			Dunn
	bonita				SOIL_T					negligible		
barra	_L8	3	NDVI	P97	AXON		2.685	5.091	5			Dunn
	bonita				SOIL_T					negligible		
barra	_L8	3	LAI	P97	AXON		2.685	5.091	5			Dunn
										moderate		
rafard	S1	3	RVI	P97	SOIL_1		548	5.215	101			Dunn
					SOIL_N						Kruskal	
rafard	L8	12	NDVI	P97	M		0.0	5.471	479	small		Dunn
					SOIL_N						Kruskal	
rafard	L8	12	LAI	P97	M		0.0	5.471	479	small		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significant_test	posthoc_test
rafard	S1	3	RVI	P97	SOLO		485	5.533	3.952	large	Kruskal	Dunn
rafard	L8	6	STB10	P97	SOIL_1		3	5.633	14	small	Kruskal	Dunn
rafard	L8	12	STB10	P97	SOIL_1		91	5.695	204	small	Kruskal	Dunn
barra	bonita_S1	6	RVI	P97	SOIL_1		196	5.716	1.108	moderate	Kruskal	Dunn
rafard	L8	6	STB10	ME AN	SOIL_2		124	5.774	312	small	Kruskal	Dunn
barra	bonita_L8	12	NDVI	ME AN	SOIL_2		2.848	5.794	163	small		Dunn
barra	bonita_L8	12	LAI	ME AN	SOIL_2		2.848	5.794	163	small		Dunn
barra	bonita_S1	12	RVI	P97	SOIL_1		443	5.822	1.034	moderate	Kruskal	Dunn
barra	bonita_L8	3	STB10	P97	SOIL_1		2.899	5.823	42	negligible		Dunn
barra	bonita_S1	12	RVI	P97	SOIL_2		87	5.835	1.165	moderate		Dunn
barra	bonita_S1	6	RVI	P97	SOIL_2		383	5.887	1.149	moderate	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	3	LAI	ME AN	SOIL_T AXON		7.156	6.012	3	negligible		Dunn
barra	bonita_S2	6	CIRE	ME AN	SOIL_2		2.468	6.022	119	small		Dunn
barra	bonita_L8	6	STB10	P97	SOIL_1		3.797	6.143	7	negligible		Dunn
rafard	L8	6	STB10	P97	SOIL_2		0.0	6.187	385	small	Kruskal	Dunn
rafard	L8	6	STB10	ME AN	SOIL_1		35	6.285	131	small	Kruskal	Dunn
rafard	S1	12	RVI	P97	SOIL_2		1.832	6.314	3.212	large		Dunn
barra	bonita_L8	3	NDVI	ME AN	SOIL_1		3.223	6.359	38	negligible		Dunn
barra	bonita_L8	3	LAI	ME AN	SOIL_1		3.223	6.359	38	negligible		Dunn
barra	bonita_L8	3	NDVI	ME AN	SOIL_2		4.884	6.469	41	negligible		Dunn
barra	bonita_L8	3	LAI	ME AN	SOIL_2		4.884	6.469	41	negligible		Dunn
barra	bonita_L8	12	STB10	ME AN	SOIL_2		1	6.506	613	moderate	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	12	LAI	P97	SOIL_1		59	6.517	379	small	Kruskal	Dunn
barra	bonita_S2	12	NDVI	P97	SOIL_1		6	6.519	379	small	Kruskal	Dunn
barra	bonita_S1	6	RVI	AN	SOIL_2	ME	557	6.826	2.037	large		Dunn
barra	bonita_L8	6	STB10	P97	SOIL_2		3.072	6.933	102	small		Dunn
rafard	bonita_S2	12	CIRE	AN	SOIL_2	ME	0.0	6.968	178	large	Kruskal	Dunn
barra	bonita_L8	12	STB10	P97	SOIL_2		4	6.974	618	moderate	Kruskal	Dunn
rafard	bonita_S2	12	NDVI	AN	SOIL_2	ME	0.0	7	1.114	moderate	Kruskal	Dunn
rafard	bonita_S1	6	RVI	AN	SOIL_1	ME	19	7.096	1.623	large	Kruskal	Dunn
rafard	bonita_S1	6	RVI	P97	SOLO		27	7.118	4.078	large	Kruskal	Dunn
barra	bonita_L8	3	NDVI	AN	AXON	ME	SOIL_T	7.223	7.182	27	negligible	Dunn
barra	bonita_L8	3	LAI	AN	AXON	ME	SOIL_T	7.223	7.182	27	negligible	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S1	3	RVI	ME AN	SOIL_T AXON		2.885	7.192	1.318	moderate		Dunn
barra	bonita_S2	6	CIRE	ME AN	SOIL_1		209	7.219	88	negligible		Dunn
rafard	S1	3	RVI	P97	SOIL_2		2.345	7.302	3.078	large		Dunn
rafard	S1	3	RVI	ME AN	SOLO		712	7.388	3.336	large		Dunn
barra	bonita_L8	6	STB10	ME AN	SOIL_T AXON		42	7.427	175	small	Kruskal	Dunn
barra	bonita_L8	3	STB10	P97	SOIL_T AXON		7.113	7.472	31	negligible		Dunn
rafard	S1	12	RVI	ME AN	SOLO		57	7.473	4.955	large	Kruskal	Dunn
barra	bonita_S1	6	RVI	ME AN	SOIL_1		341	7.479	1.956	large	Kruskal	Dunn
rafard	L8	12	NDVI	P97	SOLO		0.0	7.568	0.15	large	Kruskal	Dunn
rafard	L8	12	LAI	P97	SOLO		0.0	7.568	0.15	large	Kruskal	Dunn
barra	bonita_S2	12	LAI	ME AN	SOIL_T AXON		5.951	7.578	133	small		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	12	NDVI	AN	ME SOIL_T AXON		5.297	7.584	145	small		Dunn
rafard	L8	6	STB10	P97	ME SOIL_N M		0.0	7.627	193	small	Kruskal	Dunn
rafard	S1	6	RVI	AN	ME SOLO		4	7.676	5.382	large	Kruskal	Dunn
barra	bonita_L8	3	STB10	P97	ME SOIL_2		78	7.676	75	negligible		Dunn
rafard	L8	12	STB10	AN	ME SOIL_N M		0.0	7.684	333	small	Kruskal	Dunn
barra	bonita_S2	6	LAI	AN	ME SOIL_1		5.254	7.705	4	negligible		Dunn
barra	bonita_S2	3	LAI	AN	ME SOIL_2		8.529	7.944	31	negligible		Dunn
barra	bonita_S2	6	LAI	AN	ME SOIL_T AXON		3.684	7.959	58	negligible		Dunn
rafard	S2	12	CIRE	AN	ME SOLO	0.0		8.007	1.934	large	ANOVA	Tukey
barra	bonita_S2	12	CIRE	AN	ME SOIL_T AXON		1.838	8.007	227	small		Dunn
barra	bonita_S2	3	NDVI	AN	ME SOIL_2		827	8.037	33	negligible		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	6	NDVI	ME AN	SOIL_T AXON		3.366	8.044	63	negligible		Dunn
barra	bonita_S2	6	NDVI	ME AN	SOIL_1		515	8.065	42	negligible		Dunn
barra	bonita_S2	12	LAI	P97	SOIL_2		79	8.074	413	small	Kruskal	Dunn
barra	bonita_S2	12	NDVI	P97	SOIL_2		8	8.076	413	small	Kruskal	Dunn
barra	bonita_L8	6	NDVI	P97	SOIL_T AXON		248	8.081	202	small	Kruskal	Dunn
barra	bonita_L8	6	LAI	P97	SOIL_T AXON		248	8.081	202	small	Kruskal	Dunn
rafard	L8	12	NDVI	ME AN	SOIL_1	0.0		8.253	414	small	ANOVA	Tukey
rafard	L8	12	LAI	ME AN	SOIL_1	0.0		8.253	414	small	ANOVA	Tukey
barra	bonita_L8	12	NDVI	ME AN	SOIL_1		191	8.271	155	small		Dunn
barra	bonita_L8	12	LAI	ME AN	SOIL_1		191	8.271	155	small		Dunn
rafard	S1	3	RVI	P97	SOIL_N M		129	8.334	1.297	moderate	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	12	CIRE	AN	SOIL_2		81	8.334	301	small		Dunn
rafard	S2	12	CIRE	AN	SOIL_1		0.0	8.623	86	moderate	Kruskal	Dunn
rafard	S1	12	RVI	P97	SOLO		338	8.669	4.055	large	Kruskal	Dunn
rafard	L8	6	STB10	AN	SOIL_NM		8	8.711	157	small	Kruskal	Dunn
barra	bonita_S2	6	CIRE	AN	SOIL_TAXON		2.883	8.938	9	negligible		Dunn
barra	bonita_S2	6	LAI	AN	SOIL_2		5.002	8.977	57	negligible		Dunn
rafard	S2	6	LAI	AN	SOLO		0.0	9	61	moderate	Kruskal	Dunn
rafard	S1	3	RVI	AN	SOIL_2		3.678	9.027	2.594	large		Dunn
rafard	L8	12	STB10	AN	SOLO		0.0	9.125	1.068	moderate	Kruskal	Dunn
barra	bonita_S2	6	NDVI	AN	SOIL_2		4.848	9.156	61	negligible		Dunn
barra	bonita_S2	12	CIRE	AN	SOIL_1		1.002	9.164	221	small		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_L8	3	STB10	AN	ME SOIL_1		326	9.239	62	negligible	Kruskal	Dunn
barra	bonita_S2	12	LAI	AN	ME SOIL_1		6.779	9.268	9	negligible		Dunn
barra	bonita_S2	12	NDVI	AN	ME SOIL_2		5.193	9.331	141	small		Dunn
barra	bonita_S2	12	NDVI	AN	ME SOIL_1		6.305	9.338	96	negligible		Dunn
rafard	bonita_L8	12	STB10	AN	ME SOIL_2		1	9.371	662	moderate	Kruskal	Dunn
barra	bonita_S2	12	LAI	AN	ME SOIL_2		5.736	9.378	13	small		Dunn
barra	bonita_L8	6	NDVI	AN	ME SOIL_1		442	9.382	61	negligible		Dunn
barra	bonita_L8	6	LAI	AN	ME SOIL_1		442	9.382	61	negligible		Dunn
barra	bonita_S1	12	RVI	AN	ME SOIL_T AXON		58	9.415	3.575	large	Kruskal	Dunn
rafard	bonita_S2	12	CIRE	AN	ME SOIL_N M		0.0	9.477	825	moderate	Kruskal	Dunn
barra	bonita_S2	3	NDVI	AN	ME SOIL_1		7.373	9.489	22	negligible		Dunn

farm	satellite	interval_months	index	stat	soil_colmn	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S2	3	LAI	ME AN	SOIL_1		7.625	9.501	21	negligible		Dunn
barra	bonita_L8	6	NDVI	ME AN	SOIL_2		6.071	9.538	64	negligible		Dunn
barra	bonita_L8	6	LAI	ME AN	SOIL_2		6.071	9.538	64	negligible		Dunn
barra	bonita_S2	6	CIRE	ME AN	SOIL_T AXON	P97	769	9.608	173	small		Dunn
barra	bonita_L8	6	NDVI	ME AN	SOIL_T AXON		749	9.652	48	negligible		Dunn
barra	bonita_L8	6	LAI	ME AN	SOIL_T AXON		749	9.652	48	negligible		Dunn
barra	bonita_S1	6	RVI	ME AN	SOIL_T AXON		49	9.728	3.036	large	Kruskal	Dunn
barra	bonita_L8	3	STB10	ME AN	SOIL_2		49	9.866	101	small	Kruskal	Dunn
rafard	bonita_L8	12	NDVI	ME AN	SOIL_2	0.0		9.937	1.198	moderate	ANOVA	Tukey
rafard	bonita_L8	12	LAI	ME AN	SOIL_2	0.0		9.937	1.198	moderate	ANOVA	Tukey
barra	bonita_S1	12	RVI	ME AN	SOIL_T AXON	P97	136	9.942	2.992	large	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levens_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S1	6	RVI	P97	SOIL_T AXON		56	9.947	2.176	large	Kruskal	Dunn
rafard	L8	3	NDVI	P97	SOIL_N M		0.0	11	144	small	Kruskal	Dunn
rafard	L8	3	LAI	P97	SOIL_N M		0.0	11	144	small	Kruskal	Dunn
barra	bonita_S2	3	CIRE	P97	SOIL_2		331	16	102	small	Kruskal	Dunn
rafard	S2	12	CIRE	P97	SOIL_1		0.0	23	1.255	moderate	Kruskal	Dunn
rafard	S2	12	CIRE	P97	SOIL_N M		0.0	23	1.018	moderate	Kruskal	Dunn
rafard	S2	12	LAI	ME AN	SOLO		0.0	25	1.281	moderate	Kruskal	Dunn
rafard	S2	12	NDVI	ME AN	SOLO		0.0	37	1.328	moderate	Kruskal	Dunn
rafard	L8	3	STB10	P97	SOIL_2		819	48	119	small		Dunn
rafard	L8	3	STB10	P97	SOIL_1		9	63	51	negligible	Kruskal	Dunn
rafard	S2	6	NDVI	ME AN	SOIL_2		0.0	64	52	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
rafard	L8	12	STB10	P97	SOLO		27	64	806	moderate	Kruskal	Dunn
rafard	S2	3	NDVI	P97	SOIL_2		0.0	69	516	small	Kruskal	Dunn
rafard	S2	3	LAI	P97	SOIL_2		0.0	69	516	small	Kruskal	Dunn
rafard	L8	3	STB10	P97	SOLO		176	95	182	small	Kruskal	Dunn
rafard	S2	12	NDVI	P97	SOIL_2		0.0	102	226	large	Kruskal	Dunn
rafard	S2	6	LAI	ME AN	SOIL_2		0.0	124	512	small	Kruskal	Dunn
barra	bonita_S2	3	CIRE	P97	SOIL_1		217	135	9	negligible	Kruskal	Dunn
barra	bonita_L8	12	NDVI	ME AN	SOIL_T AXON		4.816	162	113	small		Dunn
barra	bonita_L8	12	LAI	ME AN	SOIL_T AXON		4.816	162	113	small		Dunn
rafard	S2	6	NDVI	ME AN	SOIL_N M		1	174	203	small	Kruskal	Dunn
rafard	S2	12	LAI	P97	SOLO		0.0	175	237	large	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
rafard	S2	12	NDVI	P97	SOLO		0.0	177	2.371	large	Kruskal	Dunn
barra	bonita_S2	3	NDVI	P97	SOIL_T AXON		1.686	184	59	negligible	Kruskal	Dunn
barra	bonita_S2	3	LAI	P97	SOIL_T AXON		1.686	184	59	negligible	Kruskal	Dunn
rafard	S2	12	LAI	P97	SOIL_N M		0.0	198	943	moderate	Kruskal	Dunn
rafard	L8	3	STB10	P97	SOIL_N M		39	232	63	negligible	Kruskal	Dunn
barra	bonita_L8	6	STB10	ME AN	SOIL_2		4	276	233	small	Kruskal	Dunn
rafard	L8	12	STB10	P97	SOIL_2		277	283	51	small	Kruskal	Dunn
rafard	L8	6	STB10	P97	SOLO		0.0	306	553	small	Kruskal	Dunn
rafard	S2	6	LAI	ME AN	SOIL_N M		1	309	0.02	small	Kruskal	Dunn
rafard	S2	3	NDVI	P97	SOLO		0.0	346	588	small	Kruskal	Dunn
rafard	S2	3	LAI	P97	SOLO		0.0	346	588	small	Kruskal	Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significant_test	posthoc_test
rafard	L8	6	NDVI	P97	SOIL_1		0.0	368	0.02	small	Kruskal	Dunn
rafard	L8	6	LAI	P97	SOIL_1		0.0	368	0.02	small	Kruskal	Dunn
rafard	S2	6	NDVI	AN	ME SOIL_1		2	453	191	small	Kruskal	Dunn
rafard	S2	12	CIRE	P97	SOIL_2		0.0	465	2.032	large	Kruskal	Dunn
rafard	L8	6	STB10	AN	ME SOLO		6	495	501	small	Kruskal	Dunn
barra	bonita_L8	12	STB10	AN	ME SOIL_T AXON		33	549	438	small	Kruskal	Dunn
rafard	S1	6	RVI	P97	SOIL_2		951	555	3.331	large		Dunn
rafard	S1	6	RVI	AN	ME SOIL_N M	1		556	2.255	large	ANOVA	Tukey
rafard	S2	12	NDVI	P97	SOIL_1		0.0	558	1.168	moderate	Kruskal	Dunn
rafard	S2	12	LAI	P97	SOIL_1		0.0	559	1.167	moderate	Kruskal	Dunn
barra	bonita_S1	3	RVI	P97	SOIL_T AXON		7.825	598	887	moderate		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_S1	3	RVI	P97	SOIL_1		2.216	676	1.526	large		Dunn
barra	bonita_S2	3	CIRE	AN	SOIL_2		232	704	76	negligible		Dunn
barra	bonita_S1	3	RVI	AN	SOIL_1		1.244	716	1.521	large		Dunn
rafard	L8	3	STB10	AN	ME SOIL_N M		18	854	58	negligible	Kruskal	Dunn
rafard	L8	12	NDVI	AN	ME SOIL_N M	0.0		857	456	small	ANOVA	Tukey
rafard	L8	12	LAI	AN	ME SOIL_N M	0.0		857	456	small	ANOVA	Tukey
rafard	L8	12	NDVI	P97	SOIL_2		0.0	868	129	moderate	Kruskal	Dunn
rafard	L8	12	LAI	P97	SOIL_2		0.0	868	129	moderate	Kruskal	Dunn
rafard	S2	6	LAI	AN	ME SOIL_1		2	886	189	small	Kruskal	Dunn
barra	bonita_S1	3	RVI	P97	SOIL_2		3.144	915	1.528	large		Dunn
barra	bonita_L8	3	NDVI	P97	SOIL_1		812	917	47	negligible		Dunn

farm	satellite	interval_months	index	stat	soil_column	anova_p	kruskal_p	levene_p	eta2	effect_strength	significance_test	posthoc_test
barra	bonita_L8	3	LAI	P97	SOIL_1		812	917	47	negligible		Dunn
rafard	S1	12	RVI	AN	SOIL_1		4.205	919	372	small		Dunn
barra	bonita_L8	3	STB10	AN	ME SOIL_T AXON		114	984	93	negligible	Kruskal	Dunn
barra	bonita_S1	3	RVI	AN	ME SOIL_2		1.514	985	1.523	large		Dunn

Anexo 4 - Tabela classes de solos Rafard

Sigla	Classe/Unidade de Mapeamento
Ordem	Nível de Classificação Categórico (Geral)
cx	Cambissolo
mt	Latossolo (regionalmente chamado "Marga Translucida" em alguns estudos)
nv	Nitossolo Vermelho
pa	Argissolo Amarelo
pva	Argissolo Vermelho-Amarelo
Subordem	Nível de Classificação de Subordem (Detalhado)
cabdlep.med	Cambissolo Háptico Distrófico típico, textura média
cbelep.arg	Cambissolo Háptico Eutrófico típico, textura argilosa
exhvdlep.med	Cambissolo Háptico Vermelho Distrófico típico, textura média
exhvelep.med	Cambissolo Háptico Vermelho Eutrófico típico, textura média
cxvflt.arg	Cambissolo Háptico Vermelho Distrófico típico, textura argilosa
cabet.arg	Cambissolo Eutrófico típico, textura argilosa
gbet.arg	Gleissolo Háptico Eutrófico típico, textura argilosa

gxvflt.med	Gleissolo Háptico Vermelho Distrófico típico, textura média
nldfrag.silt	Neossolo Litólico Distrófico, fase fragmentária, textura siltosa
nlefrag.silt	Neossolo Litólico Eutrófico, fase fragmentária, textura siltosa
nlett.arg	Neossolo Litólico Eutrófico, textura argilosa
nslftt.arg	Latossolo, fase transição, textura argilosa
mslft+nvdtt.mt.arg	Latossolo, fase transição + Nitossolo Vermelho Distrófico, textura muito argilosa
nvflat+nvdlat.mt.arg	Nitossolo Vermelho fase Latossólica + Nitossolo Vermelho Distrófico fase Latossólica, textura muito argilosa
nveflt.mt.arg	Nitossolo Vermelho Eutrófico fase Latossólica, textura muito argilosa
<u>paeab.ar/med</u>	Argissolo Amarelo Eutrófico abrupto, textura arenosa/média
nxd.arg	Nitossolo Xênico Distrófico, textura argilosa
<u>pvadab.ar/med</u>	Argissolo Vermelho-Amarelo Distrófico abrupto, textura arenosa/média
pvadtt.med/med	Argissolo Vermelho-Amarelo Distrófico típico, textura média/média
pvadab.med/arg	Argissolo Vermelho-Amarelo Distrófico abrupto, textura média/argilosa
<u>pvacb.ar/med</u>	Argissolo Vermelho-Amarelo Eutrófico abrupto, textura arenosa/média
