



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE CIÊNCIAS DO SOLO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DO SOLO

FRANCISCA EVELICE CARDOSO DE SOUZA

ESPECTROSCOPIA DE REFLECTÂNCIA vis-NIR-SWIR-MIR NA
CARACTERIZAÇÃO DE PERFIS E AVALIAÇÃO DE ATRIBUTOS DE SOLOS
TÍPICOS DO NORDESTE DO BRASIL

FORTALEZA

2025

FRANCISCA EVELICE CARDOSO DE SOUZA

ESPECTROSCOPIA DE REFLECTÂNCIA vis-NIR-SWIR-MIR NA CARACTERIZAÇÃO
DE PERFIS E AVALIAÇÃO DE ATRIBUTOS DE SOLOS TÍPICOS DO NORDESTE DO
BRASIL

Tese apresentada ao Programa de Pós-Graduação em Ciência do Solo da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutora em Ciência do Solo. Área de concentração: Pedologia.

Orientador: Prof. Dr. Raul Shiso Toma.

Coorientador: Prof. Dr. Fabrício da Silva Terra.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- S238e Souza, Francisca Evelice Cardoso de.
Espectroscopia de reflectância vis-NIR-SWIR-MIR na caracterização de perfis e avaliação de atributos de solos típicos do Nordeste do Brasil / Francisca Evelice Cardoso de Souza. – 2026.
157 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Ciência do Solo, Fortaleza, 2026.

Orientação: Prof. Dr. Raul Shiso Toma.

Coorientação: Prof. Dr. Fabrício da Silva Terra.

1. sensoriamento próximo. 2. comportamento espectral. 3. quantificação. 4. salinidade. 5. sodicidade. I. Título.

CDD 631.4

FRANCISCA EVELICE CARDOSO DE SOUZA

ESPECTROSCOPIA DE REFLECTÂNCIA vis-NIR-SWIR-MIR NA CARACTERIZAÇÃO
DE PERFIS E AVALIAÇÃO DE ATRIBUTOS DE SOLOS TÍPICOS DO NORDESTE DO
BRASIL

Tese apresentada ao Programa de Pós-Graduação em Ciência do Solo da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutora em Ciência do Solo. Área de concentração: Pedologia.

Aprovada em: 19/11/2025.

BANCA EXAMINADORA

Prof. Dr. Raul Shiso Toma (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Phd Adunias dos Santos Teixeira
Universidade Federal do Ceará (UFC)

Prof. Dr. Ricardo Espíndola Romero
Universidade Federal do Ceará (UFC)

Prof^ª. Dr^ª. Isabel Cristina da Silva Araújo
Universidade Federal do Ceará (UFC)

Prof. Dr. Fabrício da Silva Terra
Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM)

A Deus.

Aos meus avós, Francisco e Áurea.

AGRADECIMENTOS

A Deus, por seu amor e bondade incondicionais, por me capacitar e me guiar para alcançar meus objetivos.

Ao meu esposo, Tércio Luiz, por não soltar a minha mão durante essa jornada, pelo apoio, amor, companheirismo e incentivo para seguir em frente, mesmo quando penso que não irei conseguir.

À minha família, em especial à minha mãe e à minha irmã, Zuleide e Eveline, por sempre me apoiarem e incentivarem, por se fazerem presentes mesmo à distância e por vibrarem comigo em todas as conquistas.

Ao Prof. Dr. Raul Shiso Toma, pela valorosa orientação, paciência, empatia, conselhos e por todos os conhecimentos compartilhados durante essa jornada.

Aos professores participantes da banca examinadora, pelo tempo disponibilizado, pelas valiosas colaborações e sugestões que contribuirão para o meu crescimento pessoal e profissional.

A todos os professores e funcionários do Departamento de Ciência do Solo, por terem contribuído, de alguma forma, para minha formação.

À equipe do Laboratório de Análises de Solos, Águas, Tecidos e Adubos - Convênio FUNCEME/UFC, por disponibilizarem as amostras de solos utilizadas neste estudo.

Ao grupo de estudos de Geoprocessamento, Automação e Manejo Agrícola (GAMA), pelo apoio na realização das análises espectrais.

Ao INCT em Agricultura Sustentável no Semiárido Tropical-INCTAGriS (CNPq/Funcap/Capes), pelo apoio para a realização deste trabalho.

Às amizades estabelecidas durante o doutorado, pelas reflexões, sugestões recebidas e momentos de descontração.

A todos que contribuíram para concretização deste trabalho.

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

“Todas as coisas foram feitas por meio d’Ele;
sem Ele, nada do que existe teria sido feito”
(João 1,3).

RESUMO

O solo é essencial para a existência da vida na Terra e para o desempenho de serviços ecossistêmicos, tornando imperativo o monitoramento eficiente dos seus atributos. Tradicionalmente, o solo é avaliado por meio de análises laboratoriais de química úmida, todavia, esta técnica tem se mostrado onerosa e demorada. Como alternativa promissora, o sensoriamento próximo com a técnica de espectroscopia de reflectância destaca-se por permitir realizar análises pedológicas rápidas e de baixo custo, sendo especialmente vantajosa para o estudo de regiões heterogêneas e susceptíveis à degradação, como o Nordeste brasileiro. Diante desse contexto, o presente estudo teve como objetivos: - explorar o potencial dos espectros do visível ao infravermelho médio para caracterizar o comportamento espectral de solos da região Nordeste; - quantificar os atributos físico-químicos desses solos, incluindo a salinidade e a sodicidade, por meio da espectroscopia na faixa de 350 – 15000 nm e algoritmos de estatística multivariada. Foram avaliadas 114 amostras de solo, abrangendo nove ordens, coletadas em 24 perfis pedológicos distribuídos por 13 municípios do Ceará. Por meio das análises de química úmida foram determinados os atributos: carbono orgânico, nitrogênio total, fósforo disponível, potássio, cálcio, magnésio, sódio e alumínio trocáveis, condutividade elétrica, pH, soma de bases, capacidade de troca catiônica, saturação de bases e a percentagem de saturação por sódio. A análise espectral avaliou a reflectância do solo nas faixas do visível, infravermelho próximo, infravermelho de ondas curtas (vis-Nir-SWIR) e infravermelho médio (MIR), tendo sido esses dados pré-processados com as técnicas de suavização com o filtro Savitzky-Golay e conversão para absorbância. O resultado da análise convencional foi avaliado com estatística descritiva. Os dados suavizados foram submetidos a análise de componentes principais (ACP), e os escores da ACP foram utilizados para análise de agrupamento com o algoritmo de classificação não supervisionada Fuzzy K-médias. Para a quantificação dos atributos, os modelos preditivos foram desenvolvidos com os espectros brutos e pré-processados, utilizando-se os algoritmos de Regressão por Mínimos Quadrados Parciais, Máquina de Vetor Suporte com funções Kernel lineares e radiais e Algoritmo Cubista. O desempenho dos modelos preditivos foi avaliado pelas métricas de R^2 , RMSE, RPD e RPIQ. Os resultados da análise qualitativa revelaram comportamentos espectrais com padrões distintos entre as ordens de solo. A classificação não supervisionada agrupou amostras com base nas características dos horizontes, com a região MIR demonstrando maior sensibilidade para identificar variações mais sutis entre os horizontes. Na análise quantitativa, todos os atributos foram preditos com desempenho, no mínimo, satisfatório, com exceção do

cálcio que exibiu desempenho insatisfatório com R^2 inferior a 0,50. Os modelos desenvolvidos com dados do MIR superaram consistentemente o desempenho daqueles da faixa vis-NIR-SWIR para a maioria dos atributos. As predições da condutividade elétrica e da percentagem de saturação por sódio apresentaram desempenho razoável, evidenciando o potencial da técnica para o diagnóstico da salinidade e sodicidade dos solos. Esses resultados ratificam o potencial da espectroscopia de reflectância como uma ferramenta eficiente e alternativa para a caracterização e predição de atributos em solos heterogêneos.

Palavras-chave: sensoriamento próximo; comportamento espectral; quantificação; salinidade; sodicidade.

ABSTRACT

Soil is essential for life on Earth and for the performance of ecosystem services, making efficient monitoring of its attributes essential. Traditionally, soil is evaluated through wet chemistry laboratory analyses, but this technique has proven to be costly and time-consuming. As a promising alternative, remote sensing using reflectance spectroscopy stands out for allowing rapid and low-cost pedological analyses, which is especially advantageous for the study of heterogeneous regions susceptible to degradation, such as Northeast Brazil. Given this context, the objectives of this study were: - to explore the potential of visible to mid-infrared spectra to characterize the spectral behavior of soils in the Northeast region; - to quantify the physical and chemical attributes of these soils, including salinity and sodicity, using spectroscopy in the 350–15,000 nm range and multivariate statistical algorithms. A total of 114 soil samples were evaluated, covering nine orders, collected from 24 soil profiles distributed across 13 cities in Ceará. Through wet chemistry analyses, the following attributes were determined: organic carbon, total nitrogen, available phosphorus, exchangeable potassium, calcium, magnesium, sodium, and aluminum, electrical conductivity, pH, base sum, cation exchange capacity, base saturation, and sodium saturation percentage. Spectral analysis evaluated soil reflectance in the visible, near-infrared, short-wave infrared (vis-NIR-SWIR), and mid-infrared (MIR) ranges, with data preprocessed using Savitzky-Golay smoothing and conversion to absorbance. The results of the conventional analysis were evaluated using descriptive statistics. The smoothed data were subjected to principal component analysis (PCA), and the PCA scores were used for cluster analysis with the unsupervised Fuzzy K-means classification algorithm. To quantify the attributes, predictive models were developed with raw and preprocessed spectra using Partial Least Squares Regression, Support Vector Machine with linear and radial kernel functions, and Cubist Algorithm algorithms. The performance of the predictive models was evaluated by the metrics R^2 , RMSE, RPD, and RPIQ. The results of the qualitative analysis revealed spectral behaviors with distinct patterns between soil orders. Unsupervised classification grouped samples based on horizon characteristics, with the MIR region showing greater sensitivity to identify more subtle variations between horizons. In the quantitative analysis, all attributes were predicted with at least satisfactory performance, except for calcium, which showed unsatisfactory performance with R^2 below 0.50. The models developed with MIR data consistently outperformed those in the vis-NIR-SWIR range for most attributes. The predictions of electrical conductivity and sodium saturation percentage showed reasonable performance,

highlighting the potential of the technique for diagnosing soil salinity and sodicity. These results confirm the potential of reflectance spectroscopy as an efficient and alternative tool for characterizing and predicting attributes in heterogeneous soils.

Keywords: near-surface sensing; spectral behavior; quantification; salinity; sodicity.

LISTA DE FIGURAS

Figura 1	– Mapa da área de estudo localizada no estado do Ceará, Brasil	38
Figura 2	– Fluxograma da metodologia de trabalho para as análises do solo	39
Figura 3	– Equipamento de aquisição dos dados espectrais vis-NIR-SWIR	41
Figura 4	– Equipamento FTIR Cary 630 para aquisição de dados espectrais MIR	42
Figura 5	– Suporte com placa de referência e amostras de solo para leitura no MIR	42
Figura 6	– Análise da a) distribuição de frequência das ordens e b) subordens de solo ..	45
Figura 7	– Correlação multivariada entre atributos do solo e a faixa espectral vis-NIR-SWIR	47
Figura 8	– Correlação multivariada entre atributos do solo e a faixa espectral MIR	49
Figura 9	– Comportamento espectral de perfil 5: ARGISSOLO ACINZENTADO Eutrófico típico	52
Figura 10	– Comportamento espectral de perfil 6: ARGISSOLO AMARELO Distrófico típico	53
Figura 11	– Comportamento espectral de perfil 9: ARGISSOLO AMARELO Distrocoesolódico	54
Figura 12	– Comportamento espectral de perfil 12: ARGISSOLO VERMELHO-AMARELO Distrófico arênico	55
Figura 13	– Comportamento espectral de perfil 18: ARGISSOLO VERMELHO-AMARELO Distrófico arênico	56
Figura 14	– Comportamento espectral de perfil 18: ARGISSOLO VERMELHO Distrófico nitossólico	57
Figura 15	– Comportamento espectral de perfil 11: CAMBISSOLO HÁPLICO Tb Eutrófico típico	58
Figura 16	– Comportamento espectral de perfil 20: CAMBISSOLO HÁPLICO Tb Distrófico saprolítico	60
Figura 17	– Comportamento espectral de perfil 8: GLEISSOLO SÁLICO Sódico típico ..	62
Figura 18	– Comportamento espectral de perfil 14: LATOSSOLO AMARELO Distrófico psamítico	64
Figura 19	– Comportamento espectral de perfil 4: LUVISSOLO HÁPLICO Pálico abrupto	65

Figura 20	– Comportamento espectral de perfil 21: LUVISSOLO CRÔMICO Órtico abrupto	66
Figura 21	– Comportamento espectral de perfil 1: NEOSSOLO FLÚVICO Psamítico típico	67
Figura 22	– Comportamento espectral de perfil 7: NEOSSOLO FLÚVICO Sódico típico	68
Figura 23	– Comportamento espectral de perfil 15: NEOSSOLO FLÚVICO Ta Eutrófico solódico	69
Figura 24	– Comportamento espectral de perfil 2: NEOSSOLO QUARTZARÊNICO Órtico típico	70
Figura 25	– Comportamento espectral de perfil 13: NEOSSOLO QUARTZARÊNICO Hidromórfico típico	71
Figura 26	– Comportamento espectral de perfil 23: NEOSSOLO LITÓLICO Eutrófico típico	72
Figura 27	– Comportamento espectral de perfil 3: PLANOSSOLO NÁTRICO Órtico típico	73
Figura 28	– Comportamento espectral de perfil 10: PLANOSSOLO NÁTRICO Órtico mésico	74
Figura 29	– Comportamento espectral de perfil 17: PLANOSSOLO NÁTRICO Órtico mésico	75
Figura 30	– Comportamento espectral de perfil 22: PLANOSSOLO HÁPLICO Eutrófico típico	76
Figura 31	– Comportamento espectral de perfil 24: PLINTOSSOLO ARGILÚVICO Eutrófico petroplântico	77
Figura 32	– Comportamento espectral de perfil 16: VERTISSOLO EBÂNICO Sódico salino	79
Figura 33	– Variância explicada pelas cinco primeiras componentes na faixa vis-NIR-SWIR	80
Figura 34	– Autovetores da análise de componentes principais na faixa vis-NIR-SWIR...	80
Figura 35	– Agrupamento das amostras de solos com escores da ACP na faixa vis-NIR-SWIR	81
Figura 36	– Espectros de reflectância médio por grupo na faixa vis-NIR-SWIR	83
Figura 37	– Variabilidade dos atributos do solo (g kg^{-1}) por grupo na faixa vis-NIR-SWIR: a) areia; b) silte; c) argila	84

Figura 38 – Variabilidade dos atributos do solo por grupo na faixa vis-NIR-SWIR: a) carbono orgânico (g kg^{-1}); b) pH; c) sódio ($\text{cmol}_c \text{ kg}^{-1}$); d) PST; e) CE (dS m^{-1})	86
Figura 39 – Variabilidade dos atributos do solo ($\text{cmol}_c \text{ kg}^{-1}$) por grupo na faixa vis-NIR-SWIR: a) cálcio; b) magnésio; c) potássio; d) nitrogênio (g kg^{-1})	87
Figura 40 – Variância explicada pelas cinco primeiras componentes na faixa MIR	88
Figura 41 – Autovetores da análise de componentes principais na faixa MIR	88
Figura 42 – Agrupamento das amostras de solos com escores da ACP na faixa MIR	88
Figura 43 – Espectros de reflectância médio por grupo na faixa MIR	91
Figura 44 – Variabilidade dos atributos do solo (g kg^{-1}) por grupo na faixa MIR: a) areia; b) silte; c) argila	92
Figura 45 – Variabilidade dos atributos do solo por grupo na faixa MIR: a) carbono orgânico (g kg^{-1}); b) pH; c) sódio ($\text{cmol}_c \text{ kg}^{-1}$); d) PST; e) CE (dS m^{-1})	93
Figura 46 – Variabilidade dos atributos do solo ($\text{cmol}_c \text{ kg}^{-1}$) por grupo na faixa MIR: a) cálcio; b) magnésio; c) potássio; d) nitrogênio (g kg^{-1})	94
Figura 47 – Mapa com os municípios do estado do Ceará de coleta dos solos	101
Figura 48 – a) Amostras de solo preparadas para leitura espectral b) Equipamento de aquisição dos dados espectrais vis-NIR-SWIR	103
Figura 49 – Equipamento para leitura espectral na faixa MIR	104
Figura 50 – Fluxograma metodológico da predição de atributos físico-químicos do solo..	106
Figura 51 – Desempenho dos melhores modelos de validação para areia (A), silte (B) e argila (C) na faixa vis-NIR-SWIR	111
Figura 52 – Desempenho dos melhores modelos de validação para carbono orgânico (A), alumínio (B), sódio (C) e percentagem de sódio trocável (D) na faixa vis-NIR-SWIR	113
Figura 53 – Desempenho dos melhores modelos de validação para nitrogênio (A), fósforo (B), potássio (C), cálcio (D) e magnésio (E) na faixa vis-NIR-SWIR	115
Figura 54 – Desempenho dos melhores modelos de validação para soma de bases (A), capacidade de troca de cátions (B), saturação por bases (C), condutividade elétrica (D) e pH (E) na faixa vis-NIR-SWIR	116
Figura 55 – Desempenho dos melhores modelos de validação para areia (A), silte (B) e argila (C) na faixa MIR	119

Figura 56 – Desempenho dos melhores modelos de validação para carbono orgânico (A), alumínio (B) sódio (C) e percentagem de sódio trocável (D) na faixa MIR	120
Figura 57 – Desempenho dos melhores modelos de validação para nitrogênio (A), fósforo (B), potássio (C), cálcio (D) e magnésio (E) na faixa MIR	122
Figura 58 – Desempenho dos melhores modelos de validação para soma de bases (A), capacidade de troca de cátions (B), saturação por bases (C), condutividade elétrica (D) e pH (E) na faixa MIR	123

LISTA DE TABELAS

Tabela 1 – Características dos principais solos presentes na região Nordeste, conforme o Sistema Brasileiro de Classificação de Solos	24
Tabela 2 – Identificação de amostras do solo por grupo na faixa vis-NIR-SWIR	82
Tabela 3 – Identificação de amostras do solo por grupo na faixa MIR	90
Tabela 4 – Estatística descritiva para os atributos dos 114 solos avaliados sem normalização	109
Tabela 5 – Resultado dos melhores modelos de validação por atributo do solo	125

SUMÁRIO

1	INTRODUÇÃO GERAL	19
1.1	Hipóteses	21
2	REFERENCIAL TEÓRICO	22
2.1	Solos do Nordeste brasileiro	22
2.2	Espectroscopia de reflectância	25
2.3	Comportamento espectral do solo	26
2.4	Fatores que influenciam o comportamento espectral do solo	28
2.4.1	<i>Efeito da matéria orgânica, mineralogia, umidade e granulometria</i>	<i>28</i>
2.5	Processamento de dados espectrais e estimativa dos atributos do solo	31
3	CAPÍTULO I CARACTERIZAÇÃO ESPECTRAL DO VISÍVEL AO INFRAVERMELHO MÉDIO DE SOLOS DO NORDESTE BRASILEIRO	34
3.1	Introdução	36
3.1.1	<i>Objetivos</i>	<i>37</i>
3.2	Material e métodos	37
3.2.1	<i>Área de estudo e banco de dados do solo</i>	<i>38</i>
3.2.2	<i>Análises laboratoriais úmidas</i>	<i>39</i>
3.2.3	<i>Análise espectral</i>	<i>40</i>
3.2.4	<i>Análise estatística</i>	<i>43</i>
3.2.5	<i>Análise de componentes principais e agrupamento dos dados espectrais</i>	<i>43</i>
3.3	Resultados e discussão	44
3.3.1	<i>Caracterização dos solos</i>	<i>44</i>
3.3.2	<i>Correlação entre atributos do solo e faixas espectrais</i>	<i>46</i>
3.3.3	<i>Comportamento espectral das classes de solos</i>	<i>50</i>
3.3.3.1	<i>Argissolo</i>	<i>50</i>
3.3.3.2	<i>Cambissolo</i>	<i>57</i>
3.3.3.3	<i>Gleissolo</i>	<i>60</i>
3.3.3.4	<i>Latossolo</i>	<i>62</i>
3.3.3.5	<i>Luvisolo</i>	<i>64</i>
3.3.3.6	<i>Neossolo</i>	<i>66</i>
3.3.3.7	<i>Planossolo</i>	<i>72</i>

3.3.3.8	<i>Plintossolo</i>	76
3.3.3.9	<i>Vertissolo</i>	78
3.3.4	<i>Agrupamento de horizontes do solo na faixa espectral vis-NIR-SWIR</i>	79
3.3.5	<i>Agrupamento de horizontes do solo na faixa espectral MIR</i>	87
3.4	Conclusões	95
4	CAPÍTULO II PREDIÇÃO DE ATRIBUTOS FÍSICOS E QUÍMICOS COM ESPECTROSCOPIA DO VISÍVEL AO INFRATERMELHO MÉDIO EM SOLOS DO NORDESTE DO BRASIL	96
4.1	Introdução	98
4.1.1	<i>Objetivos</i>	99
4.2	Material e métodos	100
4.2.1	<i>Seleção das amostras</i>	100
4.2.2	<i>Análises convencionais de química úmida</i>	102
4.2.3	<i>Análise espectral</i>	102
4.2.4	<i>Processamento dos dados espectrais</i>	104
4.2.5	<i>Estatística descritiva</i>	105
4.2.6	<i>Modelagem preditiva – Calibração e Validação</i>	105
4.3	Resultados e discussão	108
4.3.1	<i>Estatística descritiva</i>	108
4.3.2	<i>Modelagem preditiva com dados espectrais vis-NIR-SWIR</i>	110
4.3.3	<i>Modelagem preditiva com dados espectrais MIR</i>	118
4.3.4	<i>Melhores modelos preditivos</i>	125
4.4	Conclusões	129
5	CONSIDERAÇÕES FINAIS	131
	REFERÊNCIAS	132
	APÊNDICE A – CLASSIFICAÇÃO DOS SOLOS E IDENTIFICAÇÃO DO PONTO DO PERFIL NO LEVANTAMENTO DOS SOLOS DO ESTADO DO CEARÁ	141
	APÊNDICE B – ESTATÍSTICA DESCRITIVA POR CLASSE DE SOLO	142
	APÊNDICE C – RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS PREDITIVOS PARA OS ATRIBUTOS FÍSICOS COM ESPECTROS VIS-NIR-SWIR	145

APÊNDICE D – RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS PREDITIVOS PARA OS ATRIBUTOS QUÍMICOS COM ESPECTROS VIS-NIR-SWIR	146
APÊNDICE E – RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS PREDITIVOS PARA OS ATRIBUTOS FÍSICOS COM ESPECTRO MIR	151
APÊNDICE F – RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS PREDITIVOS PARA OS ATRIBUTOS QUÍMICOS COM ESPECTROS MIR	152

1 INTRODUÇÃO GERAL

O atual cenário de rápido crescimento populacional tem aumentado expressivamente a demanda por alimentos, conferindo ao solo papel central tanto para manter o equilíbrio ecológico quanto para promover a segurança alimentar. Diante disso, há o consenso de que a manutenção de solos saudáveis é a base para viabilizar a segurança alimentar e mitigar os efeitos das mudanças climáticas (Souza; Leite; Medeiros, 2021). Nesse contexto, o monitoramento eficiente dos sistemas edáficos é imperativo para promover a sustentabilidade dos recursos naturais.

O monitoramento do solo é tradicionalmente realizado com análises laboratoriais de química úmida. Embora esses métodos sejam precisos e confiáveis, sua execução requer grandes quantidades de reagentes químicos, equipamentos de alto custo e múltiplas etapas analíticas, além do uso de diversos instrumentos (Beniaich *et al.*, 2025). Como alternativa, as técnicas de sensoriamento próximo têm se destacado por realizar análises rápidas, com maior eficiência operacional e causando menor impacto ambiental (Yu *et al.*, 2023).

Nesse contexto, a espectroscopia de reflectância desponta como uma tecnologia promissora para a avaliação pedológica. Essa técnica avalia o solo com base na radiação eletromagnética refletida, sem que ocorra contato direto entre o sensor e o alvo (Mendes *et al.*, 2022), sendo possível por meio de uma única leitura espectral avaliar os atributos físicos, químicos e mineralógicos do solo. A caracterização espectral é feita com base no princípio de que a diversidade, concentração e o tamanho dos componentes orgânicos e inorgânicos dos solos produzem comportamentos espectrais distintos (Rizzo *et al.*, 2021), assim, cada solo possui sua própria assinatura espectral.

A análise espectral do solo gera milhares de valores de reflectância (Padarian; Minasny; Mcbratney, 2019). O processamento desses dados envolve duas etapas importantes: o pré-processamento dos espectros brutos para extrair informações relevantes; e a modelagem estatística multivariada para prever os atributos do solo a partir dos dados espectrais (Beniaich *et al.*, 2025). A etapa de pré-processamento é considerada fundamental para remover ruídos, melhorar a qualidade do sinal e a estabilidade da regressão, havendo atualmente diversas técnicas disponíveis para tratamento espectral (Lotfollahi *et al.*, 2023).

Na etapa de modelagem realiza-se a calibração, validação e teste dos modelos, por meio de algoritmos de regressão linear e de aprendizado de máquina. Ainda que exista uma diversidade de algoritmos disponíveis para modelagem, nenhum é globalmente aceito e definido como padrão para a predição, uma vez que cada algoritmo possui vantagens e

limitações. Os métodos de regressão linear são simples e de fácil aplicação, dando resultados claros, contudo, são sensíveis a *outliers*. Os algoritmos de aprendizado de máquina, por sua vez, adaptam-se melhor a estruturas de dados complexos, porém, carecem de transparência durante a modelagem (Sun *et al.*, 2024; Vasava; Das, 2022).

As informações obtidas na análise espectral possuem grande relevância quando organizadas em bibliotecas espectrais, as quais consistem em bancos de dados de referência usados para auxiliar na compreensão do comportamento espectral do solo e na predição dos atributos. Embora existam bibliotecas de alcance continental e nacional, a utilidade de bancos de dados regionais não deve ser desconsiderada, visto que a análise espectral é complexa, sobretudo quando se usam bibliotecas compostas por solos formados sob diferentes materiais de origem, climas e relevos (Demattê *et al.*, 2019; Moura-Bueno *et al.*, 2020). Essa complexidade torna-se mais evidente na análise de áreas extensas, como o Brasil, cujas dimensões continentais resultam em elevada variedade edafoclimática.

O território brasileiro abriga solos com características contrastantes entre suas regiões, destacando-se o Nordeste como exemplo notável dessa diversidade pedológica. Esta região apresenta predominância de clima semiárido, abriga o bioma Caatinga, exclusivo do Brasil, e possui uma ampla variedade de material geológico, o que propicia a ocorrência de solos que variam de rasos a profundos, de arenosos a argilosos e de mineralogia caulínica a esmectítica (Araújo Filho *et al.*, 2022).

A Caatinga é o terceiro bioma mais degradado do país, apresentando grande parte da sua vegetação modificada por atividades antrópicas (Souza; Leite; Medeiros, 2021). Associado a este cenário, o clima semiárido contribui para o agravamento da degradação das terras, especialmente pelo acúmulo de sais no solo, fenômeno comum em regiões áridas e semiáridas, intensificado pelo uso de água de má qualidade e por práticas de irrigação inadequadas (Hailu; Mehari, 2021).

O excesso de sais no solo acarreta severos impactos sobre o desenvolvimento agrícola e a estabilidade dos ecossistemas, comprometendo a segurança alimentar em escala global (Sun *et al.*, 2024). No Brasil, esse fenômeno manifesta-se de forma preocupante, sobretudo em áreas irrigadas, uma vez que o uso de água de baixa qualidade e a deficiência de sistemas de drenagem têm contribuído para a expansão de solos salinos e sódicos, especialmente em regiões semiáridas (Pessoa, *et al.*, 2022).

Essas particularidades tornam urgente a avaliação e o monitoramento dos solos do Nordeste brasileiro, sobretudo aqueles do bioma Caatinga. No entanto, esta região é pouca explorada cientificamente, de modo que a aplicação da espectroscopia de reflectância em

solos das regiões áridas e semiáridas ainda é incipiente (Taghdis; Farpoor; Mahmoodabadi, 2022). Ainda assim, esta técnica é promissora para a avaliação em larga escala, representando alternativa eficiente, rápida e de baixo custo para áreas que carecem de métodos eficientes de monitoramento.

Nesse contexto, esta tese avalia solos representativos do Nordeste brasileiro, realizando a sua caracterização espectral e a predição de atributos físicos e químicos. A pesquisa está estruturada em dois capítulos: o primeiro apresenta a caracterização do comportamento espectral de 24 perfis pedológicos, bem como uma análise de agrupamento baseada nos dados espectrais; e o segundo expõe a modelagem preditiva de 17 atributos dos solos.

1.1 Hipóteses

Este trabalho apresenta como hipóteses gerais:

I) A espectroscopia de reflectância permite caracterizar de forma eficiente o comportamento espectral e os atributos dos solos, constituindo uma ferramenta adequada para identificação de características de solos típicos do Nordeste brasileiro;

II) A espectroscopia de reflectância apresenta elevado potencial para a predição de atributos físicos e químicos dos solos, demonstrando ser uma técnica precisa e confiável.

2 REFERENCIAL TEÓRICO

Nesta seção apresentam-se conceitos e panoramas teóricos que sustentam a base técnica desta pesquisa. Expõem-se aspectos relativos às características dos solos do Nordeste brasileiro. Discorre-se sobre o enfoque teórico da espectroscopia de reflectância e o comportamento espectral dos solos, e finaliza-se com a exploração das técnicas metodológicas para tratamentos dos dados espectrais.

2.1 Solos do Nordeste brasileiro

A região Nordeste abrange aproximadamente 18,2% do território nacional e apresenta a maior diversidade de solos do país, compondo um mosaico de pequenas áreas com distintas características pedológicas. A heterogeneidade edafoclimática dessa região favorece a ocorrência de diferentes biomas - Caatinga, Cerrado, Mata Atlântica e Floresta Amazônica -, que apresentam alta variabilidade dos recursos naturais, refletida nos diferentes solos, climas e tipos de vegetação (Souza; Leite; Medeiros, 2021).

O bioma Caatinga é o de maior predominância no Nordeste, ocupando mais de 50% da sua área e distribuindo-se pelos estados do Maranhão, Piauí, Ceará, Rio Grande do Norte, Pernambuco, Paraíba, Alagoas, Sergipe e Bahia, estendendo-se ainda por parte de Minas Gerais. Trata-se de um bioma exclusivamente brasileiro, caracterizado pelo clima semiárido, com altas temperaturas e longos períodos de estiagem. Sua vegetação destaca-se pela alta heterogeneidade, possuindo rica biodiversidade e muitas espécies endêmicas que são adaptadas às condições de semiaridez; contudo, encontra-se intensamente degradada pela ação antrópica (Alves; Araújo; Nascimento, 2009; Souza; Leite; Medeiros, 2021).

Além da diversidade de biomas, a região Nordeste apresenta alta variabilidade de material geológico, abrangendo desde rochas cristalinas (ígneas e metamórficas) até sedimentares. Essa variedade litológica favorece a formação de variados tipos de solos com diferentes graus de intemperismo e desenvolvimento pedogenético (Araújo Filho *et al.*, 2022), além de influenciar os atributos pedológicos. Nesta perspectiva, a soma de bases (SB) dos solos é muito variável, sendo comum que nos locais em que as rochas são mais ricas em minerais máficos (rochas básicas) a SB varia de alta a muito alta. Por outro lado, nos locais em que os materiais são rochas félsicas (ácidas), frequentemente os valores de SB são baixos (Souza; Leite; Medeiros, 2021).

A natureza do material parental influencia, também, o tipo de minerais presentes no solo. Os materiais cristalinos são em sua maioria muito resistentes à erosão e ao intemperismo, assim, solos desenvolvidos a partir destas rochas possuem forte correlação com o material de origem, apresentando comumente profundidade limitada e minerais primários na composição, além de minerais secundários menos intemperizados (argilas do tipo 2:1). Em contraste, os solos oriundos de materiais sedimentares são mais desenvolvidos e mais profundos, com predomínio de minerais mais intemperizados como os argilominerais secundários do tipo 1:1 e oxídicos (Ximenes, *et al.*, 2019).

Associado a variabilidade de material geológico, o clima característico da região Nordeste favorece a heterogeneidade pedológica. À medida que a precipitação é limitada nessa região, o clima reduz sua ação mitigando a atuação dos processos pedogenéticos, o que faz com o material de origem passe a assumir importante função na diferenciação dos solos (Saraiva, *et al.*, 2020). Diante disso, os solos da região destacam-se por conservar, em grande parte, feições herdadas do material de origem, de modo a refletir o seu ambiente de formação (Souza, 2020).

Entre os solos presentes na região Nordeste destacam-se as seguintes classes pela área ocupada: Latossolos (30,4%), Neossolos (24,0%), Argissolos (18,0%), Luvisolos (7,4%), Planossolos (7,4%), Plintossolos (6,3%), Cambissolos (2,4%) e Gleissolos (1,3%) e em menor percentual os Vertissolos (0,3%) (Souza; Leite; Medeiros, 2021). As principais características desses solos, definidas segundo o Sistema Brasileiro de Classificação de Solos (Santos *et al.*, 2025), estão disponíveis na Tabela 1.

Tabela 1 - Características dos principais solos presentes na região Nordeste, conforme o Sistema Brasileiro de Classificação de Solos

Ordem	Característica
Argissolo	Solo com horizonte diagnóstico B textural com argila de atividade baixa ou alta, desde que conjugada com saturação por bases baixa ou caráter aluminico. Possui profundidade variável, geralmente é muito intemperizado, bem desenvolvido, ácido, com mineralogia predominante de argilominerais do tipo 1:1 (caulinita) e relação molecular Ki entre 1,0 e 3,3.
Cambissolo	Solos com horizonte B incipiente com textura franco-arenosa ou mais fina e com o <i>solum</i> apresentando teores uniformes de argila, podendo ocorrer ligeira redução ou um pequeno incremento de argila do horizonte A para o B incipiente. Possui baixo desenvolvimento e pedogênese pouco avançada evidenciada pelo desenvolvimento da estrutura do solo.
Gleissolo	Solos minerais, hidromórficos, formados principalmente a partir de sedimentos, estratificados ou não. Apresentam expressiva gleização devido ao ambiente redutor virtualmente livre de oxigênio dissolvido em razão da saturação por água permanente ou periódica. Não possuem nenhum tipo de horizonte B diagnóstico acima do horizonte glei, o qual pode ser um horizonte C, B, E ou A.
Latossolo	Solo com horizonte diagnóstico B latossólico abaixo de qualquer horizonte superficial, exceto hístico. Possui avançada intemperização, sendo bem desenvolvido e, geralmente, muito profundo e ácido. É virtualmente destituído de minerais primários, com mineralogia variando de caulinita e valores de Ki em torno de 2,0 podendo ser 2,2, até solos oxídicos com Ki muito baixos.
Luvissolo	Solo com horizonte diagnóstico B textural com argila de atividade alta e saturação por bases alta, abaixo de horizonte A ou E. Comumente, é pouco profundo, medianamente intemperizado, moderadamente ácido e ligeiramente alcalino. Possui relação molecular Ki alta variando de 2,4 a 4,0, indicando mineralogia com expressiva presença de argilominerais do tipo 2:1.
Neossolo	Solo formado por material mineral ou orgânico, sem a presença de horizonte B diagnóstico. É pouco profundo, com baixo desenvolvimento e com predomínio das características do material parental devido à baixa atuação dos processos pedogenéticos. Possui individualização de horizonte A seguido por C ou R.
Planossolo	Solo com horizonte B plânico abaixo de qualquer horizonte A ou E. Apresenta diferenciação bem acentuada entre os horizontes A ou E com o B, em virtude da mudança textural abrupta. Ocorre preferencialmente em relevos plano ou suave ondulado e possui restrição à permeabilidade em subsuperfície.
Plintossolo	Solo com expressiva plintitização com ou sem formação de petroplintita, podendo apresentar horizonte B textural sobre ou coincidente com o horizonte plintico ou concrecionário. Normalmente, é fortemente ácido, com saturação por bases baixa e atividade da fração argila baixa. Típicos de zonas quentes e úmidas, geralmente com estação seca bem definida.
Vertissolo	Solo com horizonte vértico, pequena variação textural ao longo do perfil e com expressivo fendilhamento desde a superfície. Possui desenvolvimento restrito pela grande capacidade de movimentação do material constitutivo, alta saturação por bases, teores elevados de cálcio e magnésio e alta relação Ki.

Fonte: Adaptado de Santos *et al.* (2025).

2.2 Espectroscopia de reflectância

A espectroscopia é o termo usado para se referir à técnica de obtenção de dados por meio da absorção, transmissão ou reflexão da energia radiante que incide em um material (Meneses; Almeida; Baptista, 2019). No estudo do solo com espectroscopia de reflectância, a informação é obtida sem que haja contato entre sensor e alvo, sendo analisada a energia refletida proveniente da interação dos componentes minerais e orgânicos do solo com a radiação eletromagnética (Mendes *et al.*, 2022).

A energia eletromagnética refletida é mensurada com um espectrorradiômetro, o qual gera resultados numéricos expressos na forma de um gráfico chamado de curva de reflectância espectral. No gráfico, o eixo X evidencia os comprimentos de onda e o eixo Y o fator de reflectância. Nessa perspectiva, cada solo tem uma curva espectral, ou seja, sua assinatura espectral própria, que é uma propriedade cumulativa derivada das características intrínsecas do solo (Demattê, 2002).

Quando a energia eletromagnética interage com um material, parte da radiação é absorvida e parte é refletida, sendo as feições de absorção da curva espectral governadas por dois processos gerais chamados de: eletrônico e vibracional (Coblinski *et al.*, 2020). Nesse sentido, as absorções espectrais ocorrem devido às transições eletrônicas dos átomos e às vibrações de alongamento e de dobramento de grupos de átomos que formam as moléculas e os cristais (Meneses; Almeida; Baptista, 2019).

As transições eletrônicas requerem maiores quantidades de energia e ocorrem em íons com elétrons desemparelhados. O processo vibracional, por sua vez, é resultado das vibrações das ligações em uma molécula, de modo que cada vibração possui uma frequência, sendo esse processo dividido em vibração fundamental e não fundamental (Madeira Netto; Baptista, 2000). As transições eletrônicas acontecem no visível e infravermelho próximo, as vibrações não fundamentais incidem no infravermelho próximo e de ondas curtas, e as vibrações fundamentais ocorrem no infravermelho médio (Silvero *et al.*, 2020).

Na espectroscopia de reflectância a faixa amplamente usada para estudos qualitativos e quantitativos dos solos compreende ao visível (vis: 350-700 nm), ao infravermelho próximo (NIR: 700-1100 nm) e ao infravermelho de ondas curtas (SWIR: 1100-2500 nm) (Demattê *et al.*, 2019). A faixa do infravermelho médio (MIR: 2500-25000 nm ou 4000-400 cm^{-1}), embora ofereça grande potencial para o estudo do solo, tem sido aplicada em menor intensidade, sendo as pesquisas para identificar as principais feições

espectrais dessa faixa incipientes em solos tropicais (Silvero *et al.*, 2020). Todavia, nos últimos anos o número de estudos do solo nessa faixa aumentou significativamente.

As medições espectrais na faixa do visível ao infravermelho de ondas curtas são realizadas tanto em campo quanto em laboratório, já as medições no infravermelho médio ocorrem em laboratório. Quando os comprimentos de ondas são mensurados em laboratório, a existência de condições controladas e sem interferência da atmosfera garante maior confiabilidade ao relacionar a reflectância com a composição do material, e maior precisão na avaliação das características. Os resultados das amostras de laboratório são usados para compor grandes bancos de dados, chamados de bibliotecas espectrais, que são formadas por amostras espectrais representativas de solos (Meneses; Almeida; Baptista, 2019).

As medições espectrorradiométricas realizadas em campo podem retratar mais fielmente as condições pedológicas e dar uma boa representação da variabilidade espacial do solo, todavia, apresentam o inconveniente do efeito do ambiente, como a umidade do ar e a luminosidade, além de sofrer variações do ângulo de observação, da rugosidade do solo e do manejo. Dessa maneira, geralmente as avaliações de campo geram resultados menos precisos que as análises espectrais de laboratório, especialmente pelas condições naturais descontroladas no campo (Rizzo *et al.*, 2021).

2.3 Comportamento espectral do solo

O comportamento espectral do solo é condicionado por suas características e tem relação direta com os atributos físicos, químicos e mineralógicos, de modo a refletir os processos pedogenéticos incidentes e as condições ambientais (Demattê *et al.*, 2017). Logo, alterações na composição edáfica modificam a assinatura espectral, sendo que os caminhos da radiação eletromagnética recebida pelos componentes do solo dependem de fenômenos de interações macroscópicas (física) e microscópicas (química) (Terra *et al.*, 2021).

A interação macroscópica é responsável pela intensidade com que um objeto reflete a radiação eletromagnética em função do tamanho da onda e da textura do objeto, sendo sua atuação maior nos grandes comprimentos de onda das micro-ondas, nos quais a baixa energia não possibilita que ocorram interações no nível de átomo e de molécula. Esse fenômeno resulta das propriedades físicas e texturais do solo, como distribuição do tamanho das partículas e estrutura (Meneses; Almeida, 2012; Meneses; Almeida; Baptista, 2019).

Com relação à interação microscópica, ondas de pequeno comprimento possuem elevada energia, o que possibilita uma intensa interação microscópica da matéria e define as

relações entre absorção e reflectância. Essas interações são identificadas nos espectros pelos picos de queda da reflectância, de modo que são responsáveis pelas feições de absorção no espectro, sendo dependentes da composição mineral e orgânica do solo. Esse fenômeno microscópico está relacionado à absorção da radiação eletromagnética por átomos e moléculas (Meneses; Almeida; Baptista, 2019; Rizzo *et al.*, 2021).

O comportamento espectral do solo tem sido avaliado com sucesso nas últimas décadas, sendo essencial para isso aplicar metodologias que possibilitem interpretar adequadamente o espectro do solo. A análise descritiva da assinatura espectral é imprescindível para a caracterização do solo, a sua aplicação é baseada na observação de alguns aspectos na curva espectral, como: intensidade de reflectância (albedo), características de absorção (profundidade e amplitude) e forma espectral. A avaliação de alterações na curva permite diferenciar os solos de acordo com sua intensidade de reflectância (Demattê, 2002).

A espectroscopia de reflectância tem possibilitado estimar importantes propriedades do solo, tendo ocorrido nos anos de 1960 a determinação de diversos padrões de curvas espectrais do solo, as quais apresentaram grande relação com seus constituintes (Meneses; Almeida; Baptista, 2019). Nessa perspectiva, a espectroscopia vem sendo bastante empregada para avaliar os teores de argila, areia e carbono no solo (Rizzo *et al.*, 2021).

O carbono orgânico do solo foi estimado com sucesso por Ribeiro *et al.* (2021) usando a reflectância espectral e métodos de regressão, tendo o método de mínimos quadrados parciais alcançado a predição mais robusta. Já a textura do solo foi predita por Coblinski *et al.* (2020) a partir da análise da assinatura espectral, tendo sido observado que a previsão da textura foi mais precisa quando se combinou profundidades de avaliação.

Em estudo para avaliar a eficácia do vis-NIR-SWIR e MIR na caracterização e predição de alguns atributos do solo, Naimi *et al.* (2022) verificaram que o Vis-NIR-SWIR alcançou resultados melhores para textura do solo que o MIR. Contudo, essas faixas não possibilitaram prever a salinidade do solo. Já para os minerais, a predição é possível a partir da associação da espectroscopia com a regressão linear múltipla (Demattê; Terra, 2014). As feições de absorção dos minerais podem ser observadas na faixa vis-NIR-SWIR, todavia, as principais feições e outras características estão no MIR (Silvero *et al.*, 2020).

A espectroscopia gera inúmeros dados espectrais que são organizados em um grande banco de dados, chamado de biblioteca espectral. Atualmente, existem no mundo diversas bibliotecas espectrais que reúnem dados de solos de diferentes países. No Brasil, a biblioteca Brazilian Soil Spectral Library (BSSL) teve início em 1995 visando criar um banco de dados dos solos do país a partir de uma rede de colaboradores (Demattê *et al.*, 2019).

2.4 Fatores que influenciam o comportamento espectral do solo

O comportamento espectral do solo é influenciado por constituintes minerais e orgânicos, como a matéria orgânica, filossilicatos, óxidos, umidade e a distribuição granulométrica (Dalmolin *et al.*, 2005). Esses atributos são classificados como relações espectrais de primeira ordem e influenciam diretamente o espectro, modificando a intensidade de reflectância e as características de absorção (Terra *et al.*, 2021).

2.4.1 Efeito da matéria orgânica, mineralogia, umidade e granulometria

A matéria orgânica do solo (MOS) é formada por uma mistura complexa de substâncias de carbono com diferentes características físicas e químicas. No solo há predomínio de material orgânico nas camadas superficiais, ao passo que nas camadas subsuperficiais a concentração de matéria orgânica é menor, uma vez que na superfície do solo há aporte constante, tanto pela deposição de material vivo, como pela decomposição. Esse material é um constituinte primário da coloração, de modo a alterar a cor da matriz edáfica, possui estreita relação com a reflectância do solo. Quando o material orgânico aumenta, a energia refletida do solo diminui, visto que a matéria orgânica absorve energia (Madeira Netto; Baptista, 2000; Sousa Junior *et al.*, 2008).

O efeito da matéria orgânica na assinatura espectral do solo pode ser verificado pela sua remoção da composição pedológica, o que promove aumento do fator de reflectância (Demattê; Epiphânio; Formaggio, 2003). Todavia, ressalta-se que a modificação da reflectância pela remoção da matéria orgânica tende a ser mais perceptível nos solos de textura mais grosseira, quando comparados aos de textura mais argilosa, em virtude da formação de uma camada orgânica protetora ao redor das partículas grosseiras. Assim, nos solos arenosos há diminuição da reflectância com a presença da matéria orgânica (Demattê *et al.*, 2005).

A influência do material orgânico é tão forte na reflectância do solo que pode até mesmo mascarar a ação de outros constituintes sobre o espectro, conforme verificado por Demattê *et al.* (2006) em que o horizonte A do solo exibiu menor reflectância e bandas de absorção mais atenuadas em relação aos horizontes subsuperficiais, devido a maior concentração desse material na superfície. A MOS pode mascarar os efeitos dos óxidos de ferro do solo e afetar as bandas de absorção deste constituinte e, conseqüentemente, interferir na resposta espectral (Demattê; Epiphânio; Formaggio, 2003).

Além do teor de matéria orgânica, a sua composição também influencia a reflectância do solo. Estudos evidenciam que a variação de reflectância entre solos com teor semelhante de matéria orgânica se deve às diferentes composições do material, contudo, esta hipótese não tem confirmação experimental. Apesar disso, análises espectrais de laboratório indicam que as características de reflectância dos ácidos húmicos e fúlvicos são diferentes, embora essas relações não sejam bem compreendidas (Meneses; Almeida; Baptista, 2019).

Com relação aos minerais, a caracterização mineralógica tem grande importância na avaliação da assinatura espectral dos solos, uma vez que os minerais conferem várias feições de absorção e influenciam o albedo (Dalmolin *et al.*, 2005). Tendo em vista que o solo é um sistema complexo, pode ocorrer mistura de minerais, em que as bandas de absorção ficam muito próximas ou até se apresentam sobrepostas. Diante disso, para caracterizar esses materiais é preciso observar a dissimetria existente na curva, a profundidade das bandas de absorção e a presença de absorções secundárias (Meneses; Almeida; Baptista, 2019).

A resposta espectral dos minerais varia em função de sua composição. Minerais transparentes como o quartzo, possuem alta intensidade de reflectância por não absorverem energia (Rizzo *et al.*, 2021). Os minerais de argila do tipo filossilicato, que são divididos quanto a sua estrutura em 2:1 e 1:1, apresentam bandas de absorção, principalmente, em três comprimentos de onda do SWIR: 1400, 1900 e 2200 nm. Em geral, estas feições estão ligadas à transição do modo vibracional de um estado de energia para outro nível de energia (*overtones*) e às combinações de vibrações fundamentais do MIR (Genú *et al.*, 2010).

O argilomineral do tipo 1:1 mais comumente encontrado nos solos tropicais é a caulinita, suas principais feições de absorção estão associadas às vibrações moleculares das hidroxilas, as quais são mais visíveis nos comprimentos de onda de 1400 e 2200 nm. (Madeira Netto; Baptista, 2000). Já os argilominerais do tipo 2:1, como por exemplo, as esmectitas, são típicos de solos menos intemperizados. Demattê *et al.* (2006) verificaram em um Vertissolo que houve predomínio de esmectita como filossilicato do tipo 2:1, tendo sido a feição caracterizada por picos de absorção em 1400 e 1900 nm. Na faixa do MIR as feições dos argilominerais ocorrem entre $3620\text{--}3484\text{ cm}^{-1}$ (Terra *et al.*, 2021).

De modo semelhante aos argilominerais 2:1 e 1:1, os óxidos de ferro, também possuem grande influência no comportamento espectral dos solos (Cezar *et al.*, 2013). A goethita e a hematita são óxidos frequentemente encontrados nos solos tropicais e subtropicais, e são oriundos da oxidação do ferro (Fe^{+2}) presentes nos minerais primários durante a formação do solo. Esses óxidos possuem diferentes características de absorções espectrais nas faixas do ultravioleta e do vis-NIR (Meneses; Almeida; Baptista, 2019).

A hematita e a goethita estão fortemente ligadas à cor do solo e exibem respostas espectrais em comprimentos de onda diferentes em virtude de suas características estruturais específicas (Genú *et al.*, 2010). Suas feições de absorção são caracterizadas pelas posições centrais em torno de 480 nm para goethita e 513 nm para hematita e pelas variações de intensidade e amplitude das feições (Demattê; Terra, 2014). As feições espectrais desses óxidos observadas no espectro vis-NIR estão principalmente ligadas a interações entre a radiação e os íons na estrutura cristalina dos óxidos (Rizzo *et al.*, 2021).

Outros minerais que pertencem ao grupo de óxidos de Fe é a magnetita e a ilmenita, que são considerados como minerais acessórios. Esses óxidos possuem feições espectrais chamadas de opacas e os seus valores de reflectância, geralmente, são menores que 5% no espectro Vis-NIR; com isso, sua presença no solo reduz a intensidade de reflectância. Além disso, os solos tropicais possuem óxidos de alumínio, sendo a gibsitita o mais comum. Sua principal feição espectral ocorre em 2265 nm (Madeira Netto; Baptista, 2000) e entre $3529\text{--}3394\text{ cm}^{-1}$, devido à vibração molecular das hidroxilas (Mendes *et al.*, 2022).

No que se refere ao efeito da água sobre o espectro, os solos úmidos possuem aparência mais escura do que quando estão secos. Tal fato é resultado das características de absorção da água que causam redução na reflectância da radiação incidente no espectro (Epiphanyo *et al.*, 1992). O aumento do teor de umidade do solo reduz a reflectância devido às reflexões internas no filme de água que recobre as partículas do solo; por isso, os solos úmidos possuem aparência mais escura (Dewitte *et al.*, 2012).

A água presente no solo é responsável pela redução do albedo em todas as regiões do espectro. A reflectância do solo é afetada pelas bandas de absorção centradas no espectro em 760, 970, 1.190, 1.450 e 1.940 nm (Madeira Netto; Baptista, 2000). Contudo, ressalta-se que, de modo geral, não ocorrem grandes alterações na forma das curvas espectrais em função da mudança de umidade, com exceção das feições típicas de absorção de água em 1400 e 1900 nm (Dalmolin *et al.*, 2005).

A água é considerada um dos atributos que possui maior interferência nos dados espectrais em virtude do efeito que possui sobre a reflectância (Demattê *et al.*, 2006). Desse modo, a umidade do solo pode afetar a sua assinatura espectral, conforme foi verificado por Silvero *et al.* (2020) em estudo do efeito da água, da matéria orgânica e de formas de Fe no espectro do infravermelho médio. Os autores observaram que a adição de água ao solo mascarou diversas características de absorção e promoveu redução da intensidade de reflectância de 3700 cm^{-1} para 2700 cm^{-1} no MIR.

Quanto ao efeito da granulometria, a reflectância do solo é afetada pelo tamanho e

arranjo que as partículas assumem em relação ao ar e a água do solo (Epiphanyo *et al.*, 1992). Nesse sentido, a intensidade de reflectância varia em função da distribuição do tamanho das partículas, da estrutura e da sua rugosidade (Rizzo *et al.*, 2021). A ocorrência de superfícies mais rugosas no solo aumenta o sombreamento e a reflectância, atenuando a intensidade do espectro. Por outro lado, a redução da rugosidade da superfície promove ligeiro aumento da reflectância (Dewitte *et al.*, 2012).

Em regra, o tamanho das partículas do solo possui relação inversa com a reflectância, de modo que quanto menor o tamanho das partículas maior será o albedo (Meneses; Almeida; Baptista, 2019). Tal fato ocorre em virtude de os grãos maiores produzirem superfícies mais irregulares, com sombreamentos e maior retroespalhamento interno da luz, enquanto partículas menores criam superfícies mais uniformes, com menor quantidade de poros para reter a luz incidente (Sousa Junior *et al.*, 2008).

Já quando se refere à composição das partículas, solos que possuem menor teor de argila, ou seja, com predominância de areia, apresentam maior valor de energia refletida, enquanto solos com maior quantidade de argila possuem baixo albedo (Demattê; Terra, 2014). Esse efeito das partículas primárias no comportamento espectral foi constatado por Sousa Junior *et al.* (2008), em que solos da mesma ordem taxonômica, contudo de classes texturais distintas, exibiram diferentes comportamentos espectrais, de modo que aqueles com textura mais arenosa apresentaram maior albedo ao longo da curva espectral.

Além do efeito da granulometria sobre o espectro, o comportamento espectral do solo é influenciado pelos minerais que compõem as partículas argila e areia. A baixa reflectância de solos argilosos é resultado, especialmente, da maior formação de agregados no solo e da presença de minerais opacos, o que promove maior absorção da energia incidente (Bellinaso *et al.*, 2010). Para solos arenosos, a maior intensidade da reflectância ocorre em virtude da sílica presente no mineral quartzo (Terra *et al.*, 2018).

2.5 Processamento de dados espectrais e estimativa dos atributos do solo

As análises espectrais produzem uma grande quantidade de dados acerca do solo. Diante disso, metodologias têm sido aplicadas para extrair informações úteis do espectro. As técnicas de pré-processamento dos dados brutos são comumente usadas a fim de se aumentar a eficiência das análises e de reduzir o elevado número de dados, os quais podem prejudicar o potencial dos modelos de predição dos atributos (Souza; Madari; Guimarães, 2012).

As técnicas de pré-processamento auxiliam na melhoria da interpretação da

assinatura espectral e na obtenção de modelos preditivos mais precisos, por meio da redução do ruído no espectro, melhoraria das feições espectrais relacionadas aos atributos do solo, remoção dos efeitos de espalhamento de luz e diminuição da dimensionalidade dos dados. Dentre as técnicas mais usadas pode-se citar: transformação em absorbância, correção de espalhamento multiplicativo, variação normal padrão, transformação de Savitzky-Golay, filtros de média móvel, remoção de contínuo e correção de linha de base (Rizzo *et al.*, 2021).

Ressalta-se que não existe um método de pré-processamento único que seja tido como ideal para qualquer situação. O emprego das técnicas de processamento pode até mesmo não promover nenhuma melhoria no desempenho preditivo, conforme constatado por Mendes *et al.* (2022), em que os modelos de predição com dados pré-processados ou com dados de infravermelho médio brutos não exibiram diferenças razoáveis, indicando que os espectros processados não conseguiram reduzir a relação sinal-ruído.

Após o pré-processamento dos dados espectrais, realiza-se a divisão do conjunto de informações visando desenvolver os modelos de predição. As amostras são separadas em dois grupos: um destinado a treinar o modelo e outro a testar. Normalmente, utiliza-se cerca de 70% dos dados para o treinamento e 30% para teste. A etapa de treinamento tem como finalidade construir um modelo empírico multivariado capaz de associar os dados espectrais às características do solo de interesse, possibilitando a predição dos atributos (FAO, 2022).

Nos dados selecionados para treinamento, aplicam-se métodos estatísticos que permitem aos modelos estimar quantitativamente os atributos. Essa análise fundamenta-se na hipótese de que há uma relação direta entre a concentração de determinado constituinte e uma propriedade espectral correspondente. A relação matemática formada entre esses dois fatores é denominada de equação de calibração, a qual é gerada a partir dos dados de treinamento e usada para estimar a concentração de novas amostras, desde que os espectros que sejam obtidos em equipamentos e condições semelhantes (Meneses; Almeida; Baptista, 2019).

A modelagem de calibração é desenvolvida a partir das relações entre os atributos do solo, determinados em análises laboratoriais tradicionais, e os dados obtidos nas análises espectrais. Essa calibração é feita por meio de métodos de regressão multivariada ou de aprendizado de máquina, como *random forest*, redes neurais e *deep learning*, entre outros. Dentre as técnicas de estatística multivariada destacam-se a regressão linear múltipla (MLR), a regressão por componentes principais (PCR) e a regressão por mínimos quadrados parciais (PSLR) (Meneses; Almeida; Baptista, 2019; Shepherd *et al.*, 2022).

Os modelos desenvolvidos para a predição de atributos do solo possibilitam estimar variações em sua composição, sendo o desempenho dessas predições influenciado

pela população amostral e pela representatividade dos dados analisados. Conforme observaram Paiva *et al.* (2022) que, de modo geral, os modelos calibrados com conjunto de dados locais apresentaram melhor desempenho do que aqueles com amostras regionais ou nacionais. Esses resultados sugerem que, independentemente do número de amostras, a qualidade e representatividade dos dados são imprescindíveis para gerar modelos confiáveis.

O desempenho dos modelos é avaliado por meio de parâmetros estatísticos, como o erro médio (ME), a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação (R^2) (FAO, 2022). Outro indicador amplamente empregado na avaliação de modelos preditivos é a razão de desempenho para intervalo interquartil (RPIQ). Na literatura ainda não há um valor crítico definido para o RPIQ; com isso, têm sido adotadas referências baseadas no parâmetro razão de desempenho do desvio (RPD). De modo geral, valores elevados de R^2 e RPIQ, associados a valores reduzidos de RMSE, indicam previsões com qualidade de boa à excelente (Luce *et al.*, 2022).

3 CAPÍTULO I - CARACTERIZAÇÃO ESPECTRAL DO VISÍVEL AO INFRAVERMELHO MÉDIO DE SOLOS DO NORDESTE BRASILEIRO

RESUMO

O solo é um recurso essencial para a vida, tornando indispensável sua caracterização e a identificação da distribuição espacial. A espectroscopia de reflectância é uma ferramenta eficaz para potencializar a caracterização e auxiliar na classificação de solos, especialmente em países de grandes dimensões. Nesse sentido, o objetivo deste trabalho foi explorar o potencial dos espectros vis-NIR-SWIR e MIR para caracterizar solos do Nordeste brasileiro quanto aos seus comportamentos espectrais, bem como identificar variações espectrais e similaridades dos perfis de solo pertencentes a diferentes classes. Foram avaliadas 114 amostras de 24 perfis de solos oriundos de municípios do Ceará. O solo foi avaliado com metodologia convencional de química úmida para determinar os atributos físicos e químicos, e com metodologia espectral para avaliar sua reflectância nas faixas do visível, infravermelho próximo, infravermelho de ondas curtas (vis-Nir-SWIR) e infravermelho médio (MIR). Os dados espectrais foram pré-processados por meio da suavização com o filtro Savitzky-Golay, e o comportamento espectral das curvas foi caracterizado por perfil de solo. Foi avaliada a distribuição de frequência das classes pedológicas, e os resultados das análises convencionais foram submetidos à estatística descritiva. Além disso, foi realizada a análise de correlação multivariada entre os atributos do solo e os valores de reflectância espectral suavizados. A análise de componentes principais (ACP) foi efetuada nos dados espectrais visando reduzir a dimensão dos dados no espaço multivariado. Em seguida, com os escores resultantes da ACP foi feita a análise de agrupamento usando o algoritmo de classificação não supervisionada Fuzzy K-médias. Os Neossolos e Argissolos foram os solos com maior representação nesse estudo. O comportamento espectral dos perfis apresentou padrões distintos em função da ordem de solo. A classificação não supervisionada agrupou amostras com base nas características dos horizontes. A faixa vis-NIR-SWIR distinguiu seis classes de espectros do solo, ao passo que na faixa MIR houve a separação em nove classes de espectros. Esse estudo comprova a eficiência da espectroscopia na caracterização e distinção de classes de solo.

Palavras-chave: espectroscopia; comportamento espectral; agrupamento; horizonte do solo.

ABSTRACT

Soil is an essential resource for life, making its characterization and spatial distribution identification indispensable. Reflectance spectroscopy is an effective tool for enhancing characterization and assisting in soil classification, especially in large countries. In this sense, the objective of this study was to explore the potential of vis-NIR-SWIR and MIR spectra to characterize soils in Northeast Brazil in terms of their spectral behavior, as well as to identify spectral variations and similarities in soil profiles belonging to different classes. A total of 114 samples from 24 soil profiles from municipalities in Ceará were evaluated. The soil was evaluated using conventional wet chemistry methodology to determine its physical and chemical attributes, and spectral methodology to evaluate its reflectance in the visible, near-infrared, short-wave infrared (vis-Nir-SWIR), and mid-infrared (MIR) ranges. The spectral data were preprocessed using Savitzky-Golay smoothing, and the spectral behavior of the curves was characterized by soil profile. The frequency distribution of the soil classes was evaluated, and the results of the conventional analyses were subjected to descriptive statistics. In addition, multivariate correlation analysis was performed between soil attributes and smoothed spectral reflectance values. Principal component analysis (PCA) was performed on the spectral data to reduce the dimension of the data in the multivariate space. Then, with the scores resulting from the PCA, cluster analysis was performed using the unsupervised Fuzzy K-means classification algorithm. Neosols and Argisols were the most represented soils in this study. The spectral behavior of the profiles showed distinct patterns depending on the soil order. The unsupervised classification grouped samples based on the characteristics of the horizons. The vis-NIR-SWIR band distinguished six classes of soil spectra, while the MIR band separated them into nine classes. This study proves the efficiency of spectroscopy in characterizing and distinguishing soil classes.

Keywords: spectroscopy; spectral behavior; clustering; soil horizon.

3.1 Introdução

O solo possui papel essencial para a existência da vida na Terra, desenvolvendo uma ampla gama de serviços ecossistêmicos e atuando como um recurso básico para diversas atividades humanas. Dada à importância desse recurso natural, existem na atualidade diversas aplicações que demandam um elevado volume de informações edáficas com alta resolução (Ge; Wadoux; Peng, 2022). Diante disso, é cada vez mais indispensável caracterizar o solo e conhecer sua distribuição espacial, visando promover o uso sustentável e o manejo adequado.

Tradicionalmente, o solo é caracterizado por meio de análises laboratoriais de química úmida, as quais servem de base para a classificação pedológica. Contudo, tais análises são onerosas, demoradas e possuem potencial de causar contaminação ambiental pela geração de resíduos perigosos (Mendes *et al.*, 2022). Essas limitações são ainda mais intensificadas no contexto dos solos brasileiros. Por ser o maior país da América do Sul e o quinto maior do mundo, o Brasil enfrenta um grande desafio para a caracterização e o mapeamento pedológico de sua extensa área territorial (Demattê *et al.*, 2019).

Nessa perspectiva, a espectroscopia de reflectância tem se destacado como alternativa promissora e um método eficiente em estudos de gênese, monitoramento e gestão do solo (Taghdis; Farpoor; Mahmoodabadi, 2022). Esta técnica possibilita estimar simultaneamente os atributos físicos, químicos e mineralógicos a partir de uma única leitura espectral, permitindo a aquisição rápida de dados do solo, de forma não destrutiva e sem o uso de reagentes químicos (Ge; Wadoux; Peng, 2022). Deste modo, se consolida como uma tecnologia eficiente, de baixo custo e ambientalmente sustentável.

A análise do solo com espectroscopia é realizada nas faixas do visível (vis: 350-750 nm), do infravermelho próximo (NIR: 750-1100 nm), do infravermelho de ondas curtas (SWIR: 1100-2500 nm) e do infravermelho médio (MIR: 2500-25000 nm ou 4000-400 cm^{-1}) (Mendes *et al.*, 2022). Nestas regiões, as assinaturas espectrais possuem relação direta com a composição e a estrutura molecular dos componentes do solo, o que torna possível identificar e quantificar os atributos pedológicos (Rizzo *et al.*, 2021).

Diante desse contexto, a espectroscopia se fortalece como ferramenta eficaz para caracterizar e auxiliar na classificação dos solos, e como técnica particularmente benéfica em países de grandes dimensões, como o Brasil, cuja demanda por levantamentos pedológicos em larga escala exige metodologias rápidas e de alta capacidade. O território brasileiro, por sua vez, abriga uma grande variedade de solos, sendo a região Nordeste um nítido exemplo desta diversidade pedológica. Esta região abriga diferentes biomas, destacando-se a Caatinga, o

único bioma exclusivamente brasileiro. Sob um clima semiárido e com forte exploração, os solos deste ecossistema são muito susceptíveis à degradação (Souza; Leite; Medeiros, 2021).

A Caatinga hospeda desde solos muito intemperizados até pouco evoluídos, sendo comum a ocorrência de solos pouco profundos e com baixo desenvolvimento, formados principalmente por processos pedogenéticos de argiluviação, salinização e sodificação (Souza, *et al.*, 2022). Todavia, do ponto de vista científico, esses solos são subexplorados. O uso da espectroscopia de reflectância em estudos pedológicos no semiárido brasileiro ainda é incipiente, sobretudo na faixa do infravermelho médio, cujo potencial para a predição de atributos é pouco investigado (Santos *et al.*, 2020). Assim, persiste uma lacuna expressiva em estudos relativos à pedologia espectral, especialmente em ambientes semiáridos (Taghdis; Farpoor; Mahmoodabadi, 2022).

Diante destes aspectos, a aplicação de técnicas espectrais em uma região com elevada heterogeneidade pedológica, como o Nordeste brasileiro, representa uma oportunidade estratégica de promoção da conservação do solo e de avanço metodológico. Neste sentido, parte-se da hipótese de que é possível discriminar ordens de solos baseado em espectros de reflectância nas faixas do visível ao infravermelho médio, uma vez que estes contêm feições espectrais associadas a atributos relevantes para a classificação pedológica.

3.1.1. Objetivos

O objetivo principal deste trabalho foi explorar o potencial dos espectros de reflectância vis-NIR-SWIR e MIR para caracterizar solos do Nordeste brasileiro quanto aos seus comportamentos espectrais, bem como identificar variações espectrais e similaridades dos perfis de solo pertencentes a diferentes classes.

Como objetivos específicos foram almejados:

- Realizar uma descrição qualitativa das características espectrais dos solos;
- Determinar faixas espectrais com maior expressão para os atributos pedológicos;
- Identificar grupos de solos com características espectrais semelhantes.

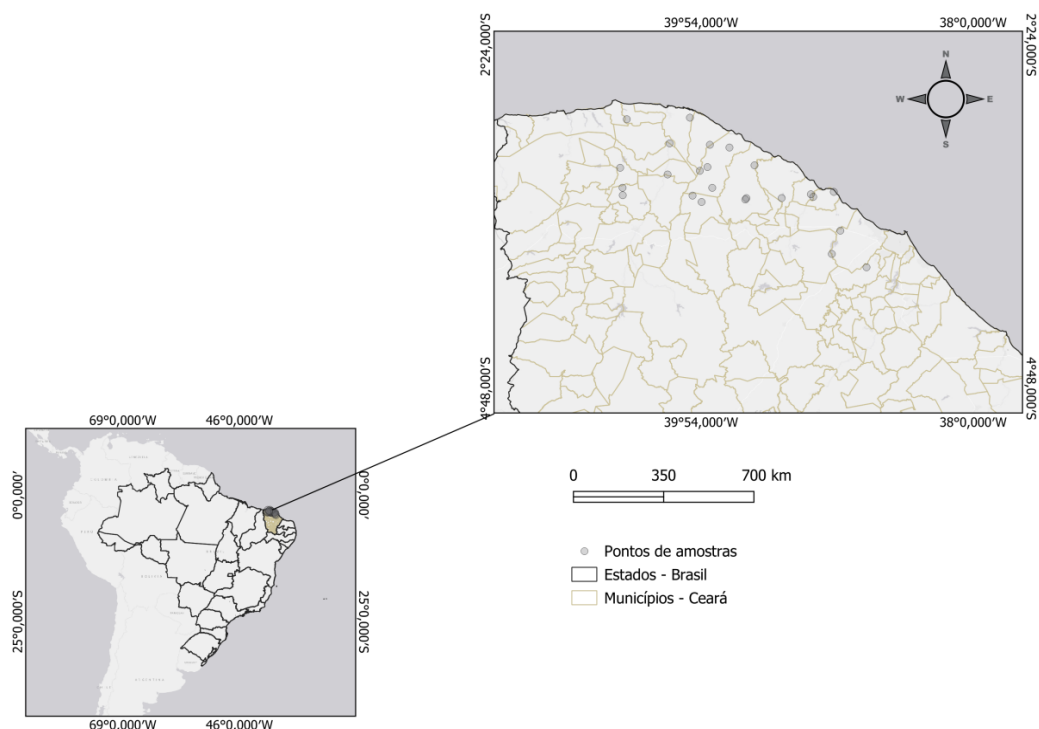
3.2 Material e métodos

Esta seção apresentará o banco de dados avaliado, a metodologia empregada para as análises dos solos e as técnicas estatísticas aplicadas visando à avaliação dos dados gerados.

3.2.1 Área de estudo e banco de dados do solo

As amostras de solos utilizadas neste estudo compõe o Levantamento de reconhecimento de média intensidade dos solos do Estado do Ceará (2024), o qual reúne informações detalhadas dos perfis de solos analisados. Os solos integram a área 7 do estudo e são oriundos de 13 municípios do Ceará que estão situadas nas mesorregiões Noroeste Cearense, Norte Cearense e Metropolitana de Fortaleza (Figura 1).

Figura 1 – Mapa da área de estudo localizada no estado do Ceará, Brasil



Fonte: elaborada pela autora.

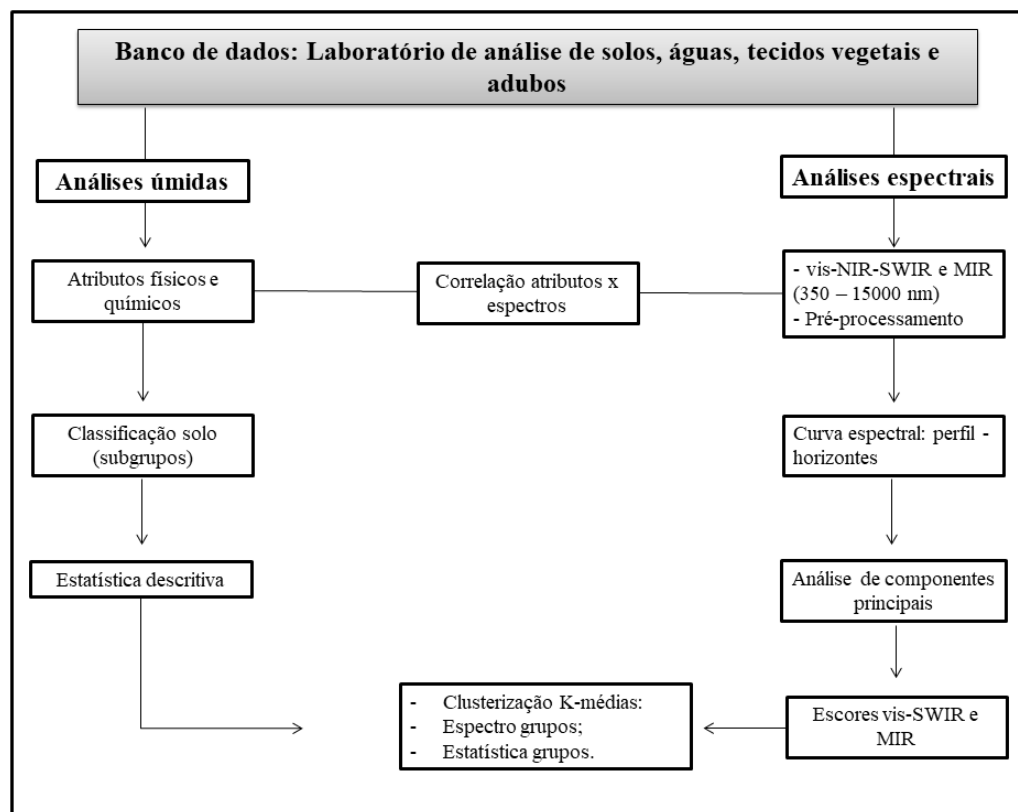
Os solos foram coletadas na última etapa do Levantamento. No total, foram avaliadas 114 amostras correspondentes aos horizontes dos solos, provenientes de 24 perfis pedológicos, os quais representavam os solos de maior ocorrência no Nordeste. Estes perfis compreendem 9 ordens de solo e foram classificados até o quarto nível categórico do Sistema Brasileiro de Classificação do Solo (Santos *et al.*, 2018), sendo esta etapa conduzida pela equipe responsável pela realização do Levantamento de solos. Posteriormente, os perfis foram reclassificados para o Sistema Brasileiro de Classificação do Solo (Santos *et al.*, 2025), visando apresentar neste estudo a versão mais recente da classificação dos solos.

Os materiais de solo avaliados foram adquiridos no acervo do Laboratório de Análises de Solos, Águas, Tecidos e Adubos - Convênio FUNCEME/UFC, localizado no

Departamento de Ciência do Solo da Universidade Federal do Ceará (UFC). As análises de química úmida foram realizadas pela equipe técnica do referido laboratório. Já as análises espectrais foram conduzidas pelos pesquisadores deste estudo. A faixa vis-NIR-SWIR foi avaliada no Laboratório de Geoprocessamento do Departamento de Engenharia Agrícola, enquanto a faixa MIR foi processada no Laboratório Multiaparelhos do Departamento de Ciência do Solo. Ambos os laboratórios situam-se no Campus Pici, UFC.

Um resumo com as etapas metodológicas das análises realizadas neste estudo pode ser visualizado na Figura 2. O detalhamento de cada etapa será apresentado posteriormente na seção de metodologia das análises.

Figura 2 - Fluxograma da metodologia de trabalho para as análises do solo



Fonte: elaborada pela autora.

3.2.2 Análises laboratoriais úmidas

Para iniciar as análises, as amostras de solo foram dispostas na sombra e ao ar para secagem, posteriormente foram destorroadas e tamisadas em peneira com malha de abertura de 2 mm, para obtenção da terra fina seca ao ar (TFSA). Após a aquisição da TFSA, as amostras foram avaliadas com a metodologia tradicional de química úmida e por

espectroscopia de reflectância.

As análises tradicionais foram realizadas conforme a metodologia do Manual de Métodos de Análise de Solo da Embrapa (Teixeira *et al.*, 2017), tendo sido avaliado 12 atributos do solo. Para os atributos químicos, o carbono orgânico foi determinado por oxidação com dicromato de potássio; o nitrogênio total foi analisado pela oxidação com ácido sulfúrico; o cálcio e magnésio trocáveis foram extraídos com solução de KCl; o potássio e sódio trocáveis foram extraídos com *Mehlich 1*; o pH foi determinado em água, com relação solo-água de 1:2,5; a condutividade elétrica (CE) foi avaliada a partir da pasta de saturação do solo; e a percentagem de saturação por sódio (PST) foi calculada a partir dos valores de sódio e de capacidade de troca de cátions.

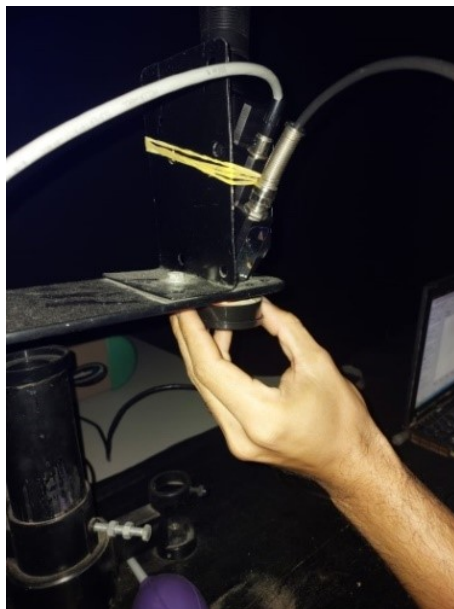
Para os atributos físicos, a granulometria do solo (argila, silte e areia) foi determinada com o método da pipeta realizando a dispersão da amostra, seguida da separação das frações do solo por peneiramento e da sedimentação das partículas em meio líquido.

3.2.3 Análise espectral

Para realizar as análises espectrais do solo, as amostras de terra fina seca ao ar foram submetidas ao processo de secagem em estufa com circulação forçada de ar em temperatura de 45°C durante 24 horas, a fim de homogeneizar os efeitos da umidade do solo (Demattê *et al.*, 2014). Os dados espectrais vis-NIR-SWIR e MIR foram obtidos por meio de metodologias distintas.

As amostras de solo para leitura espectral na faixa vis-NIR-SWIR foram acondicionadas em recipiente de polipropileno preto, com 5 cm de diâmetro e 1,5 cm de altura. Os dados espectrais de reflectância bidirecional foram obtidos com o auxílio de uma sonda de contato (*Hi-Brite Contact Probe*) e de um espectrorradiômetro FieldSpec Pro FR 3 (Analytical Spectral Devices, Boulder, Colorado, USA) (Figura 3). Esse equipamento realiza leituras na faixa do visível ao infravermelho de ondas curtas (350 – 2500 nm), com resolução espectral de 3 nm e 10 nm reamostrados para 1nm, e um campo de visão de 25°.

Figura 3 – Equipamento de aquisição dos dados espectrais vis-NIR-SWIR



Fonte: A autora.

Para a aquisição dos dados espectrais vis-NIR-SWIR foi realizada a calibração do sensor com uma placa branca (Spectralon), a qual é considerada como padrão de referência de 100% de reflectância e é empregada no cálculo do fator de reflectância bidirecional (FRB). A calibração foi efetuada a cada 20 minutos por meio da leitura da placa padrão. Foram realizadas três leituras em diferentes pontos da superfície do material, de modo que a amostra foi girada aproximadamente 120° entre cada leitura para se obter uma boa representatividade. Com isso, cada amostra foi caracterizada pela média aritmética simples das três leituras.

Para a leitura espectral na faixa MIR foi necessário efetuar uma etapa extra de preparo do solo visando obter partículas mais finas. Para tanto, antes da secagem das amostras em estufa foi realizada uma trituração adicional em almofariz de ágata. A leitura no infravermelho médio foi feita usando o infravermelho com transformada de Fourier FTIR Cary 630 (Agilent Technologies) equipado com c difusa (DRIFTS). O equipamento executa leituras espectrais na faixa MIR de 2500 a 15000 nm (4000 a 650 cm^{-1}), com resolução espectral $\leq 2 \text{ cm}^{-1}$ e abriga internamente os componentes ópticos mais importantes, como o laser, fonte de luz e detector (Figura 4).

Figura 4 – Equipamento FTIR Cary 630 para aquisição de dados espectrais MIR



Fonte: A autora.

As amostras de solo foram lidas em triplicata para a obtenção de dados espectrais na faixa MIR, sendo a reflectância da amostra obtida pela média simples das três repetições. Para cada leitura foi utilizado aproximadamente 1 cm^3 de solo, que foi colocado em um suporte próprio do acessório DRIFTS. Antes de cada medida foi efetuada a calibração do sensor, por meio da leitura da placa de referência que está posicionada na primeira posição do suporte. A referência consiste de um espelho dourado de reflectância difusa que auxilia na remoção da radiação de *background* do espectro (Figura 5).

Figura 5 - Suporte do acessório DRIFTS com espelho de referência e amostras de solo



Fonte: A autora.

Após a obtenção dos espectros, os dados de reflectância bruta foram submetidos ao pré-processamento de filtragem (suavização) Savitzky-Golay (SG), a fim de suavizar os ruídos do espectro (Savitzky; Golay, 1964). O emprego dessa técnica resultou na perda das cinco janelas iniciais e finais das faixas espectrais avaliadas, de modo que a região vis-NIR-

SWIR apresentou 2141 feições e a faixa MIR exibiu 1788 feições.

O comportamento espectral dos 24 perfis coletados, bem como cada horizonte do perfil, foi analisado individualmente. A análise foi realizada baseando-se na metodologia de interpretação morfológica do espectro de reflectância, descrita por Demattê *et al.* (2014). Nesse sentido, foram avaliados os seguintes critérios: intensidade da curva espectral, forma geral da curva ao longo do espectro, características de absorção e comparação das curvas entre horizontes do mesmo perfil pedológico.

3.2.4 Análise estatística

As análises estatísticas, o processamento espectral e a elaboração dos gráficos foram realizados no software R (R Core Team, 2024). A distribuição de frequência das classes pedológicas foi computada para determinar a proporção das ordens de solos estudadas. Em seguida, os resultados das análises físicas e químicas convencionais foram submetidos à estatística descritiva, avaliando-se os dados por classe de solos.

Foi avaliada, também, a normalidade dos atributos por meio do teste de hipótese Shapiro-Wilk a 5%, e diante da não normalidade dos dados, aplicou-se a análise de correlação multivariada. A correlação foi realizada entre os atributos do solo e os valores de reflectância suavizados, visando avaliar a direção e a intensidade da interação entre os atributos estudados e as faixas espectrais.

3.2.5 Análise de componentes principais e agrupamento dos dados espectrais

A análise de componentes principais (ACP), com centro médio, foi aplicada nos dados espectrais vis-NIR-SWIR e MIR suavizados com o filtro SG. Essa análise foi realizada visando possibilitar a visualização de estruturas e padrões de distribuição dos dados e reduzir a dimensão dos dados no espaço multivariado para potencializar a análise de agrupamento.

Para a análise de agrupamento dos dados espectrais foi empregado o algoritmo de classificação não supervisionada Fuzzy K-médias (FKM). Este algoritmo foi aplicado sobre os cinco primeiros escores resultantes da ACP, a fim de se obter o agrupamento das amostras de solo e de verificar a existência de padrões de aglomeração. A técnica FKM confere um grau de associação (pertinência) fuzzy para cada amostra, baseando-se na distância ao centro do cluster. Os graus de associações variam de 0 a 1 (Costa *et al.*, 2022).

O número adequado de clusters na análise de agrupamento foi determinado com

base nos índices coeficiente de partição e entropia de partição (Bezdek, 1974). Esses índices de validade usam somente a pertinência dos padrões ao cluster para obter seu valor, sendo desejado para o coeficiente de partição valor mais próximo a zero e para o de entropia mais próximo a um (Pal; Bezdek, 1995). Os grupos gerados tiveram seus atributos físico-químicos analisados com estatística descritiva. Esta estatística dos grupos associada à análise dos autovetores resultantes da ACP, apoiaram a compreensão dos agrupamentos formados.

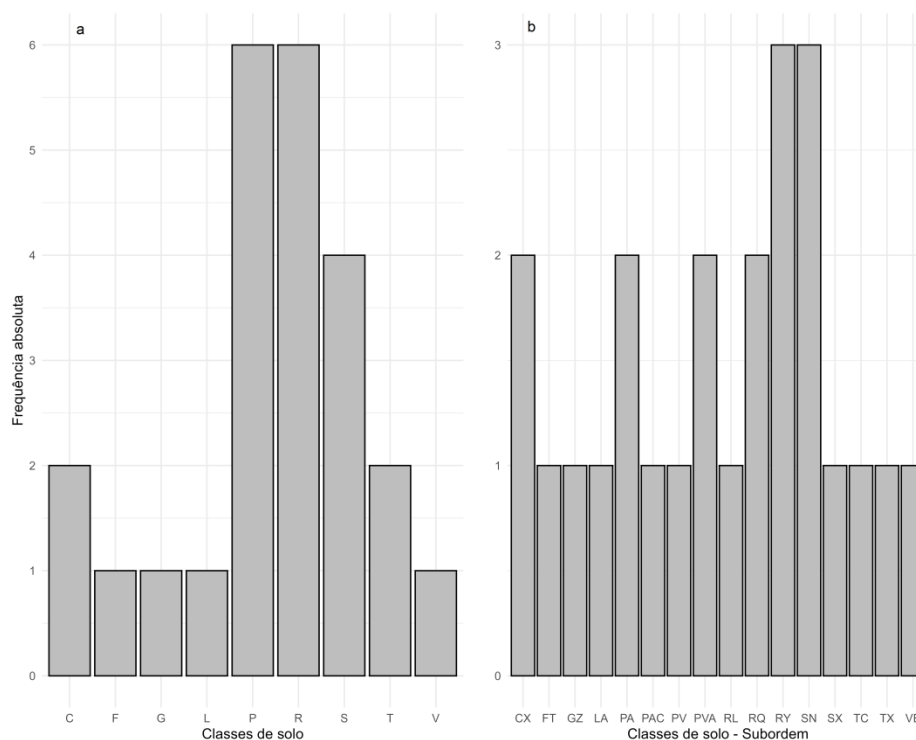
3.3 Resultados e discussão

Nesta seção serão caracterizados os atributos físico-químicos do conjunto de solos avaliado e o comportamento espectral de todos os 24 perfis pedológicos coletados, bem como será discutido o agrupamento dos solos nas faixas espectrais vis-NIR-SWIR e MIR.

3.3.1 Caracterização dos solos

As classes dos solos estudadas, classificadas até o 4º nível categórico (subgrupo), bem como os locais de coleta das amostras, estão disponíveis no Apêndice A. Os 24 perfis de solos analisados corresponderam às seguintes classes, com suas respectivas taxas de ocorrência: Neossolos (R) e Argissolos (P), destacando-se com 25% das ocorrências cada um, Planossolos (S) com 16,6% de ocorrência, Cambissolos (C) e Luvisolos (T) representando 8,3% cada, e Gleissolos (G), Latossolos (L), Plintossolos (F) e Vertissolos (V) corresponderam a 4,2% cada (Figura 6a). Quanto à subordem (Figura 6b), sobressaíram-se os Neossolos Flúvicos e Planossolos Nátricos.

Figura 6 – Análise da a) distribuição de frequência das ordens e b) subordens de solo



CX: Cambissolo Háplico; FT: Plintossolo Argilúvico; GZ: Gleissolo Sáfico; LA: Latossolo Amarelo; PA: Argissolo Amarelo; PAC: Argissolo Acinzentado; PV: Argissolo Vermelho; PVA: Argissolo Vermelho-Amarelo; RL: Neossolo Litólico; RQ: Neossolo Quartzarênico; RY: Neossolo Flúvico; SN: Planossolo Nátrico; SX: Planossolo Háplico; TC: Luvisso Crômico; TX: Luvisso Háplico; VE: Vertissolo Ebânico.

Fonte: A autora.

No contexto estadual, Neossolos e Argissolos são as duas principais classes de solos do Ceará (Levantamento de reconhecimento de média intensidade dos solos do Estado do Ceará, 2024). Já para a região Nordeste, as classes dominantes em ordem decrescente de ocorrência são os Latossolos, Neossolos, Argissolos, Planossolos, Luvisso, Plintossolos, Cambissolos e Gleissolos (Souza; Leite; Medeiros, 2021). Tais dados destacam a diversidade edáfica da região, marcada por solos em diferentes estágios de desenvolvimento, e reforçam a relevância desse estudo ao contribuir para a caracterização espectral dos principais solos.

A análise estatística da granulometria dos solos (Apêndice B), considerando os valores médios, evidenciou que o Neossolo apresentou textura arenosa, enquanto as demais classes se enquadraram no grupamento textural média (Santos *et al.*, 2025). Para os macronutrientes, com base nos valores máximos, as concentrações mais elevadas para Ca e Mg ($> 9 \text{ cmol}_c \text{ kg}^{-1}$) ocorreram no Gleissolo, Luvisso e Planossolo, e os teores mais altos de N ($> 3 \text{ g kg}^{-1}$) aconteceram no Argissolo, Cambissolo e Luvisso.

Quanto ao CO, as maiores concentrações ($> 10 \text{ g kg}^{-1}$) foram observadas nos Argissolo, Cambissolo, Luvisso e Plintossolo. No semiárido, os maiores teores de COT

(12,3 g kg⁻¹) são geralmente reportados em Cambissolos e Vertissolos (Souza; Leite; Medeiros, 2021). Contudo, o presente estudo avaliou apenas um perfil de Vertissolo, o qual apresentou baixo CO, contrastando a tendência regional.

O pH dos solos variou de fortemente ácido, com valor mínimo de 3,9 no Cambissolo, a moderadamente alcalino, atingindo 8,2 no Vertissolo. Em solos alcalinos, a elevada saturação por cátions básicos e/ou o acúmulo de sais é comumente observada, sobretudo em ambientes de várzeas com ocorrência de solos salinos (Araújo Filho *et al.*, 2022). Essa condição foi verificada no Vertissolo estudado, que apresentou, além de alcalinidade, alta concentração do cátion sódio e elevada condutividade elétrica.

No que se refere às características de salinidade e sodicidade do solo, foram avaliados os valores de condutividade elétrica (CE) e porcentagem de saturação por sódio (PST), empregados para identificar os solos afetados por sais e classifica-los em três categorias: salinos - CE > 4 dS m⁻¹ e PST < 15%; sódicos - CE < 4 dS m⁻¹ e PST > 15%; e salino-sódicos - CE > 4 dS m⁻¹ e PST > 15% (FAO, 2024). Com base nos valores máximos observados, o Gleissolo, Neossolo e Vertissolo foram enquadrados como salino-sódicos e os Planossolos foram classificados como sódicos.

Os resultados obtidos evidenciam que a sodicidade representa um grave problema para os solos do Nordeste brasileiro. O excesso de sódio trocável no solo ocasiona baixa estabilidade estrutural, permeabilidade reduzida e fraca aeração, além de favorecer a formação de crostas superficiais, fatores que limitam o crescimento radicular e o desenvolvimento das culturas (Hailu; Mehari, 2021). O acúmulo de sais nos solos dessa região compromete a sustentabilidade da produção agrícola local.

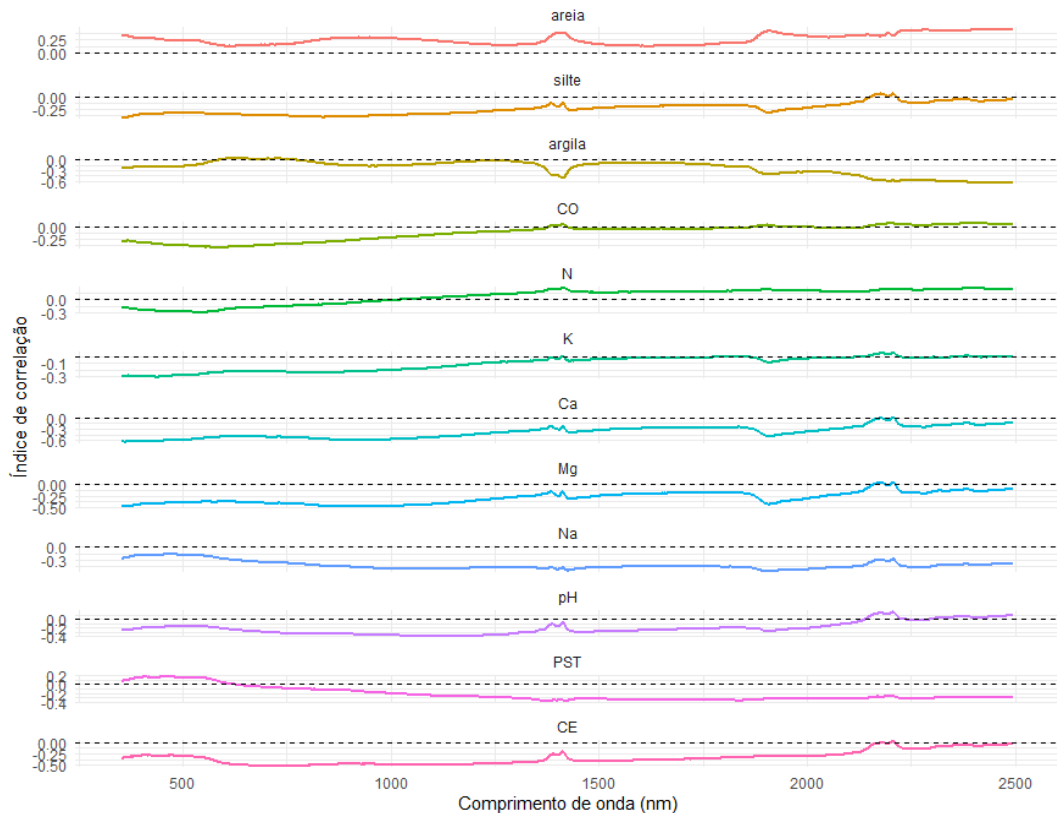
3.3.2 Correlação entre atributos do solo e faixas espectrais

A correlação de Spearman (ρ) foi utilizada devido a não normalidade dos dados. Esta análise mede a intensidade e a direção da relação entre duas variáveis, e é representada por um coeficiente que varia de -1 a +1. Coeficientes positivos ($\rho > 0$) indicam relação direta, enquanto valores negativos ($\rho < 0$) refletem relação inversa. A interpretação da magnitude das relações é feita em classes, conforme Mukaka (2012): coeficientes entre 0 e 0,3 (0 a -0,3) são considerados desprezíveis; entre 0,30 a 0,5 (-0,30 a -0,5), são baixos; entre 0,50 e 0,7 (-0,50 a -0,7), moderados; entre 0,70 e 0,9 (-0,7 a 0,9), altos; e > 0,9 (maior que -0,9), muito altos.

A análise de correlação de Spearman entre os atributos do solo e os dados espectrais vis-NIR-SWIR suavizados com o filtro SG evidenciou a predominância de relações

inversas, com exceção da areia, e amplitudes variando de desprezíveis a fracas (Figura 7).

Figura 7 – Correlação multivariada entre atributos do solo e a faixa espectral vis-NIR-SWIR



Fonte: A autora.

Entre os atributos físicos, a areia foi a única variável positivamente correlacionada com a reflectância, com destaque para as faixas 1898-1923 nm e 2220-2495 nm (ρ de 0,40 a 0,45), que apresentaram as correlações mais fortes, promovendo o aumento da reflectância. Em contrapartida, a argila e o silte exibiram correlações negativas ao longo do espectro. O silte exibiu os maiores coeficientes nas faixas 355-379 nm e 775-929 nm (ρ entre -0,40 e -0,43), enquanto a argila destacou-se na região de 2142-2495 nm (ρ entre -0,51 e -0,65).

A correlação positiva entre a areia e o espectro vis-NIR-SWIR decorre da composição desta fração do solo, constituída predominantemente por quartzo, um mineral transparente que não absorve energia e contribui para o aumento da intensidade de reflectância global (albedo) (Terra *et al.*, 2021). Por outro lado, a correlação inversa entre a argila e o comportamento espectral evidencia que maiores concentrações desta fração reduzem a reflectância do solo, favorecendo a ocorrência de feições de absorção. Este efeito está relacionado à mineralogia da argila, composta principalmente por minerais que apresentam absorção na região SWIR, como a caulinita, por exemplo (Madeira Netto; Baptista, 2000).

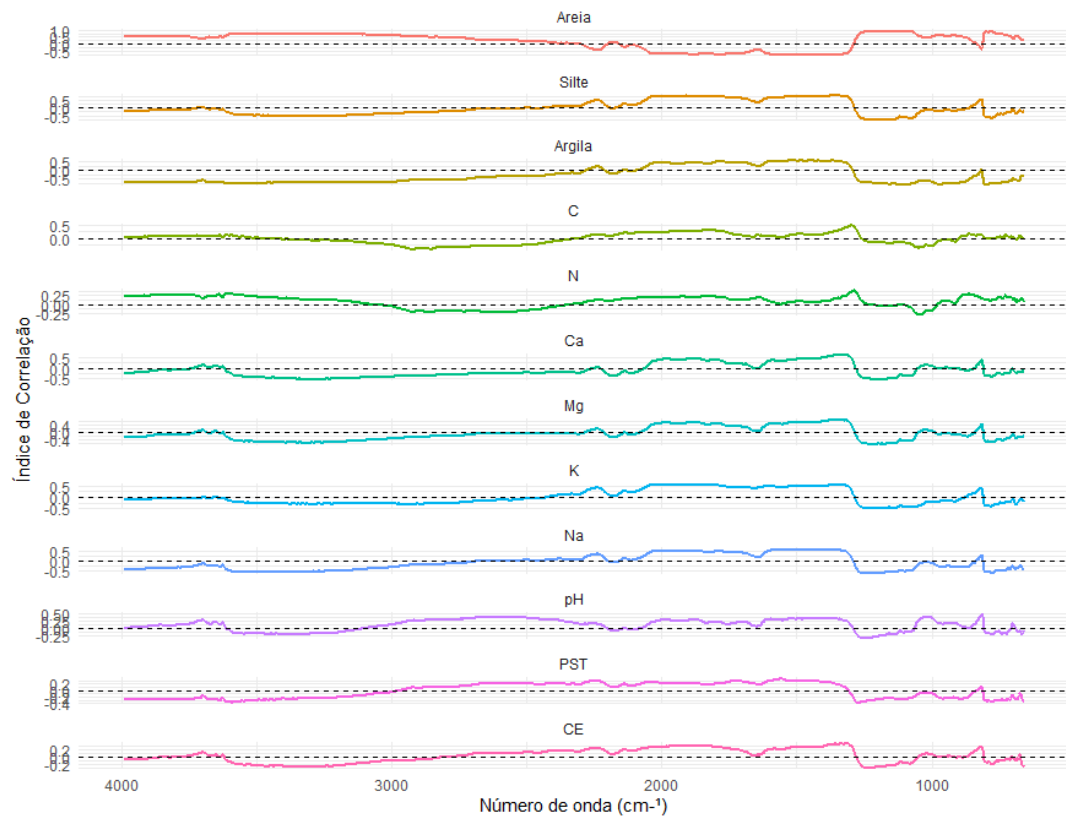
Com relação aos atributos químicos, o sódio (Na) destacou-se nas faixas de 1398-1404 nm, 1419-1441 nm e 1880-2003 nm (ρ de -0,51 a -0,56), já a PST se destacou em 1346-1433 nm, 1547-1563 nm e 1643-1891 nm (ρ de -0,35 a -0,38). O pH apresentou associação mais forte na região de 905-1284 nm (ρ de -0,35 a -0,40), enquanto a CE exibiu os maiores coeficientes em 640-834 nm (ρ de -0,50 a -0,51). O carbono orgânico (C) apresentou as correlações mais expressivas na faixa 524-664 nm (ρ de -0,40 e -0,43). A presença de matéria orgânica no solo é reconhecida como um importante atributo para caracterização espectral, apresentando maior correlação com a reflectância do visível (Meneses; Almeida; Baptista, 2019), o que reforça os resultados obtidos.

Quanto aos macronutrientes, o nitrogênio (N) e potássio (K) apresentaram correlações de baixa magnitude. O N exibiu tanto relações positivas quanto negativas, contudo foram consideradas insignificantes tendo o maior valor ocorrido em 531-556 nm (ρ = -0,29), enquanto o K mostrou fraca associação, apresentando o maior valor em 433-447 nm (ρ = -0,31). O cálcio (Ca) exibiu correlações moderadas nas faixas 355-591 nm e 677-1125 nm (ρ de -0,51 a -0,64), e o magnésio (Mg) obteve maior correlação em 355-466 nm, 669-1150 nm e 1897-1927 nm (ρ de -0,40 a -0,48).

Os atributos químicos, com exceção do carbono orgânico, não alteram diretamente o espectro do solo, sendo considerados propriedades de segunda ordem. No entanto, tais atributos encontram-se adsorvidos ou dependem de grupos funcionais de compostos minerais e orgânicos (Terra *et al.*, 2021), o que possibilita a sua análise indireta por meio da interação com os atributos de primeira ordem.

Na análise de correlação de Spearman entre os dados espectrais MIR suavizados e os atributos do solo, observaram-se, de forma geral, relações tanto diretas quanto inversas, com magnitudes mais expressivas do que as relações verificadas na faixa vis-NIR-SWIR (Figura 8).

Figura 8 – Correlação multivariada entre atributos do solo e a faixa espectral MIR



Fonte: A autora.

Os atributos físicos apresentaram altas correlações. A areia exibiu associações positivas fortes nas faixas $3583\text{--}3198\text{ cm}^{-1}$, $1269\text{--}1060\text{ cm}^{-1}$ e $806\text{--}751\text{ cm}^{-1}$ ($\rho = 0,71$ a $0,92$), enquanto as correlações negativas mais intensas ocorreram em $1802\text{--}1770\text{ cm}^{-1}$ e $1597\text{--}1332\text{ cm}^{-1}$ ($\rho = -0,71$ a $-0,77$). O silte destacou-se em $2035\text{--}1777\text{ cm}^{-1}$ e $1530\text{--}1315\text{ cm}^{-1}$ ($\rho = 0,71$ a $0,77$), além da região $1250\text{--}1133\text{ cm}^{-1}$ ($\rho = -0,71$ a $-0,77$). A argila, por sua vez, exibiu os coeficientes mais elevados nas regiões $3990\text{--}3883\text{ cm}^{-1}$, $3675\text{--}3669\text{ cm}^{-1}$, $3637\text{--}3628\text{ cm}^{-1}$, $3621\text{--}3404\text{ cm}^{-1}$, $3391\text{--}3373\text{ cm}^{-1}$, $3273\text{--}3063\text{ cm}^{-1}$, $1256\text{--}1058\text{ cm}^{-1}$, $993\text{--}890\text{ cm}^{-1}$ e $808\text{--}743\text{ cm}^{-1}$ ($\rho = -0,71$ a $-0,85$), além das faixas $1794\text{--}1768\text{ cm}^{-1}$ e $1600\text{--}1334\text{ cm}^{-1}$ ($\rho = 0,51$ a $0,57$).

Diferentemente do observado na faixa vis-NIR-SWIR, a fração areia apresentou correlações negativas na região MIR. Essa relação inversa promove absorções e está associada à presença de sílica, a qual possui bandas de absorção apenas no MIR. Nos solos, a sílica está presente no quartzo que compõe a areia e nos argilominerais filossilicatos que constituem a fração argila, promovendo absorções nessas partículas (Terra *et al.*, 2021).

Em relação aos atributos químicos, o carbono apresentou correlações negativas mais intensas em $2946\text{--}2838\text{ cm}^{-1}$ e $1837\text{--}1818\text{ cm}^{-1}$ ($\rho = -0,35$ a $-0,41$), e positivas em $1313\text{--}1285\text{ cm}^{-1}$ ($\rho = 0,40$ a $0,48$). O sódio exibiu os maiores valores nas faixas $3600\text{--}3173\text{ cm}^{-1}$,

1272-1075 cm^{-1} e 805-762 cm^{-1} ($\rho = -0,51$ a $-0,66$), além da região 1599-1323 cm^{-1} ($\rho = 0,51$ a $0,59$). O pH destacou-se em 820-810 cm^{-1} ($\rho = 0,40$ a $0,47$) e em 1263-1230 cm^{-1} ($\rho = -0,31$ a $-0,33$). A PST exibiu as maiores correlações nas faixas 3615-3561 cm^{-1} , 1284-1252 cm^{-1} e 780-773 cm^{-1} ($\rho = -0,35$ a $-0,39$) e em 1563-1554 cm^{-1} ($\rho = 0,35$). Já a CE, apresentou correlação mais elevada em 1397-1300 cm^{-1} ($\rho = 0,31$ a $0,37$).

Quanto aos macronutrientes, o N obteve maior correlação em 1302-1280 cm^{-1} ($\rho = 0,35$ a $0,40$). O K apresentou correlações positivas em 2048-1779 cm^{-1} , 1487-1483 cm^{-1} e 1388-1313 cm^{-1} ($\rho = 0,51$ a $0,57$), enquanto em 1243-1213 cm^{-1} foram observados maior correlação negativa ($\rho = -0,50$ e $-0,51$). O Ca apresentou relações mais intensas em 3417-3153 cm^{-1} e 1252-1136 cm^{-1} ($\rho = -0,51$ a $-0,56$), além de 1401-1289 cm^{-1} ($\rho = 0,51$ a $0,64$). O Mg exibiu os maiores coeficientes nas faixas 3509-3503 cm^{-1} , 3486-3171 cm^{-1} , 1265-1127 cm^{-1} e 786-769 cm^{-1} ($\rho = -0,51$ a $-0,63$), além de 1889-1867 cm^{-1} e 1500-1304 cm^{-1} ($\rho = 0,51$ a $0,66$).

De modo geral, os coeficientes de correlação produzidos na faixa MIR foram superiores aos obtidos na região vis-NIR-SWIR. A exceção foi os coeficientes da CE e do Ca. As correlações fortes entre os atributos e a energia eletromagnética do MIR, decorrem das vibrações moleculares fundamentais desta região, as quais refletem os componentes minerais e orgânicos dos solos (Dangal *et al.*, 2019). Este tipo de interação da energia do MIR permite a melhor caracterização dos atributos, sobretudo daqueles que alteram o espectro do solo, como a granulometria e o carbono orgânico.

3.3.3 Comportamento espectral das classes de solos

3.3.3.1 Argissolo

Todos os seis perfis de Argissolo avaliados apresentaram alta intensidade de refletância na faixa vis-NIR-SWIR, com valores superiores a 0,70, o que evidencia a forte contribuição da fração areia no albedo. A morfologia espectral foi semelhante entre os perfis, tendo a curva espectral exibido inicialmente forma ascendente, seguida de um trecho plano e, a partir de 2000 nm, leve tendência descendente. Observaram-se diferenças na intensidade de refletância entre os horizontes superficiais e subsuperficiais, atribuídas principalmente à influência da matéria orgânica e às variações granulométricas entre os horizontes.

A redução do teor de areia e o aumento de argila entre os horizontes superficial e subsuperficial é uma característica típica de Argissolos (Santos *et al.*, 2025). Essa diferenciação textural entre horizontes resulta da atuação de diferentes processos

pedogenéticos, como a argiluviação (lessivagem) e a elutriação. Na argiluviação, ocorre a movimentação das partículas finas da fração argila, com a eluviação dos horizontes superficiais e o consequente enriquecimento dos horizontes subsuperficiais pela iluviação da argila. Já na elutriação, o material fino é removido do horizonte superficial em função do escoamento superficial, promovendo um gradiente textural no solo (Kämpf; Curi, 2012).

A diferença textural entre os horizontes de Argissolos foi adequadamente captada pela espectroscopia de reflectância, uma vez que os horizontes B texturais apresentaram feições espectrais típicas de minerais de argila com absorções bem pronunciadas. Em contraste, o horizonte superficial exibiu maior reflectância na região do SWIR e picos acentuados na faixa do MIR, em decorrência do seu alto teor de areia.

O maior conteúdo de matéria orgânica nos horizontes superficiais A promoveu, na faixa vis-NIR-SWIR, menor intensidade de reflectância, além do mascaramento das feições associadas aos óxidos de ferro. Estes óxidos ocorrem em menor quantidade nesses horizontes em virtude da migração de partículas finas a partir do horizonte superficial, processo associado à lessivagem (Kämpf; Curi, 2012). Por outro lado, o maior teor de areia, em relação aos horizontes subsuperficiais, favoreceu o aumento da reflectância a partir de 2100 nm, promovendo inversão das curvas. Nos horizontes B texturais, observaram-se absorções típicas dos óxidos de ferro em torno de 435-530 nm e 885-950 nm, sendo esta última feição caracterizada pelo aspecto côncavo na curva espectral (Madeira Netto; Baptista, 2000).

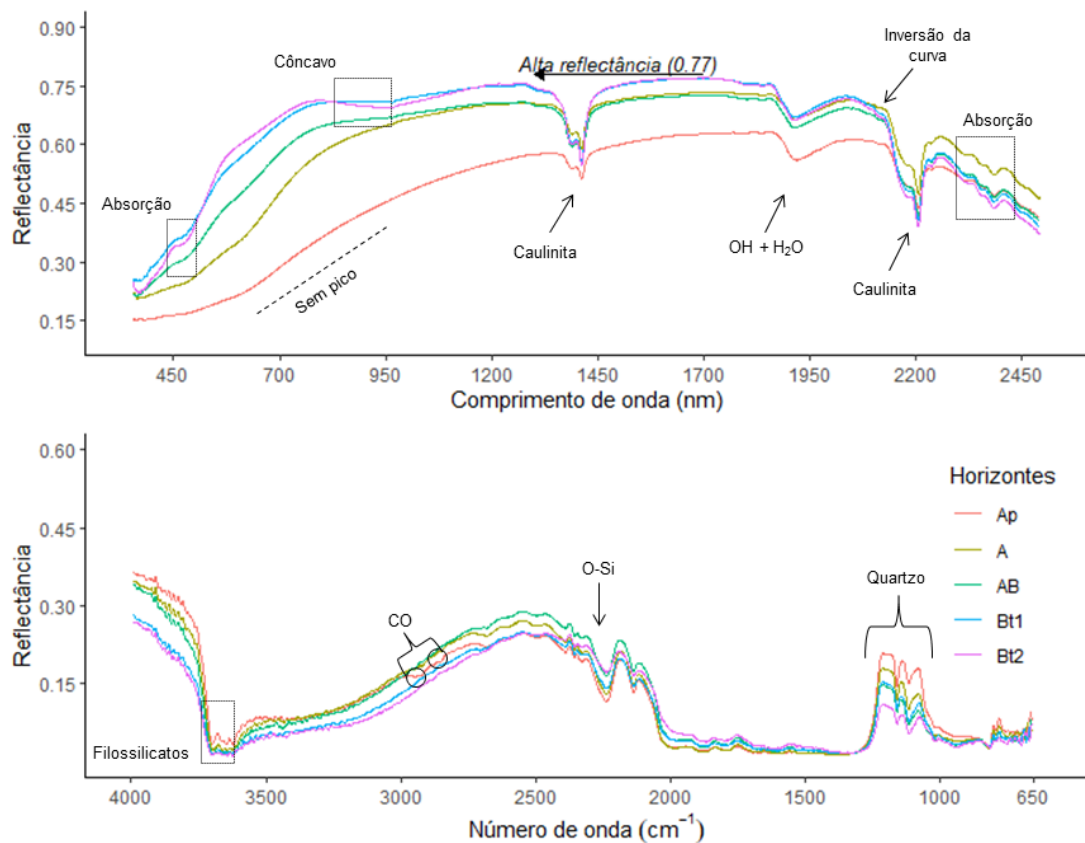
Na região do MIR, os perfis não apresentaram grandes distinções na intensidade geral de reflectância, mas, semelhante ao vis-NIR-SWIR, foi verificada diferenças entre os horizontes. As feições de absorção associadas ao CO, centradas em $2924\text{-}2843\text{ cm}^{-1}$ (Mendes *et al.*, 2022), foram mais evidentes nos horizontes superficiais, que têm maior conteúdo de matéria orgânica. De modo geral, nos horizontes B texturais ocorreu redução da energia refletida nas regiões de $3695\text{-}2750\text{ cm}^{-1}$ e $1250\text{-}1000\text{ cm}^{-1}$, atribuída ao maior conteúdo de argila desses horizontes.

A análise do comportamento espectral do perfil 5 (Figura 9) revelou predominância de goethita, caracterizado por maior intensidade de reflectância no início do espectro vis. A hematita e a goethita são os óxidos de ferro mais encontrados nos solos tropicais (Meneses; Almeida; Baptista, 2019). Observaram-se absorções em 1400 e 1900 nm com a presença de um ombro à esquerda das feições, indicando ocorrência da caulinita, enquanto as absorções em 2346 e 2440 nm foram atribuídas às micas (Demattê *et al.*, 2014; Meneses; Almeida; Baptista, 2019).

Na faixa MIR, a reflectância exibiu padrão abrupto de queda no início do

espectro, especialmente nos horizontes superficiais que possuem elevado teor de areia e presença de quartzo na composição, o qual possui forte absorção nesta região do espectro. Nestes horizontes foram observadas, também, feições associadas ao CO, tendo ocorrido altos picos de reflectância a partir de 1250 cm^{-1} , os quais são atribuídos ao quartzo (Mendes *et al.*, 2022).

Figura 9 – Comportamento espectral de perfil 5: ARGISSOLO ACINZENTADO Eutrófico típico



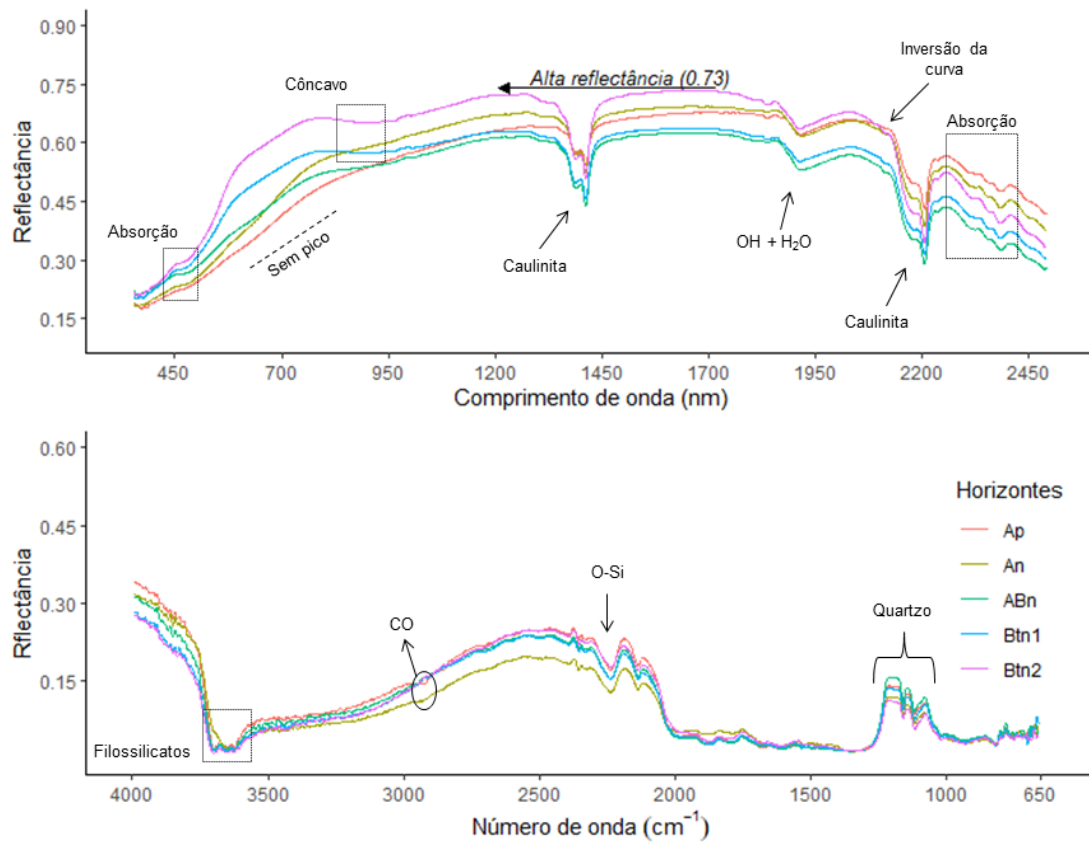
Fonte: A autora.

Nos perfis 6 e 9, a análise do comportamento espectral também evidenciou a predominância de goethita, em concordância com a cor amarelada desses solos. As feições atribuídas a caulinita em 1400 e 2200 nm foram bem definidas, enquanto as absorções associadas às micas foram observadas no final do espectro vis-NIR-SWIR. No MIR, a porção inicial do espectro revelou um padrão abrupto de reflectância nos horizontes superficiais pelo alto teor de quartzo.

O perfil 6 (Figura 10) apresentou variações entre os espectros dos horizontes, com o horizonte An exibindo a menor reflectância de $3250\text{--}2100\text{ cm}^{-1}$ e uma forte absorção em

2250 cm^{-1} , sendo esta feição de absorção associada a sílica presente no quartzo ou nos filossilicatos (Mendes *et al.*, 2022).

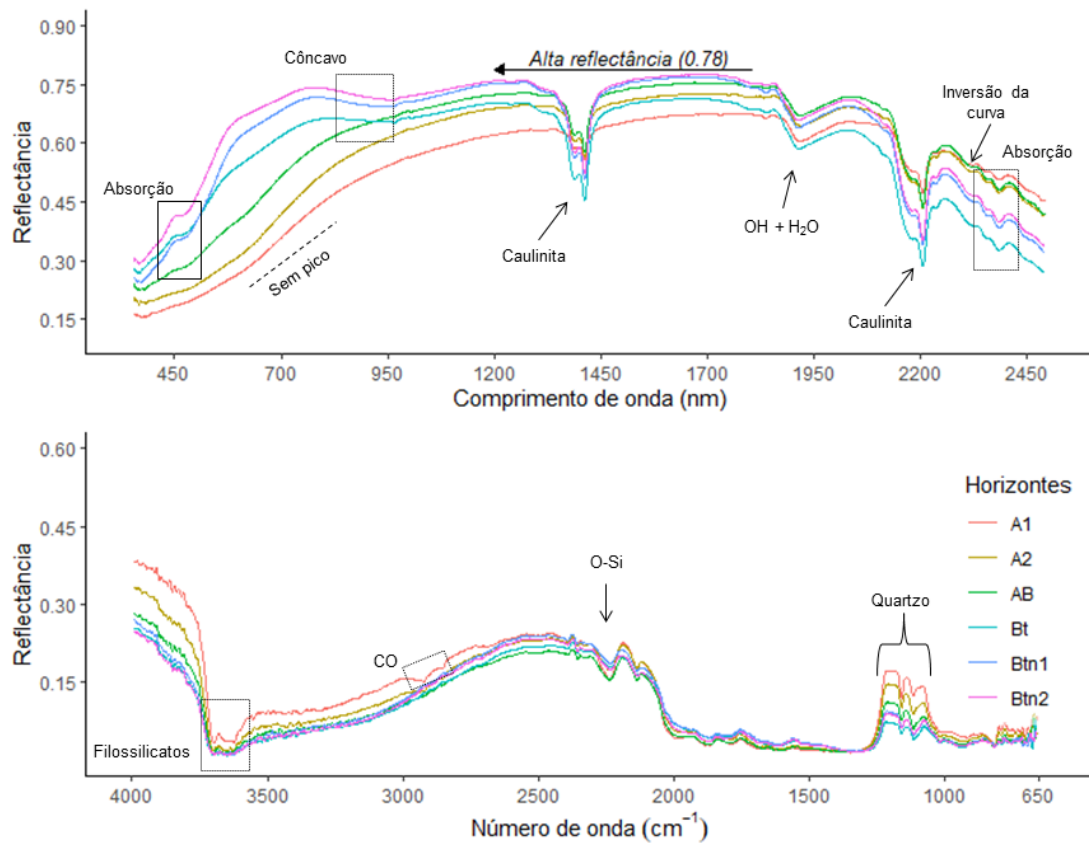
Figura 10 – Comportamento espectral de perfil 6: ARGISSOLO AMARELO Distrófico típico



Fonte: A autora.

No perfil 9 (Figura 11), as absorções dos filossilicatos entre 3700-3600 cm^{-1} foram mais evidentes, sugerindo maior ocorrência de caulinita (Di Raimo *et al.*, 2022).

Figura 11 – Comportamento espectral de perfil 9: ARGISSOLO AMARELO Distrocoesolódico

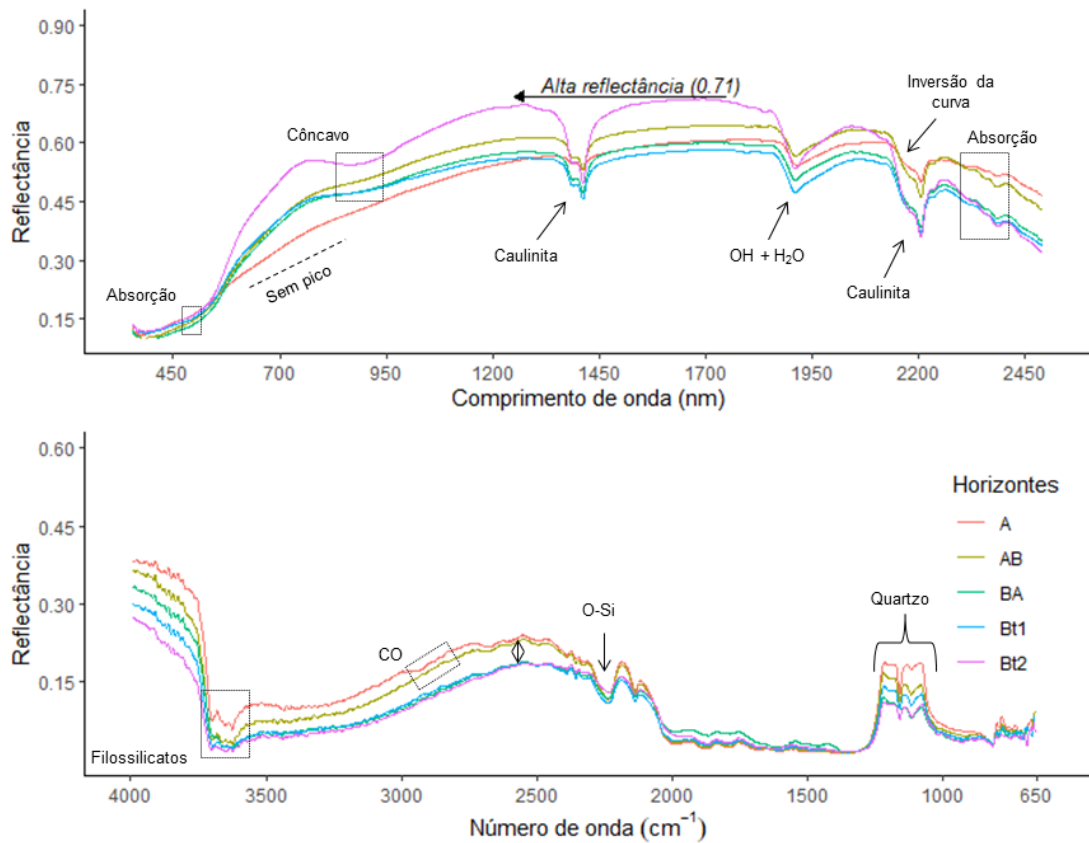


Fonte: A autora.

A análise do comportamento espectral dos perfis 12, 18 e 19 evidenciou a predominância do óxido de Fe hematita, indicada pela menor intensidade de reflectância no início do espectro visível. Foram observadas absorções associadas à caulinita e às micas na região SWIR. As feições atribuídas aos óxidos e aos argilomonerais 1:1 foram mais pronunciadas nos horizontes subsuperficiais, evidenciando a importância de se realizar análise espectral em horizontes diagnósticos, os quais exibem características fundamentais para a classificação do solo. As feições dos minerais observados confirmam as características dos Argissolos, solos considerados em estágio intermediário de evolução (Santos *et al.*, 2025).

Embora os perfis 12 e 18 possuam a mesma classificação pedológica, seus horizontes apresentaram distinções no comportamento espectral da faixa MIR, possivelmente relacionadas a diferenças no material de origem, uma vez que os solos se formaram em áreas distintas. O perfil 12 (Figura 12) apresentou diferenças de intensidade entre os horizontes, as feições de absorção dos filossilicatos foram mais nítidas, e ocorreram pequenos picos em $1780\text{--}1500\text{ cm}^{-1}$, indicando maior predominância de caulinita.

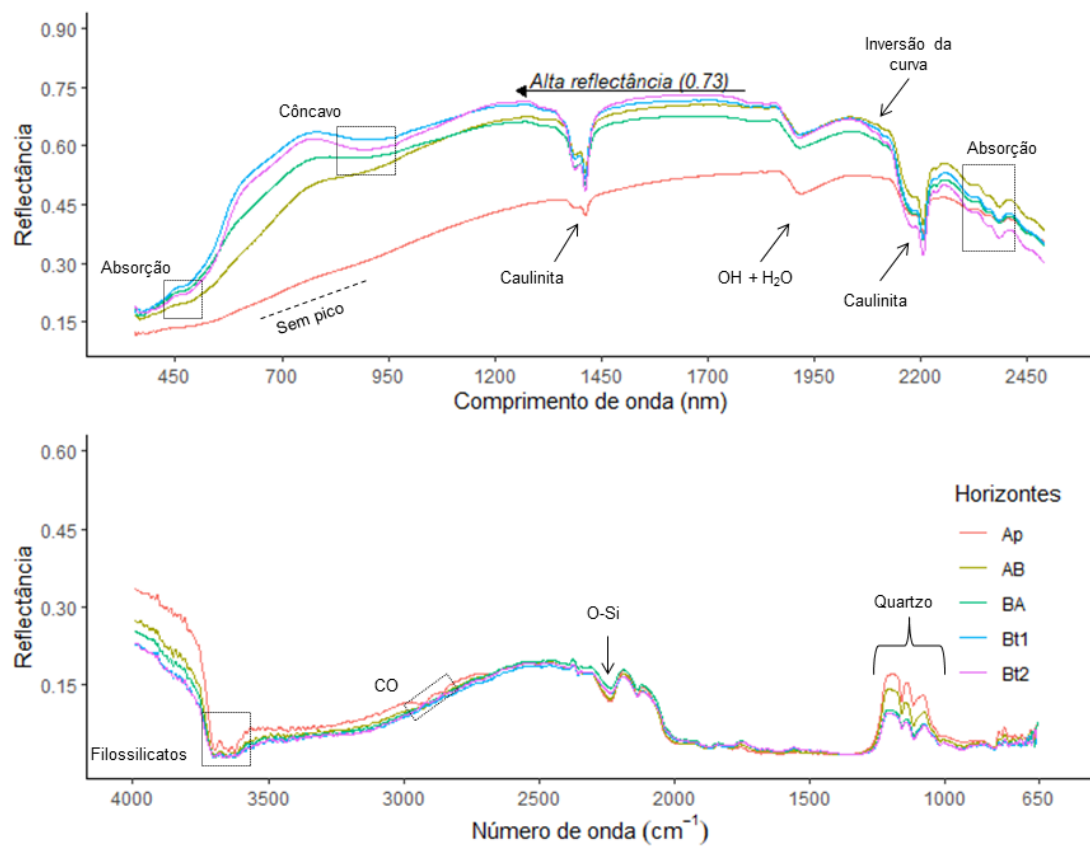
Figura 12 – Comportamento espectral de perfil 12: ARGISSOLO VERMELHO-AMARELO Distrófico arênico



Fonte: A autora

Em contraste, no perfil 18 (Figura 13) as absorções do quartzo em 2000-1750 cm^{-1} foram suaves e os picos em 1250-1000 cm^{-1} foram menos intensos, sugerindo menor teor de quartzo que no perfil 12.

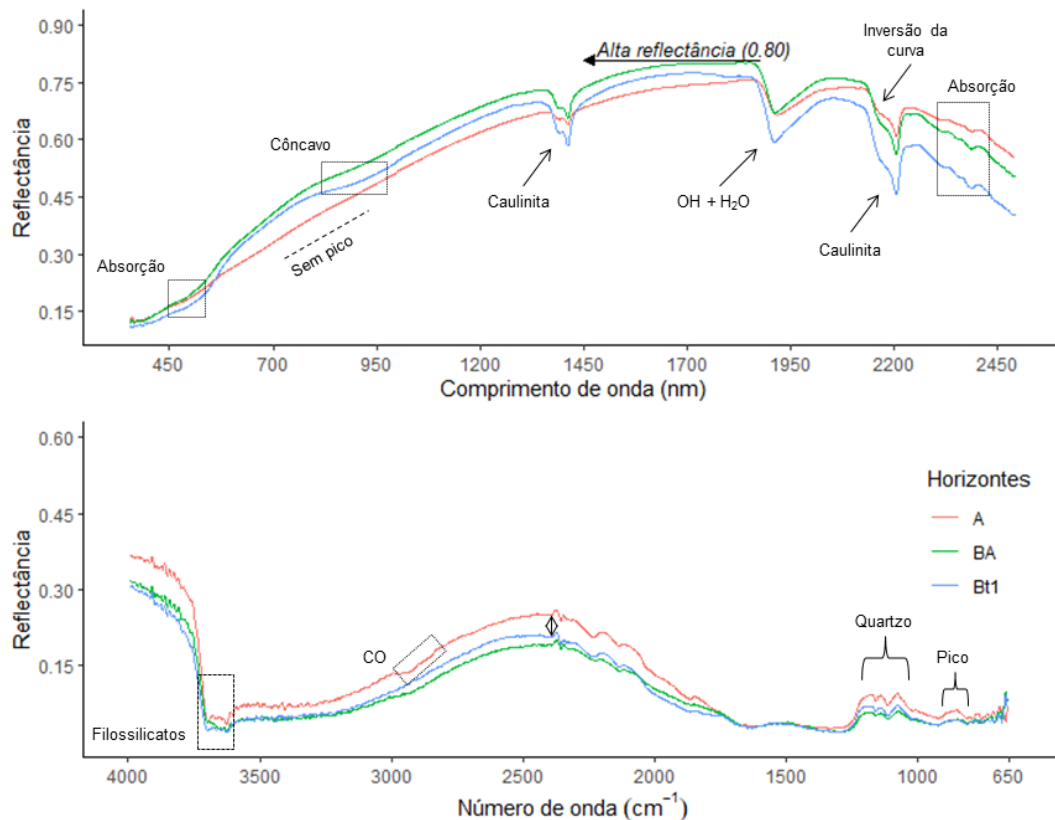
Figura 13 – Comportamento espectral de perfil 18: ARGISSOLO VERMELHO-AMARELO Distrófico arênico



Fonte: A autora

O perfil 19 (Figura 14), por sua vez, apresentou o maior fator de reflectância entre todos os perfis de Argissolos avaliados. Na faixa MIR, as feições de absorção atribuídas ao CO em 2924-2843 cm^{-1} foram muito suaves. Por outro lado, observou-se a ocorrência de um pico em 916 cm^{-1} , associada à hematita oriunda da desidroxilação da goethita (Ruan *et al.*, 2002).

Figura 14 – Comportamento espectral de perfil 19: ARGISSOLO VERMELHO Distrófico nitossólico



Fonte: A autora

3.3.3.2 Cambissolo

Os dois perfis de Cambissolo avaliados apresentaram elevado albedo na faixa vis-NIR-SWIR, com fator de reflectância superior a 0,75, o que evidencia a forte contribuição da granulometria para o aumento da reflectância. A morfologia espectral seguiu padrão semelhante entre os perfis, caracterizado por curvas inicialmente ascendentes, seguidas por trecho com tendência plana.

Foram observadas diferenças na intensidade de reflectância entre os horizontes, atribuídas principalmente à influência da matéria orgânica e à granulometria. As feições dos óxidos de ferro presentes na faixa vis-NIR indicaram predominância de hematita, com banda de absorção mais estreita em torno de 950 nm. Estas feições foram observadas apenas nos horizontes subsuperficiais, os quais não sofrem mascaramento pela matéria orgânica, o que ratifica a importância destes horizontes para auxiliar na classificação dos solos.

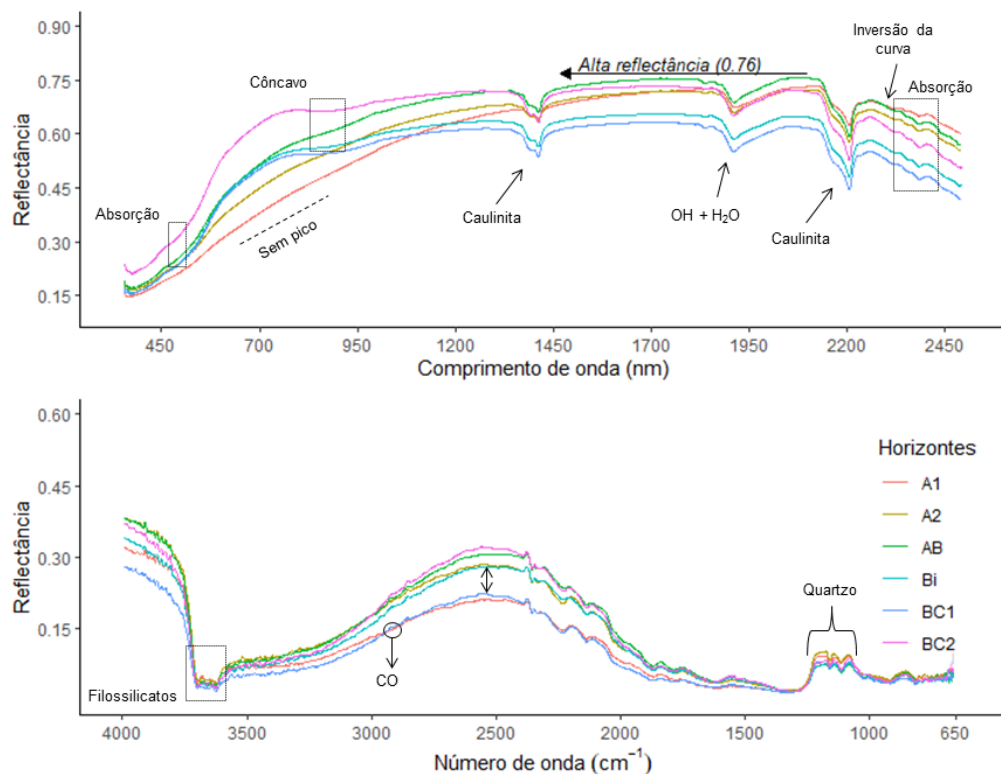
No MIR, também foram verificadas diferenças na intensidade de reflectância entre os horizontes em algumas regiões. Embora os horizontes superficiais tenham apresentado

teores elevados de CO ($> 10 \text{ g kg}^{-1}$), suas feições de absorção centradas entre $2924\text{-}2843 \text{ cm}^{-1}$ (Mendes *et al.*, 2022), foram suaves. Já os picos de quartzo, entre $1200\text{-}1000 \text{ cm}^{-1}$, exibiram baixa intensidade e ausência de diferenças expressiva entre horizontes. Estes aspectos sugerem menor teor de quartzo e poucas variações texturais, o que é típico de Cambissolos, que são caracterizados pelo baixo desenvolvimento pedogenético (Santos *et al.*, 2025).

O comportamento espectral do perfil 11 (Figura 15) apresentou feições de absorção típicas de caulinita e micas na faixa NIR-SWIR, com inversão da curva em 2350 nm , decorrente do aumento da reflectância no horizonte A1, em virtude do maior teor da fração areia em relação aos demais horizontes. Embora os Cambissolos apresentem, normalmente, teores uniformes de argila ou pequenos incrementos (Santos *et al.*, 2025), esta leve diferença de textura pôde ser capturada pela análise espectral, que evidenciou variações na reflectância entre os horizontes.

Na faixa MIR, observaram-se feições atribuídas à caulinita, com absorções entre $3700\text{-}3600 \text{ cm}^{-1}$, além de pequenas variações na intensidade de reflectância entre os horizontes na região de $3000\text{-}2000 \text{ cm}^{-1}$. Essas diferenças podem estar associadas a incrementos sutis no teor de argila dos horizontes (Di Raimo *et al.*, 2022).

Figura 15 – Comportamento espectral de perfil 11: CAMBISSOLO HÁPLICO Tb Eutrófico típico



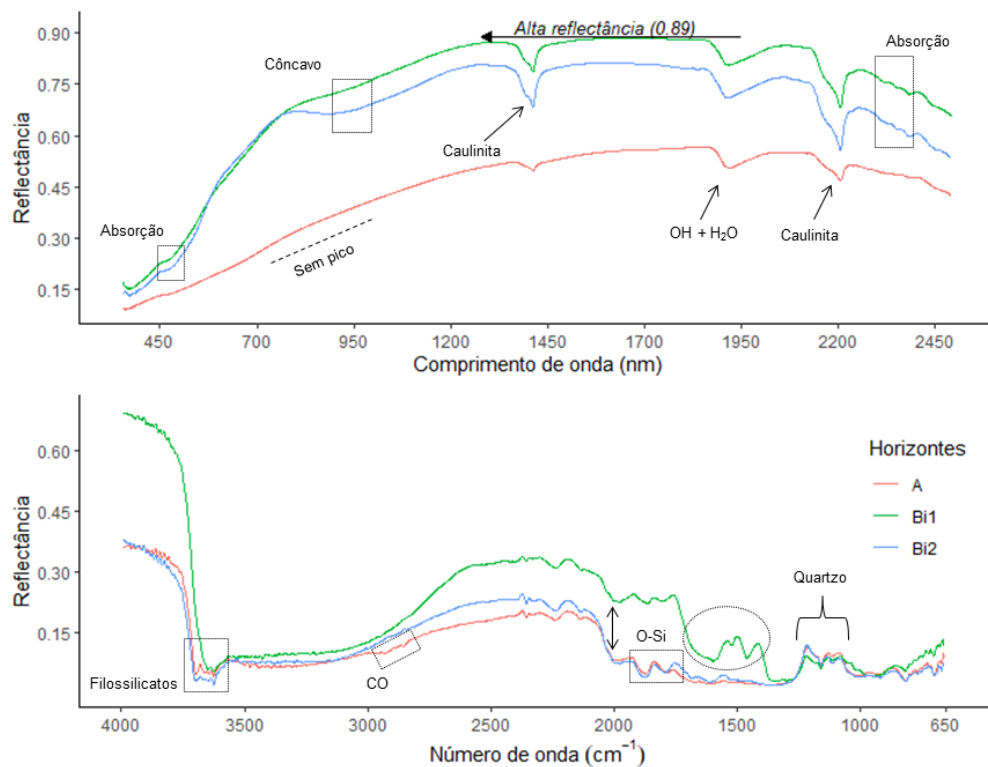
Fonte: A autora

Em contraste, o perfil 20 (Figura 16) não apresentou inversão da curva. Todavia, as feições bem marcadas em 1400 e 2200 nm indicaram a prevalência de caulinita, o que foi corroborado no MIR pelas absorções dos filossilicatos no início do espectro e pelo pico em 1500 cm^{-1} , enquanto as feições em 1900 e 2346 nm sugeriram a ocorrência de argilominerais 2:1. Os horizontes subsuperficiais exibiram elevada reflectância, comportamento característico dos Cambissolos, cujo maior teor de silte, sobretudo nos horizontes subsuperficiais, associado ao baixo desenvolvimento pedogenético e a presença de argilominerais 2:1, favorece a alta reflectância (Bellinaso; Demattê; Romeiro, 2010).

A curva do horizonte B1l destacou-se pela reflectância superior em todas as faixas, atribuído ao seu maior teor de areia. Observaram-se diferenças no seu comportamento entre 2750 e 1400 cm^{-1} , em relação aos demais horizontes, associadas a variações na granulometria e no teor de CO. Este horizonte representa a zona de maior transformação pedogenética do perfil, enquanto o horizonte subsequente, por ser mais profundo, pode conter minerais primários com assinaturas espectrais distintas.

O horizonte B1l apresentou maior teor de areia e redução na concentração de CO, em comparação ao horizonte A, o que favoreceu a sua alta reflectância. O predomínio da fração areia tende a reduzir a superfície específica das partículas, permitindo que o CO, mesmo com baixos teores, exerça maior influência sobre o espectro (Di Raimo *et al.*, 2022). Assim, as absorções nessa região correspondem à combinação das bandas de CO e de H₂O com as dos minerais, sendo as feições presentes entre 1725 e 1530 cm^{-1} atribuídas aos ácidos carboxílicos e proteínas da matéria orgânica (Rossel *et al.*, 2008).

Figura 16 – Comportamento espectral de perfil 20: CAMBISSOLO HÁPLICO Tb Distrófico saprolítico



Fonte: A autora.

3.3.3.3 Gleissolo

O perfil de Gleissolo analisado apresentou alta reflectância, com intensidade máxima de 0,72 (Figura 17). A morfologia espectral foi caracterizada por comportamento inicialmente ascendente, seguindo de um trecho mais plano a partir de 1450 nm. Foram observadas diferenças na intensidade de reflectância entre os horizontes superficiais e subsuperficiais. De forma similar ao verificado no Cambissolo, os horizontes subsuperficiais deste perfil apresentaram alta reflectância em razão do elevado conteúdo de silte, que é característico de solos com baixo desenvolvimento, associado ao maior teor de areia.

Na faixa vis-NIR-SWIR, os horizontes subsuperficiais exibiram curva com concavidade suave entre 900 e 950 nm, indicando ocorrência de óxidos de ferro em pequena quantidade. Embora o ferro seja um elemento característico dos Gleissolos, nestes solos ele ocorre principalmente na forma reduzida, a qual não possui feições típicas. O predomínio do ferro reduzido decorre da preponderância do processo de gleização, que ocorre pela saturação do solo com água, que estabelece condições anaeróbias e promove a redução do Fe, originado uma matriz de cor cinzenta, com ocorrência ocasional de mosqueados ou concreções de Fe e

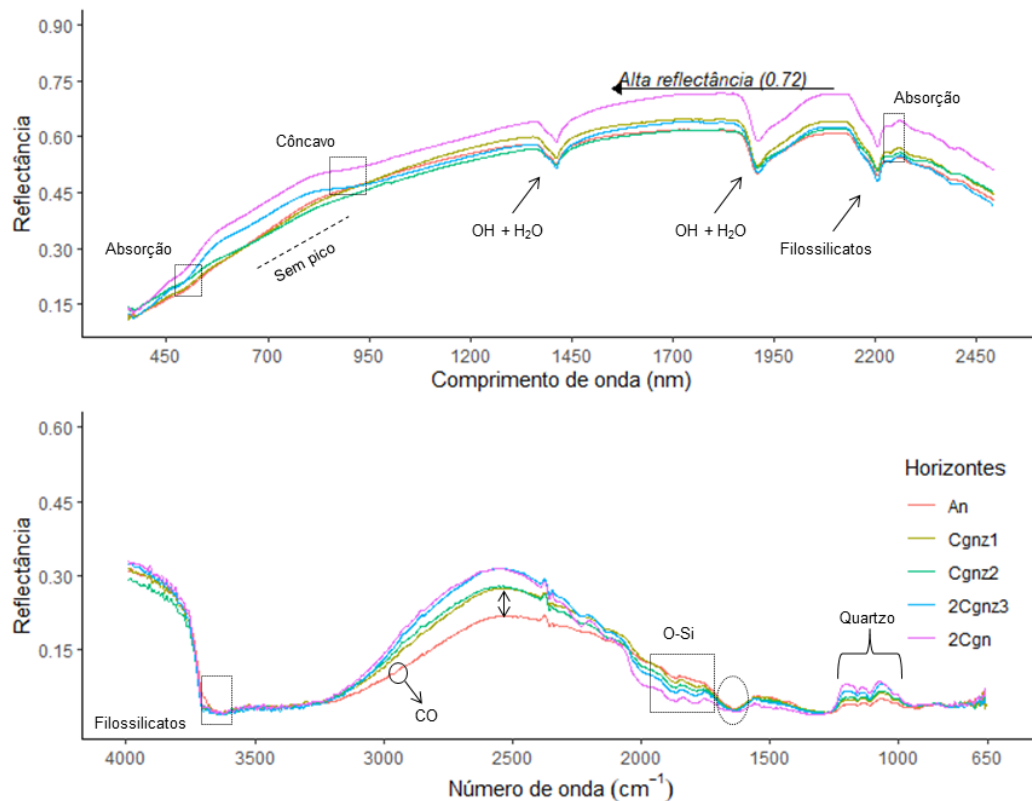
Mn (Kämpf; Curi, 2012).

Ainda na faixa vis-NIR-SWIR, observaram-se feições relacionadas aos argilominerais, indicando predominância de minerais do tipo 2:1, evidenciada pelas absorções mais suaves em 1400 e 2200 nm e pela feição em 1900 nm, profunda e com aspecto em “V”. Além disso, verificaram-se feições entre 2261-2440 nm associadas às micas e aos carbonatos (Meneses; Almeida; Baptista, 2019), corroboradas pelos maiores teores de Ca e Mg no perfil. Em contraste com os carbonatos, as características de salinidade e sodicidade deste perfil não puderam ser identificadas, uma vez que os sais solúveis não alteram o espectro.

A presença de carbonatos é típica de ambientes com baixo intemperismo químico, como os solos do semiárido, que preservam características do material de origem e frequentemente se formam a partir de rochas sedimentares (Araújo Filho *et al.*, 2022). No contexto do Ceará, a ocorrência destes minerais nos Gleissolos é particularmente favorecida pelo material de origem, depósitos aluvionares e litorâneos (Levantamento de reconhecimento de média intensidade dos solos do Estado do Ceará, 2024). É importante destacar que a dinâmica do ambiente de formação desse solo, o qual é formado principalmente por sedimentos sob condições de hidromorfia (Santos *et al.*, 2025), associado a influência de água salgada, cria condições propícias para gênese de solos salino-sódicos.

De modo oposto, na faixa do MIR não foram observadas feições associadas a carbonatos. O comportamento espectral apresentou variações sutis na intensidade de reflectância entre os horizontes, principalmente na região de 3000-2250 cm^{-1} , atribuídas a diferenças na granulometria. Os maiores teores de areia nos horizontes subsuperficiais promoveram maior reflectância nesta região e também entre 1200-1000 cm^{-1} , em função da maior presença de quartzo. Foram verificadas ainda feições de absorção suaves dos filossilicatos em 3695-3622 cm^{-1} e do CO em 2924 cm^{-1} , além de uma absorção com aspecto mais largo e profundo em torno de 1624 cm^{-1} , atribuída a combinação das bandas de CO e de H₂O, resultante da influência conjunta da matéria orgânica e da água.

Figura 17 – Comportamento espectral de perfil 8: GLEISSOLO SÁLICO Sódico típico



Fonte: A autora.

3.3.3.4 Latossolo

O perfil de Latossolo apresentou alta reflectância, com intensidade máxima de 0,77 na região vis-NIR-SWIR (Figura 18). A morfologia espectral exibiu aspecto inicialmente ascendente, seguido de um trecho plano e, a partir de 2100 nm, tendência levemente descendente. O comportamento espectral foi semelhante entre os horizontes na faixa vis-NIR-SWIR, refletindo a granulometria mais uniforme, enquanto no MIR ocorreram diferenças. Na região SWIR ocorreu inversão das curvas, com o horizonte A apresentando maior reflectância. Embora os Latossolos exibam pouca diferenciação de sub-horizontes, pode ocorrer pequeno incremento de argila no horizonte B latossólico com a profundidade (Santos *et al.*, 2025).

Na faixa vis-NIR-SWIR, observaram-se feições típicas de óxidos e argilominerais do tipo 1:1. Na curva espectral, a concavidade mais larga entre 900-1000 nm sugere a predominância de goethita, o que está em concordância com a coloração do perfil, enquanto a absorção em 2265 nm está associada à ocorrência de gibbsita (Meneses; Almeida; Baptista, 2019). Também foram verificadas absorções atribuídas à caulinita, evidenciadas pelo ombro à esquerda nas feições em 1400 e 2200 nm. A ocorrência concomitante de óxidos e

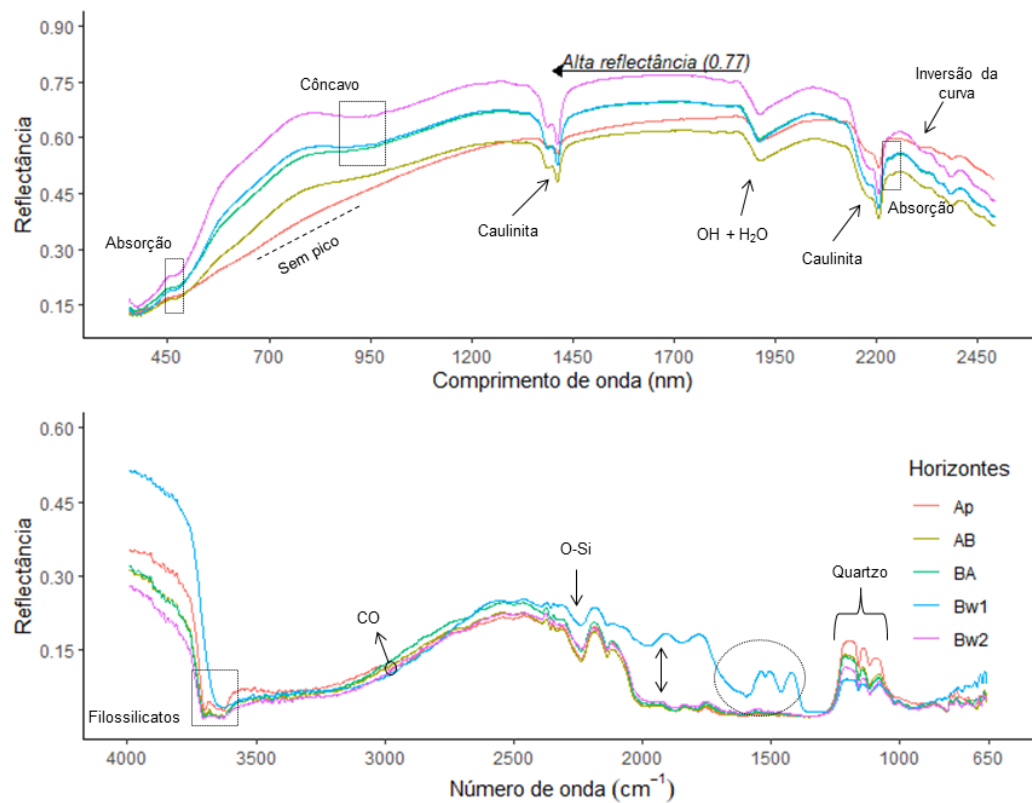
argilominerais 1:1 neste perfil, evidencia o avançado desenvolvimento pedogenético dos Latossolos.

Os Latossolos se caracterizam pelo alto grau de intemperismo, concentrando argilominerais mais resistentes e óxidos de Fe e Al, de modo que o predomínio de minerais secundários favorece o acúmulo de caulinita e gibbsita (Santos *et al.*, 2025). Neste solo, predomina o processo pedogenético de ferralitização, que resulta na remoção da sílica (dessilicação), na formação de caulinita e na concentração de óxidos de Fe e Al, evidenciando a forte atuação do intemperismo químico (Kämpf; Curi, 2012). Estas características do processo pedogenético puderam ser verificadas na análise espectral, manifestando-se de forma mais intensa nos horizontes subsuperficiais, os quais são diagnósticos para identificar esta classe do solo.

Na região do MIR, as feições de absorção do CO em 2924 cm^{-1} foram pouco expressivas, possivelmente mascaradas pelo maior conteúdo de óxidos. Foram observadas absorções entre $3695\text{-}3390\text{ cm}^{-1}$, características de filossilicatos e gibbsita, além de feições acentuadas de quartzo, com absorção em 2230 cm^{-1} e picos de reflectância entre $1200\text{-}1000\text{ cm}^{-1}$ (Mendes *et al.*, 2022), corroborando o elevado conteúdo de areia do perfil. Por outro lado, os horizontes subsuperficiais apresentaram pequeno acúmulo de argila, destacando-se o horizonte Bw1, que exibiu alta reflectância e comportamento distinto dos demais horizontes na faixa de $2500\text{-}1250\text{ cm}^{-1}$.

O horizonte Bw1 é a zona de maior atuação pedogenética. As variações espectrais observadas neste horizonte podem ser atribuídas a mudanças na granulometria e no conteúdo de CO, visto que, em relação ao horizonte antecedente, houve redução dos teores de areia e de CO e incremento de argila. A variação destes atributos tornou mais pronunciada as feições dos minerais entre $2000\text{-}1500\text{ cm}^{-1}$, sendo que na região entre $1725\text{-}1530\text{ cm}^{-1}$ ocorrem importantes absorções de CO (Rossel *et al.*, 2008). Assim, de modo similar ao perfil 20 de Cambissolo, as feições verificadas nessa região, possivelmente, são a combinação das bandas de CO e de H₂O junto aos minerais oriundos do acúmulo de argila, prevalecendo neste caso os minerais secundários.

Figura 18 – Comportamento espectral de perfil 14: LATOSSOLO AMARELO Distrófico psamítico



Fonte: A autora.

3.3.3.5 Luvissole

Os dois perfis de Luvissole avaliados apresentaram elevado albedo, com fator de reflectância $\geq 0,69$. O comportamento e a morfologia espectral exibiram padrão semelhante entre os perfis, caracterizado por curva com forma inicialmente ascendente, seguida de um trecho plano e, a partir de 2000 nm, ocorreu leve tendência descendente. Foram observadas diferenças na intensidade de reflectância entre os horizontes, atribuídas à influência da matéria orgânica e às variações granulométricas.

De modo semelhante aos Argissolos, a diferenciação textural dos Luvissoles resulta do processo pedogenético de elutriação, no qual ocorre a remoção superficial da argila por erosão, e do processo de argiluviação, que promove a migração da argila dos horizontes superficiais e o consequente acúmulo nos subsuperficiais, (Kämpf; Curi, 2012). Todavia, embora esta classe apresente contraste textural com incremento de argila em profundidade, há expressiva presença de argilominerais do tipo 2:1 (Santos *et al.*, 2025), o que a diferencia dos Argissolos e evidencia o estágio intermediário de desenvolvimento. A análise espectral

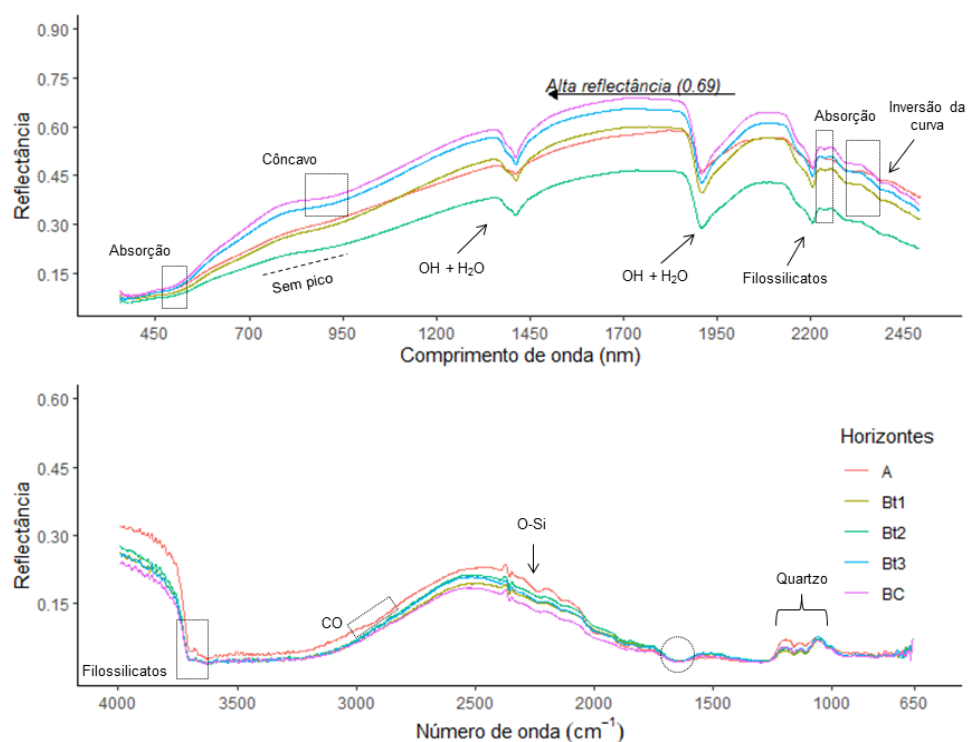
identificou tais aspectos texturais e mineralógicos, sobretudo nos horizontes subsuperficiais, que são diagnósticos para classificação do solo.

Na faixa vis-NIR-SWIR, o comportamento espectral dos perfis exibiu feições associadas aos óxidos de ferro, indicando predomínio de hematita, devido à baixa intensidade de reflectância no início do espectro. Observaram-se ainda no SWIR, absorções mais pronunciadas e profundas em 1900 nm, indicativas do predomínio de argilomimerais 2:1. Entre 2261-2440 nm, foram identificadas absorções atribuídas aos carbonatos e as micas (Meneses; Almeida; Baptista, 2019), coincidindo com o menor desenvolvimento desse solo.

Nos Luvissoles, é comum a alta saturação por bases e a presença de minerais menos intemperizados (Santos *et al.*, 2025). Estes aspectos, associado à geologia e o baixo intemperismo químico da região, favorecem a permanência nos solos de minerais primários como as micas, a formação dos minerais secundários argilominerais 2:1 e a ocorrência de carbonatos, que foi corroborado pela maior concentração de Ca e Mg nos perfis.

Na região do SWIR, também foi verificada a inversão das curvas devido à diferença textural, ocorrendo em trechos distintos dos perfis, o que sugere diferenças na composição mineralógica específica. No perfil 4 (Figura 19), a inversão ocorreu em 2350 nm, enquanto no perfil 21 ocorreu em 1800 nm.

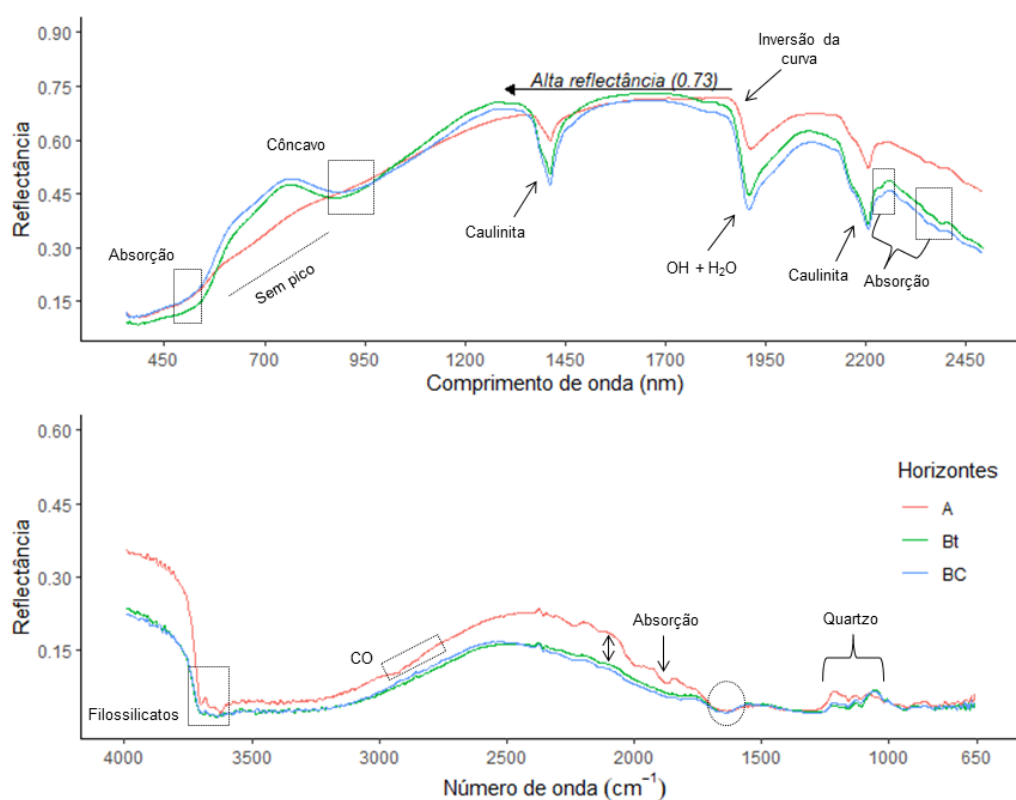
Figura 19 – Comportamento espectral de perfil 4: LUVISSOLO HÁPLICO Pálico abrupto



Fonte: A autora.

Na faixa MIR, os horizontes superficiais exibiram a maior intensidade de reflectância, atribuído ao maior teor de areia desses horizontes. Observaram-se feições de absorção de filossilicatos no início do espectro e picos de quartzo entre 1250-1000 cm^{-1} , os quais foram menos intensos em virtude do menor teor de quartzo nos perfis, que apresentaram textura média. As feições em 2920 e 2880 cm^{-1} foram mais visíveis no perfil 21 (Figura 20), devido ao seu maior conteúdo de CO, ocorrendo ainda absorções entre 1750-1600 cm^{-1} , associadas a diferentes formas de CO na matéria orgânica. Próximo a esta região, em 1800 cm^{-1} , a feição de absorção é atribuída aos carbonatos (Wijewardane *et al.*, 2018).

Figura 20 – Comportamento espectral de perfil 21: LUVISSOLO CRÔMICO Órtico abrupção



Fonte: A autora.

3.3.3.6 Neossolo

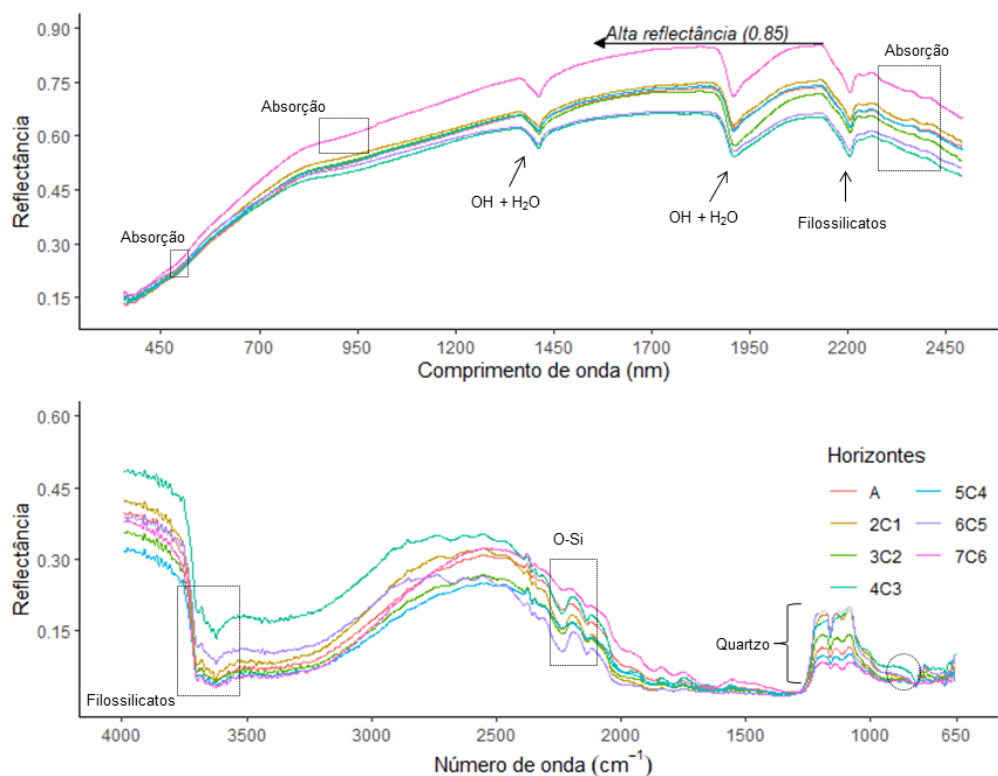
Os seis perfis de Neossolos avaliados apresentaram alta reflectância, com intensidade variando entre 0,64 e 0,90 na faixa vis-NIR-SWIR. Este comportamento está associado ao elevado teor da fração areia e à significativa contribuição do mineral quartzo. A morfologia espectral foi semelhante entre os perfis, exibindo aspecto ascendente até aproximadamente 1300 nm, seguido por trecho de tendência plana.

Apesar dos perfis terem exibido curvas espectrais com características semelhantes, observaram-se diferenças na intensidade de reflectância entre os horizontes, atribuídas principalmente ao efeito da matéria orgânica e às variações granulométricas. Em algumas subordens de Neossolos, como nos Flúvicos e Quartzarênicos, ocorre adição de partículas minerais na superfície do solo pela ação eólica, hidrológica e coluvial, resultado do processo pedogenético de aggradação – acúmulo de sedimentos (Kämpf; Curi, 2012).

Os três perfis de Neossolos Flúvicos avaliados exibiram variações na intensidade de reflectância, sem, contudo, apresentarem um padrão definido entre os horizontes em qualquer das faixas espectrais. Tal comportamento deve-se à estratificação das camadas com influência de diferentes materiais, característica típica desta subordem. Estes solos são derivados de sedimentos aluviais com caráter flúvico até 150 cm de profundidade, o que resulta em camadas estratificadas e distribuição irregular do CO (Santos *et al.*, 2025).

Dentre os Neossolos Flúvicos, o perfil 1 apresentou a reflectância mais elevada, atribuída ao seu maior conteúdo de areia, conforme indicado pela classificação Psamítico no terceiro nível. Neste perfil, observaram-se pequenas absorções nos horizontes subsuperficiais, entre 800-950 nm, indicando baixos teores de óxidos de ferro (Figura 21).

Figura 21 – Comportamento espectral de perfil 1: NEOSSOLO FLÚVICO Psamítico típico

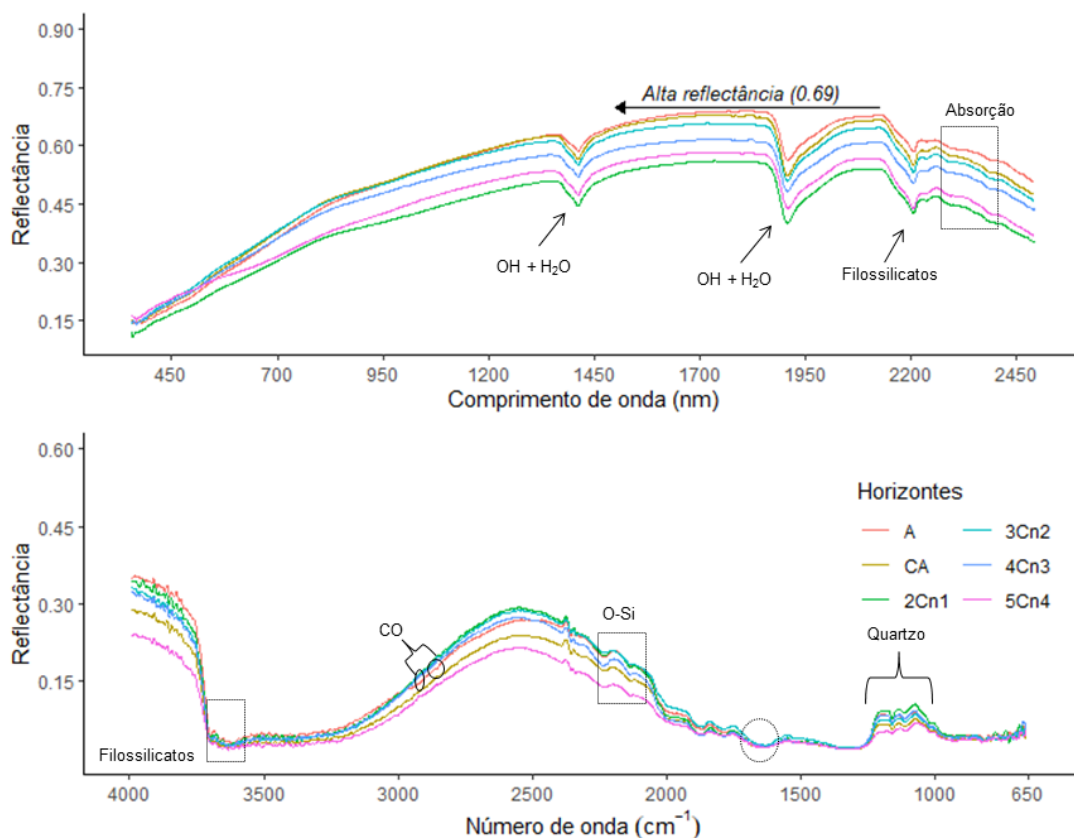


Fonte: A autora.

Na faixa vis-NIR-SWIR, as feições de absorção dos filossilicatos foram mais intensas em 1900 nm, indicando a predominância de minerais 2:1. Foram observadas também absorções entre 2340-2400 nm atribuídas às micas, o que condiz com o baixo desenvolvimento pedogenético dos Neossolos, que mantêm características do material de origem (Santos *et al.*, 2025). Estes aspectos, que são típicos de solos pouco evoluídos, afetam diretamente o comportamento espectral e a sua identificação auxilia na classificação do solo no primeiro nível categórico.

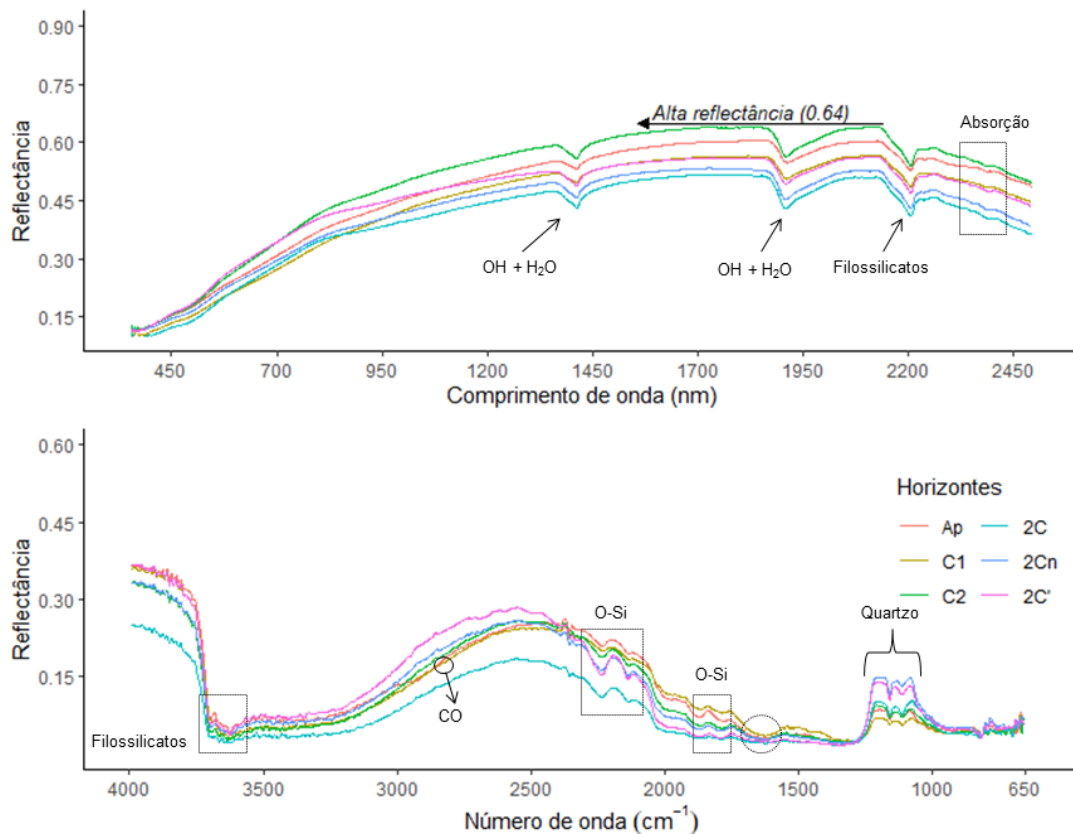
Na região do MIR, observaram-se absorções dos filossilicatos no início do espectro e uma feição mais profunda em torno de 1624 cm^{-1} , atribuída a presença de minerais do tipo 2:1 (Souza *et al.*, 2021), associada a diferentes formas de CO (Rossel *et al.*, 2008). Os picos de quartzo entre $1250\text{-}1000\text{ cm}^{-1}$ foram mais suaves nos perfis 7 (Figura 22) e 15 (Figura 23), do que no perfil 1, em virtude de seus menores teores de areia.

Figura 22 – Comportamento espectral de perfil 7: NEOSSOLO FLÚVICO Sódico típico



Fonte: A autora.

Figura 23 – Comportamento espectral de perfil 15: NEOSSOLO FLÚVICO Ta Eutrófico solódico



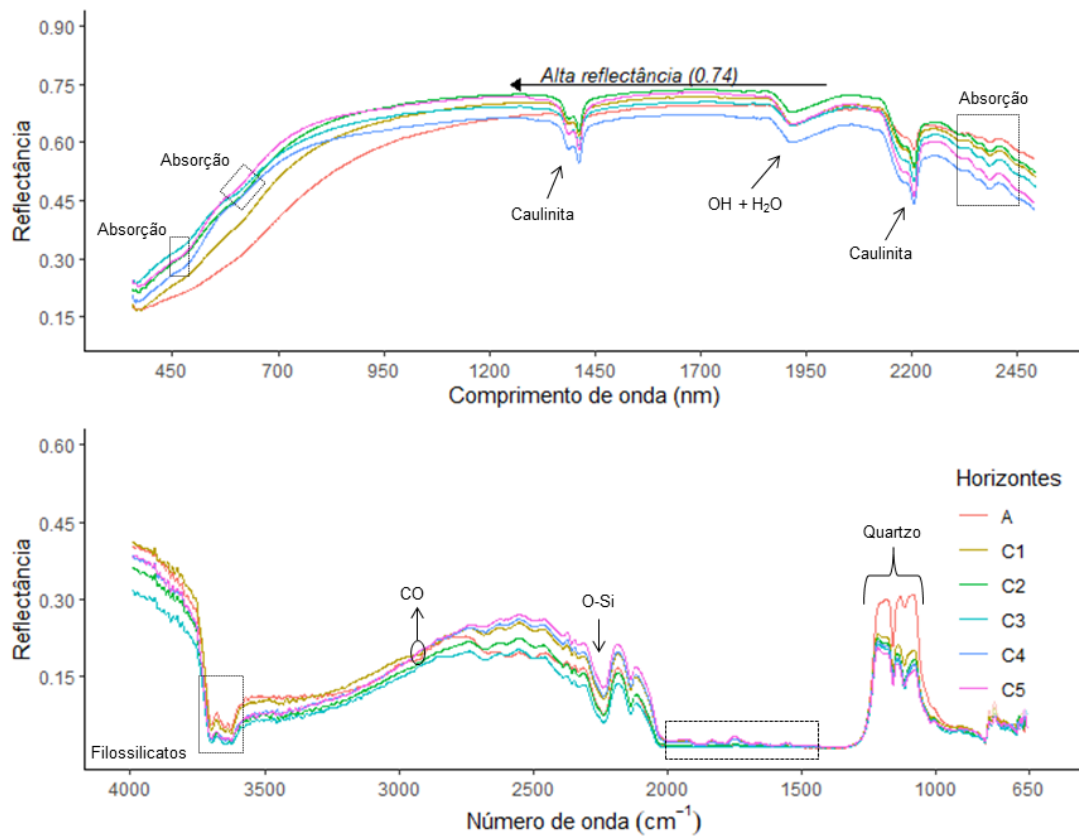
Fonte: A autora.

Nos Neossolos Quartzarênicos, os dois perfis avaliados apresentaram maior reflectância na faixa vis-NIR-SWIR para os horizontes subsuperficiais. Esta maior reflectância está relacionada aos seus menores teores de argila e carbono orgânico, em função da textura arenosa típica desta subordem.

Na faixa MIR, observaram-se absorções características dos filossilicatos entre 3695-3300 cm⁻¹ e do CO entre 2924-2843 cm⁻¹. Além disso, verificou-se forte absorção em 1750-1250 cm⁻¹, atribuída ao elevado conteúdo de quartzo no solo. Solos arenosos com baixo teor de hematita e alto teor de quartzo tendem a exibir acentuada absorção em torno de 1350 cm⁻¹, com curvas espectrais mais próximas do eixo X (Di Raimo *et al.*, 2022).

O perfil 2 (Figura 24) apresentou, na faixa vis-NIR, feições de óxidos de ferro muito suaves, enquanto as absorções dos filossilicatos foram típicas da caulinita, evidenciadas pela ocorrência de um ombro à esquerda da feição.

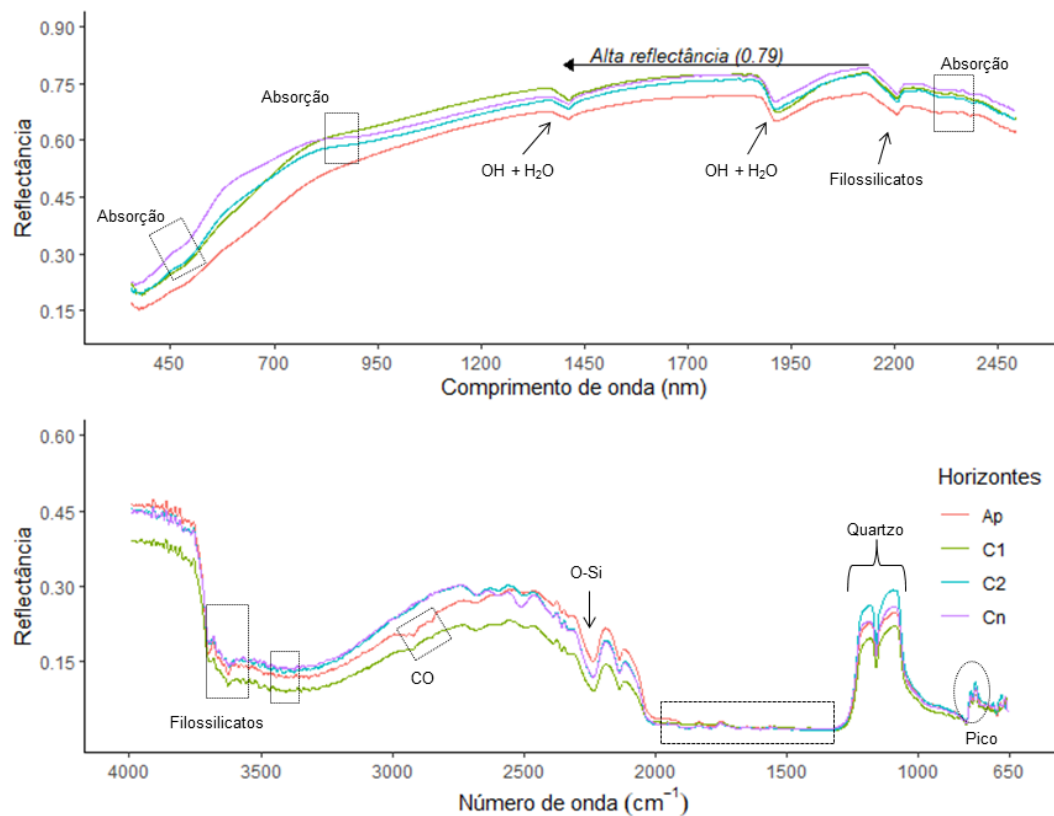
Figura 24 – Comportamento espectral de perfil 2: NEOSSOLO QUARTZARÊNICO Órtico típico



Fonte: A autora.

Por sua vez, o perfil 13 (Figura 25) exibiu feições indicativas da predominância de minerais do tipo 2:1, expressas pela absorção mais profunda em 1900 nm. Observou-se ainda na região vis-NIR uma concavidade típica dos óxidos de Fe. Na faixa MIR, as feições atribuídas ao CO em 2924-2843 cm^{-1} , foram mais fortes, com absorções evidentes no horizonte superficial e no subsequente, sugerindo maior conteúdo de CO. Além disso, foi observada a ocorrência de um pico em 800 cm^{-1} , atribuído ao quartzo (Mendes *et al.*, 2022).

Figura 25 – Comportamento espectral de perfil 13: NEOSSOLO QUARTZARÊNICO Hidromórfico típico



Fonte: A autora.

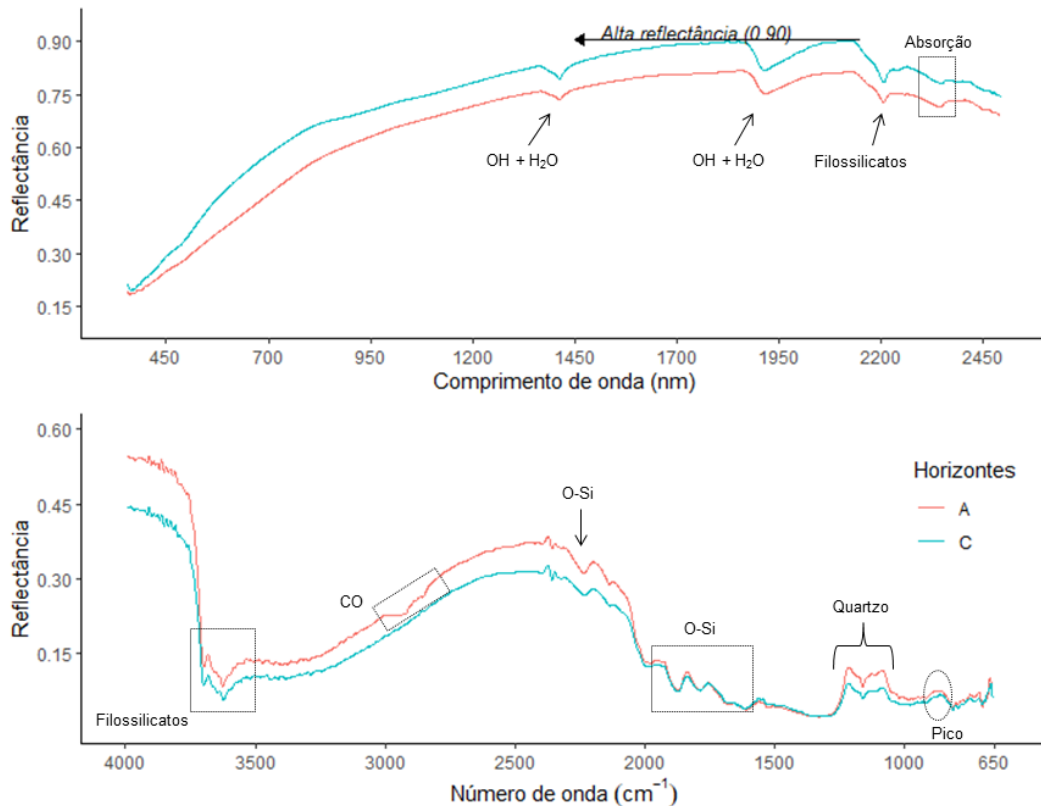
O perfil de Neossolo Litólico apresentou o maior albedo entre todos os perfis avaliados (Figura 26). Na faixa vis-NIR-SWIR, a alta reflectância observada no horizonte subsuperficial está associada ao maior conteúdo de silte, enquanto, na região, MIR a elevada reflectância do horizonte superficial é atribuída ao maior teor de quartzo. Conforme foi verificado no perfil 20 de Cambissolo (Figura 16), o alto teor de silte, especialmente no horizonte subsuperficial que possui menor conteúdo de CO, associado à ocorrência de argilominerais do tipo 2:1, contribui para o aumento da intensidade de reflectância, configurando-se com um padrão espectral para solos menos intemperizados.

A faixa vis-NIR-SWIR foi afetada pelo maior conteúdo de CO, característico desta ordem de solo, que pode ser constituída por material orgânico pouco espesso (Santos *et al.*, 2025). Neste sentido, ocorreu feição com aspecto convexo até cerca de 1000 nm, e as absorções dos filossilicatos em 1400, 1900 e 2200 nm foram atenuadas. Observou-se uma feição mais profunda na banda de 1900 nm indicando a predominância de argilominerais do tipo 2:1, e uma absorção em 1340 nm atribuída às micas.

Para a região do MIR, observaram-se absorções associadas aos filossilicatos,

carbono orgânico e quartzo, além da presença de picos associados ao quartzo em 1250-1000 cm^{-1} e 800 cm^{-1} , sendo as feições de quartzo mais pronunciadas no horizonte A em virtude de seu maior conteúdo de areia.

Figura 26 – Comportamento espectral de perfil 23: NEOSSOLO LITÓLICO Eutrófico típico



Fonte: A autora.

3.3.3.7 Planossolo

Os quatro perfis de Planossolos avaliados apresentaram elevada reflectância, com intensidade variando entre 0,69 e 0,84 na faixa vis-NIR-SWIR, evidenciando a forte contribuição da fração areia para o aumento do albedo. A morfologia espectral foi semelhante entre os perfis, com aspecto ascendente até aproximadamente 1300 nm, seguido por um trecho de tendência plana, especialmente nos horizontes de maior reflectância. Observaram-se diferenças na intensidade de reflectância entre os horizontes, atribuídas à influência da matéria orgânica e às variações granulométricas, de modo que os horizontes A e E, mais arenosos, exibiram maior reflectância e comportamento espectral semelhante.

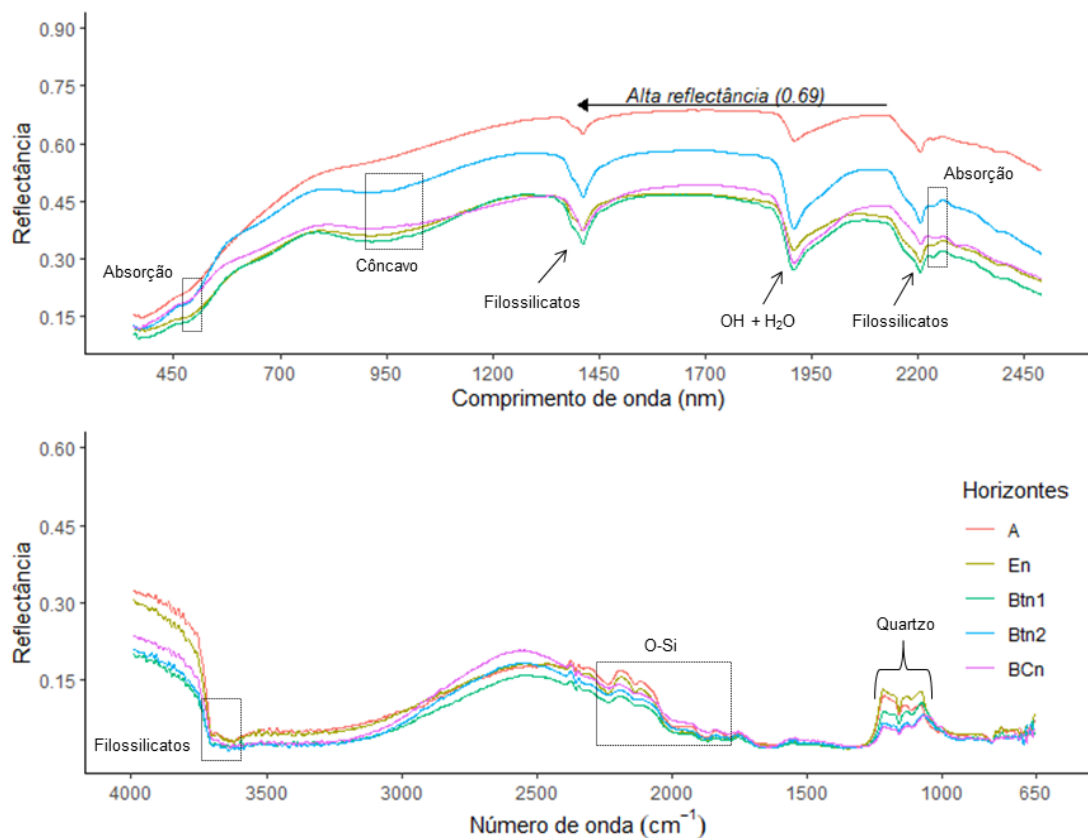
Os Planossolos possuem horizonte superficial (A) ou subsuperficial (E) de eluviação, com textura leve, enquanto o horizonte B exibe, em geral, maior concentração de

argila (Santos *et al.*, 2025). Tal configuração resulta do processo pedogenético de ferrólise, que promove a destruição de argilominerais do horizonte superficial a partir da oxidação do Fe e produz gradiente textural no horizonte B (Kämpf; Curi, 2012).

O comportamento espectral dos perfis de Planossolo Nátrico na faixa vis-NIR-SWIR apresentou feições associadas aos óxidos de Fe, aos filossilicatos 2:1 e 1:1 e às micas. Estas feições foram mais pronunciadas nos horizontes subsuperficiais B, visto que o maior teor de matéria orgânica no horizonte A reduz a reflectância e mascara as absorções dos óxidos de Fe (Demattê; Terra, 2014). Assim, na faixa MIR, as feições associadas ao CO foram mais visíveis no horizonte A, corroborando o seu maior conteúdo de matéria orgânica.

O perfil 3 (Figura 27) apresentou feições indicativas da ocorrência de argilominerais do tipo 2:1 e 1:1, destacando-se dos demais perfis pela alta reflectância do horizonte Bt, superior a do horizonte En na faixa vis-NIR-SWIR, possivelmente em razão do menor teor de CO neste horizonte.

Figura 27 – Comportamento espectral de perfil 3: PLANOSSOLO NÁTRICO Órtico típico



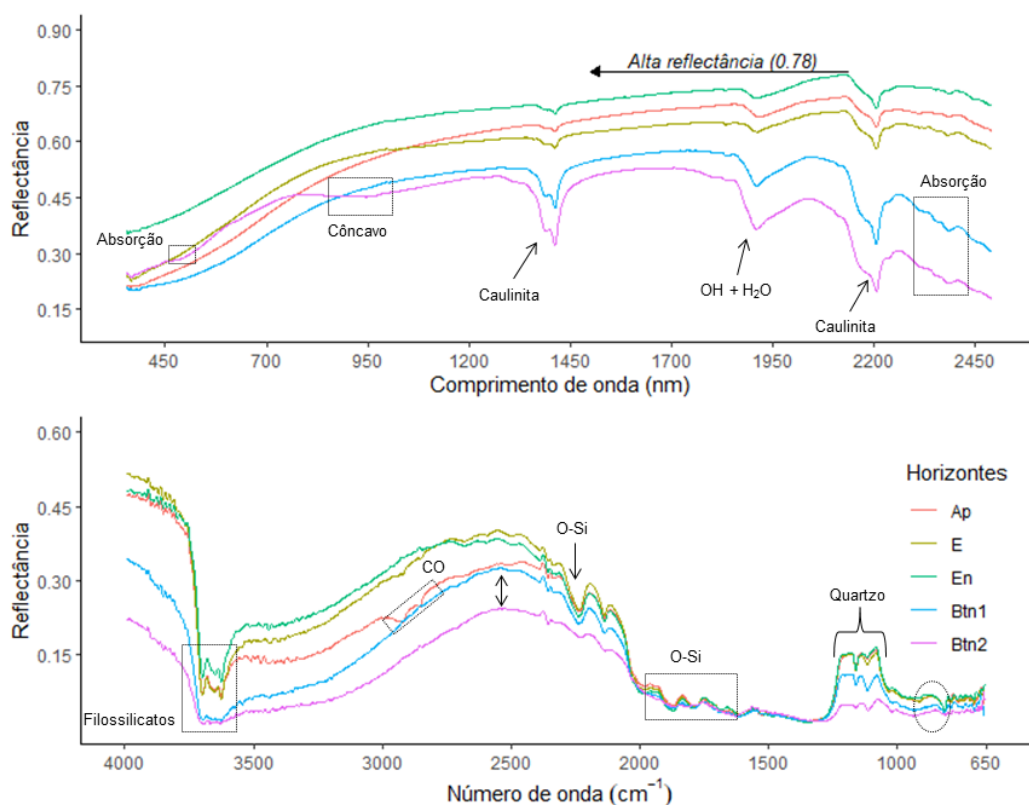
Fonte: A autora.

Por sua vez, o perfil 10 (Figura 28) apresentou na faixa vis-NIR-SWIR feições típicas de caulinita, com absorções fortes em 1400 e 2200 nm, indicando predomínio deste

mineral. Já no MIR, as absorções típicas dos filossilicatos no início do espectro foram intensas. As características nítidas entre 3700-3600 cm^{-1} são associadas ao padrão de absorção da caulinita (Di Raimo *et al.*, 2022). Além disso, observou-se que as feições de absorção em 2250 cm^{-1} e os picos de reflectância entre 1250-1000 cm^{-1} , atribuídos ao quartzo, foram mais pronunciados nos horizontes E em virtude do seu maior teor de areia e menor CO.

O horizonte E é formado a partir do processo de leucinização, em que os compostos orgânicos e os óxidos de ferro são removidos e o horizonte E é desenvolvido com coloração clara devido à ação dos minerais primários, especialmente o quartzo. Além disso, ocorre remoção dos cátions básicos (Kämpf; Curi, 2012). O maior teor de quartzo deste horizonte se reflete diretamente no aumento da intensidade de reflectância.

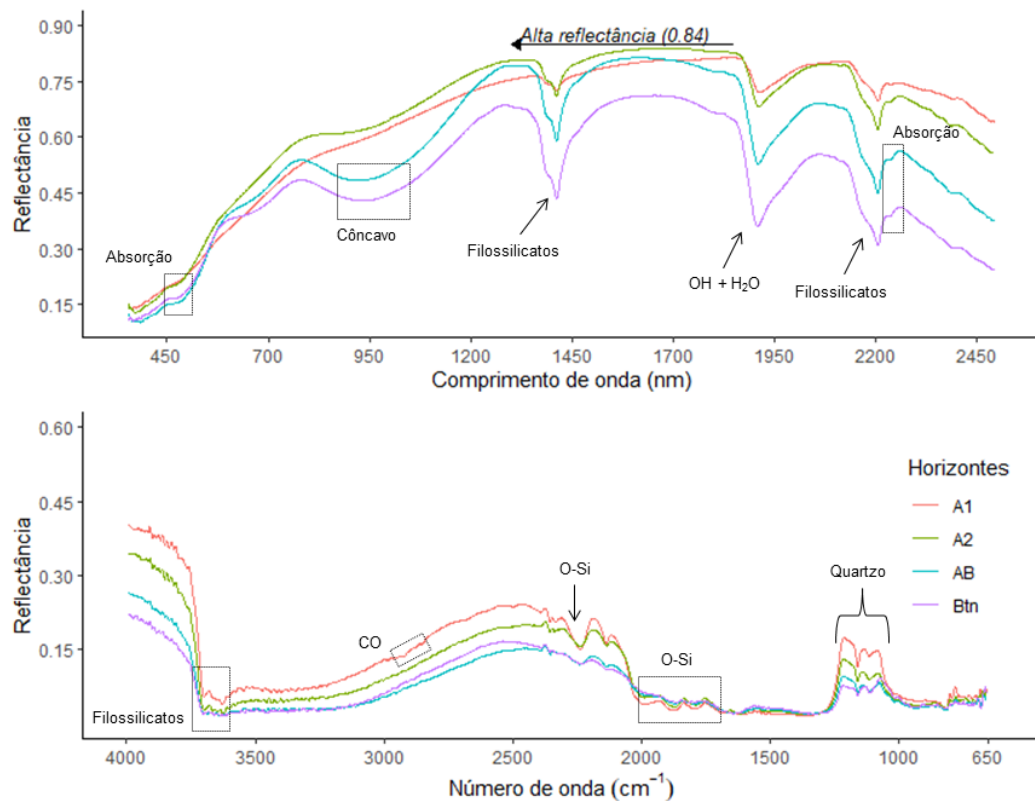
Figura 28 – Comportamento espectral de perfil 10: PLANOSSOLO NÁTRICO Órtico mésico



Fonte: A autora.

O perfil 17 exibiu na região vis-NIR-SWIR feições indicativas da predominância de argilominerais 2:1, com absorção mais profunda em 1900 nm, enquanto uma leve dissimetria na curva espectral em 2200 nm evidenciou também a presença de caulinita em menor quantidade (Figura 29). Na faixa MIR, o horizonte A1 se destacou pela maior reflectância, corroborando seu maior conteúdo da fração areia.

Figura 29 – Comportamento espectral de perfil 17: PLANOSSOLO NÁTRICO Órtico mésico

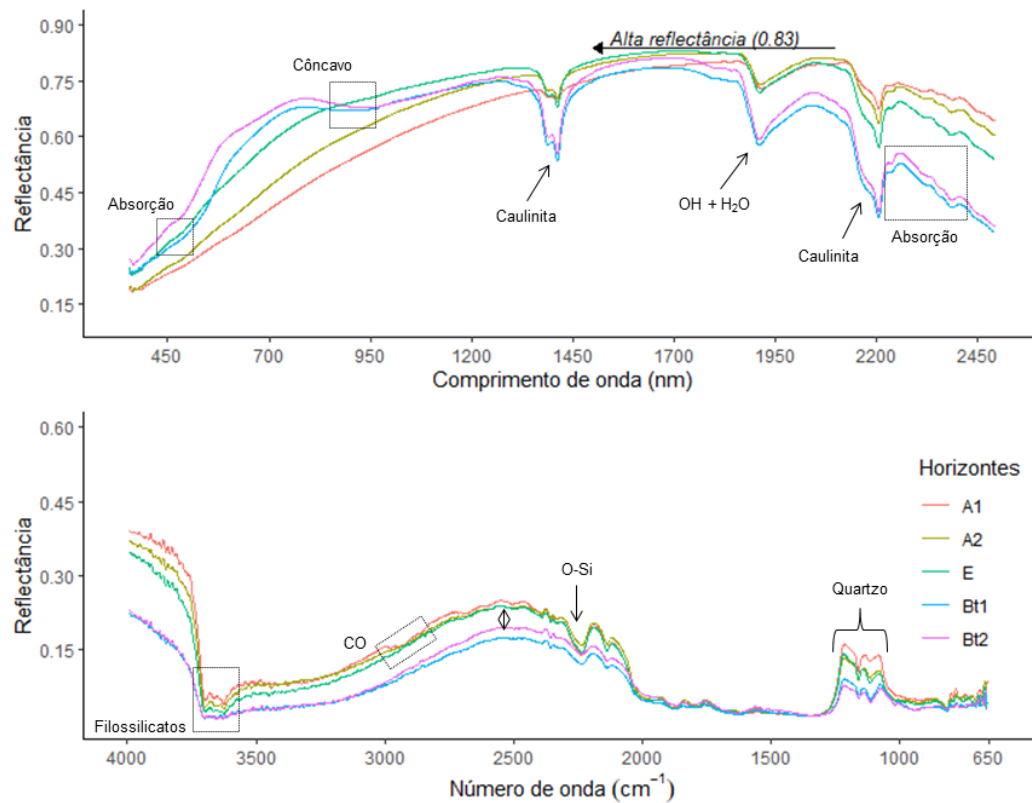


Fonte: A autora.

O perfil de Planossolo Háplico apresentou pequena diferença da intensidade de reflectância entre os horizontes, atribuída principalmente a granulometria (Figura 30). Observaram-se na faixa vis-NIR-SWIR feições típicas de caulinita, e absorções atribuídas às micas entre 2300-2440 nm, que têm ocorrência comum nesse solo, visto que os Planossolos apresentam teores consideráveis de minerais primários de fácil intemperização (Levantamento de reconhecimento de média intensidade dos solos do Estado do Ceará, 2024). Embora as absorções associadas às micas tenham ocorrido também nos perfis de Planossolo Nátrico, as feições foram mais pronunciadas neste perfil, sugerindo maior conteúdo.

Na região do MIR, ocorreram feições associadas aos filossilicatos, CO e quartzo, sendo que as absorções do CO foram verificadas apenas nos horizontes superficiais em virtude do conteúdo mais elevado de matéria orgânica. Os picos de reflectância atribuídos ao quartzo foram mais intensos no horizonte A, indicando conteúdo superior da fração areia neste horizonte.

Figura 30 – Comportamento espectral de perfil 22: PLANOSSOLO HÁPLICO Eutrófico típico



Fonte: A autora.

3.3.3.8 Plintossolo

O perfil de Plintossolo apresentou alta reflectância, com intensidade máxima de 0,79 (Figura 31). A morfologia espectral exibiu curva de formato inicialmente ascendente, seguido por trecho plano e, a partir de 1950 nm, leve tendência descendente. O comportamento espectral mostrou diferenças entre as faixas. Na região vis-NIR-SWIR observou-se nítida diferenciação entre horizontes, com os horizontes subsuperficiais exibindo maior reflectância, enquanto os horizontes superficiais apresentaram valores reduzidos. No MIR, por sua vez, não houve grandes diferenças de intensidade, embora o horizonte superficial tenha mostrado reflectância ligeiramente maior nas regiões associadas ao quartzo.

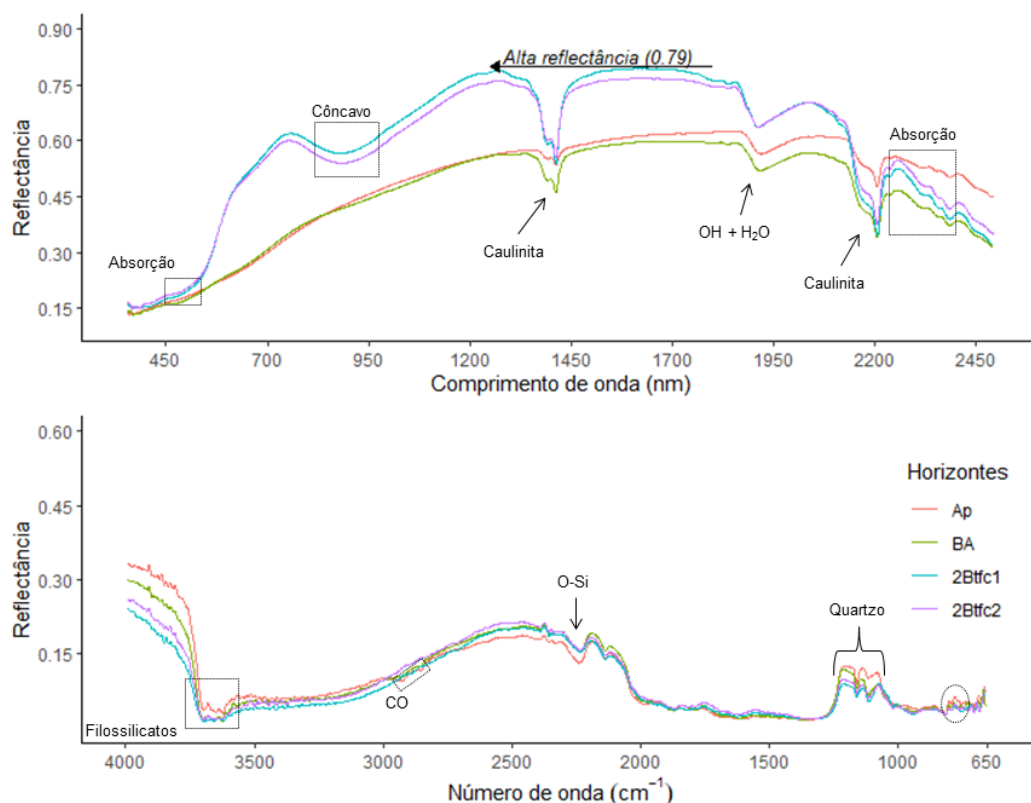
Apesar de apresentar textura mais arenosa do que os horizontes subsuperficiais, o horizonte superficial teve sua reflectância significativamente reduzida pelo maior conteúdo de CO, o que também mascarou as feições dos óxidos de ferro e conferiu aspecto convexo a curva espectral na região vis-NIR (Figura 31). A maior concentração de CO é coerente com a

coloração cinzento-escuro a bruno-acinzentada, frequentemente observada no horizonte superficial dos Plintossolos (Levantamento de reconhecimento de média intensidade dos solos do Estado do Ceará, 2024).

Na faixa vis-NIR-SWIR, foram observadas feições acentuadas dos óxidos de Fe, indicativas da predominância de hematita, caracterizada pela reflectância mais baixa no início do espectro e concavidade estreita entre 800-1000 nm. A presença marcante de óxidos de Fe é típica deste solo, resultante do processo pedogenético de plintitização, caracterizado pela translocação de Fe na forma reduzida e sua posterior precipitação por oxidação, associada à dessilicação do solo (Kämpf; Curi, 2012). Estas características foram evidenciadas, sobretudo, nos horizontes subsuperficiais, que, embora mais argilosos, não sofrem efeito do CO.

Na região do MIR, observaram-se feições atribuídas aos filossilicatos, CO e quartzo, sendo os picos de quartzo em $1250\text{-}1000\text{ cm}^{-1}$ e 800 cm^{-1} mais pronunciados no horizonte A. As feições atribuídas ao quartzo foram mais suaves no Plintossolo, em comparação aos perfis de solos mais arenosos. Este comportamento deve-se a textura mais argilosa deste solo, conforme evidenciado pela sua classificação no segundo nível categórico.

Figura 31 – Comportamento espectral de perfil 24: PLINTOSSOLO ARGILÚVICO Eutrófico petroplíntico



Fonte: A autora.

3.3.3.9 Vertissolo

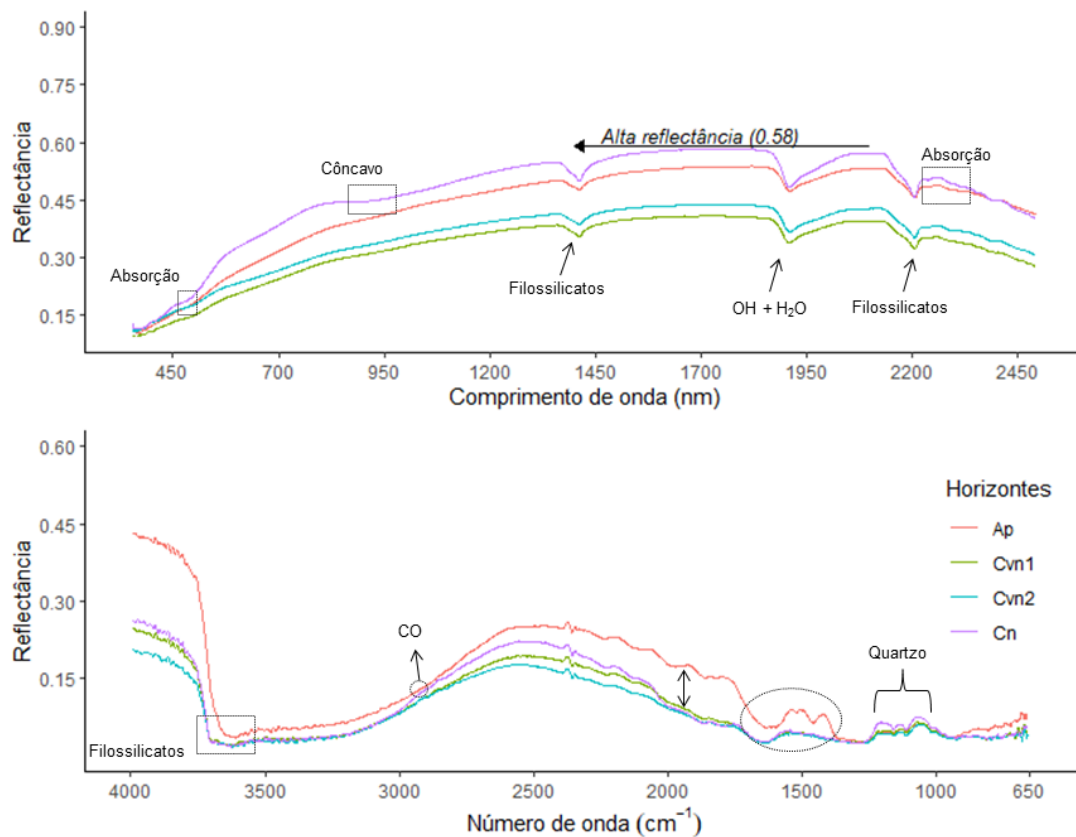
O perfil de Vertissolo apresentou alta reflectância, com intensidade máxima de 0,58 (Figura 32). Entretanto, este perfil exibiu o menor albedo entre todos os solos avaliados, o que é atribuído ao menor teor de areia e à textura média. Os Vertissolos apresentam pequena variação textural ao longo do perfil, geralmente com textura argilosa, embora possam apresentar textura média (Santos *et al.*, 2025). Quanto à morfologia espectral, observou-se formato inicialmente ascendente, seguido por trecho plano a partir de 1450 nm. O comportamento espectral exibiu diferenças de intensidade de reflectância entre os horizontes.

Na faixa vis-NIR-SWIR, o horizonte Cn apresentou curva com suave concavidade entre 800-1000 nm, indicando presença de pequena quantidade de óxidos de Fe, enquanto as curvas dos demais horizontes exibiram aspecto convexo, associado ao seu conteúdo de CO. Foram observadas feições atribuídas aos argilominerais 2:1, com absorção mais intensa em 1900 nm. Entre 2261-2440 nm, ocorreram absorções associadas aos carbonatos e às micas, comuns a este solo, que possui desenvolvimento incipiente e alta saturação por bases (Santos *et al.*, 2025), conforme evidenciado pelos teores elevados de Ca e Mg.

A presença de argilominerais 2:1 é característica dos Vertissolos, nos quais ocorre o processo pedogenético de vertização. Este processo é típico de solos com predomínio de argilominerais esmectíticos e resulta na formação de fendas, agregados cuneiformes e superfícies de fricção. Estes minerais esmectíticos podem formar associações estáveis com o CO, conferindo coloração escura aos horizontes superficiais (Kämpf; Curi, 2012), o que contribui para a redução da reflectância destes horizontes.

Na região do MIR, observou-se que as feições atribuídas aos filossilicatos do tipo 1:1 e ao quartzo foram mais suaves, refletindo a mineralogia dos Vertissolos que é dominada por filossilicatos 2:1 e apresenta teor mais baixo de areia. O horizonte Ap destacou-se na faixa entre 2000-1250 cm^{-1} , com comportamento distinto dos demais horizontes, o que é atribuído ao seu elevado teor de CO. De modo mais específico, na região de 1725-1275 cm^{-1} , as fortes absorções são atribuídas a diferentes grupos funcionais da matéria orgânica, associado à banda de absorção da água aproximadamente em 1600 cm^{-1} (Rossel *et al.*, 2008; Zhang; Hartemink; Huang, 2021), que pode ser amplificada pela água adsorvida na estrutura dos argilominerais 2:1, típicos dessa classe de solo.

Figura 32 – Comportamento espectral de perfil 16: VERTISSOLO EBÂNICO Sódico salino

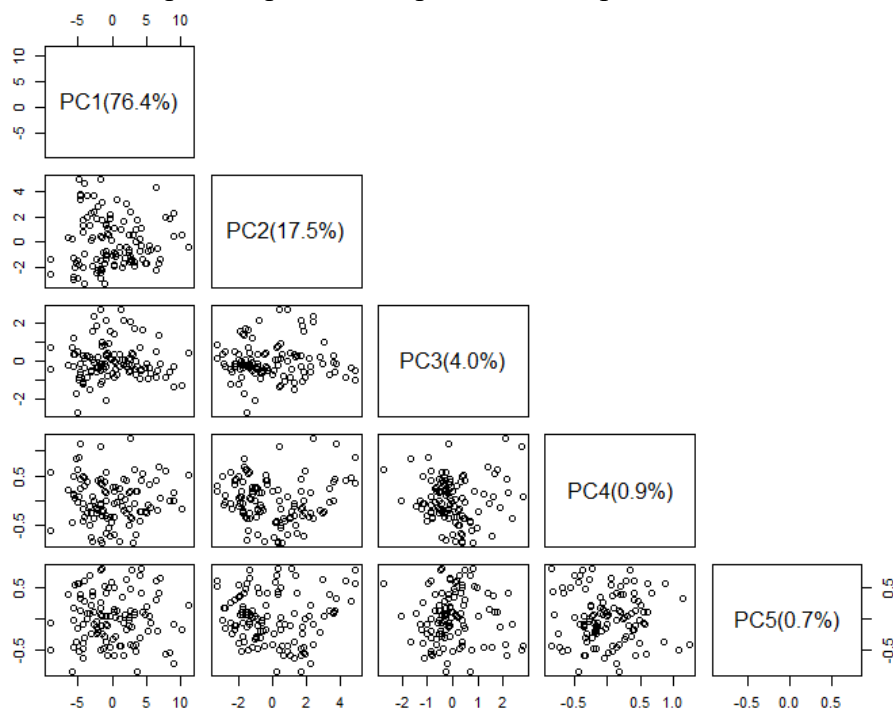


Fonte: A autora.

3.3.4 Agrupamento de horizontes do solo na faixa espectral vis-NIR-SWIR

A análise de componentes principais (ACP), aplicada sobre os espectros de reflectância suavizados, resultou na extração dos cinco primeiros componentes que foram utilizados para a classificação não supervisionada. Estes componentes principais explicaram 99,5% da variabilidade total dos dados, sendo que o maior percentual de variação foi explicado pelo primeiro componente, com redução progressiva nos componentes subsequentes (Figura 33).

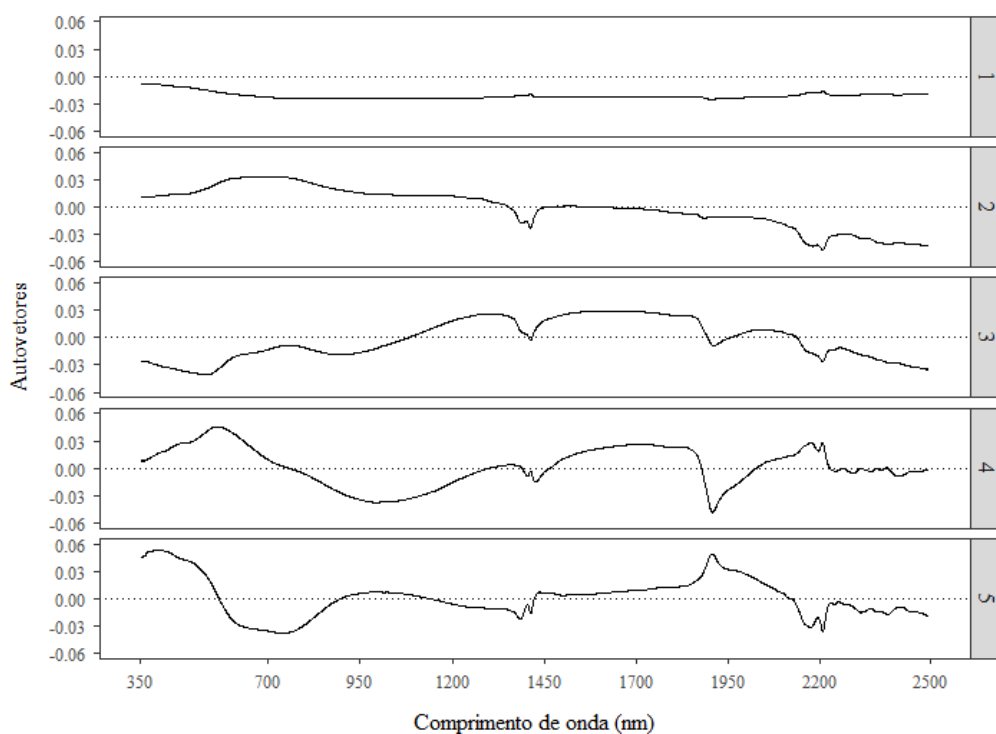
Figura 33 – Variância explicada pelas cinco primeiras componentes na faixa vis-NIR-SWIR



Fonte: A autora.

A análise dos autovetores evidenciou as contribuições positivas e negativas dos valores de reflectância para a produção dos escores de cada componente principal (Figura 34), de forma a destacar as regiões espectrais de maior importância.

Figura 34 – Autovetores da análise de componentes principais na faixa vis-NIR-SWIR

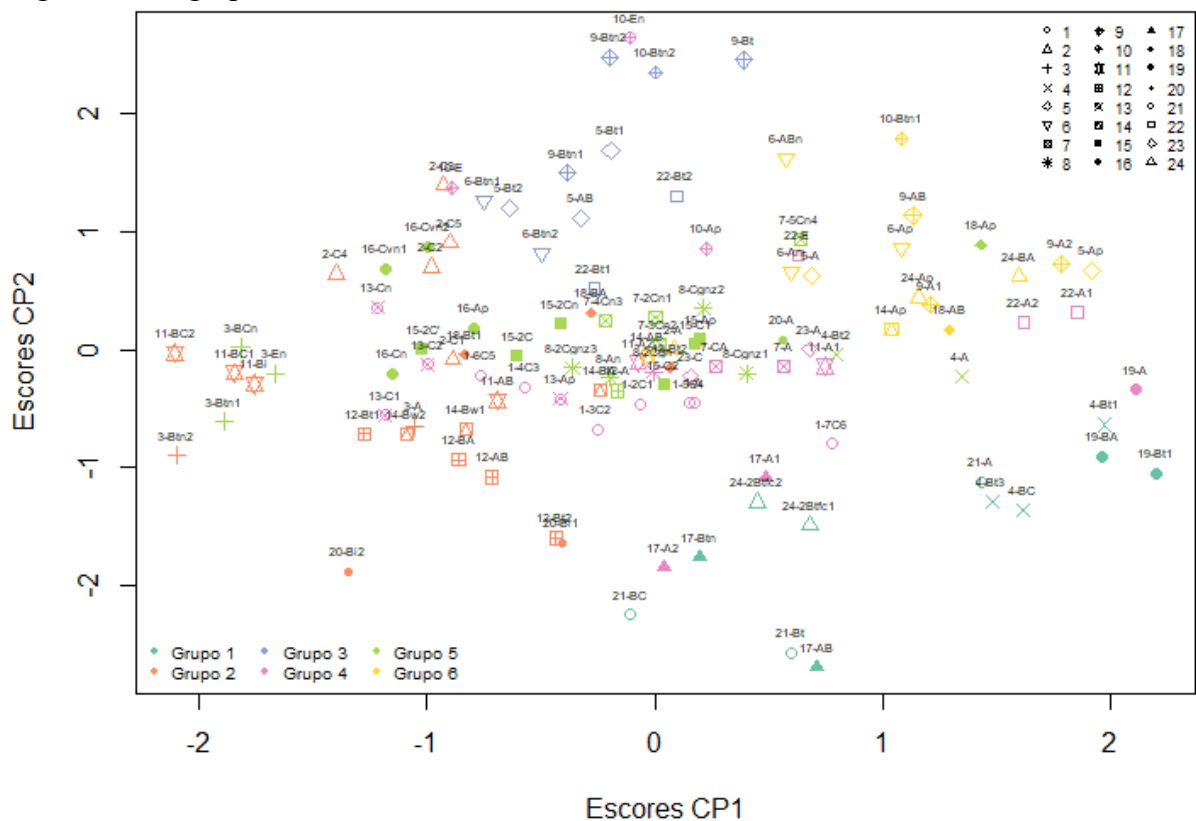


Fonte: A autora.

A primeira componente (CP1) foi dominada por autovetores negativos, com contribuição relativamente constante ao longo do espectro. Já as demais componentes apresentaram padrões contrastantes com autovetores positivos e negativos. Nas CP2, CP3 e CP5 destacaram-se cargas negativas em torno de 2200 nm, região associada a feições de absorção de argilominerais filossilicatos. A CP4, por sua vez, mostrou forte contribuição negativa em 1900 nm, que também está relacionada a esses minerais. Além disso, nas CP3 e CP5, ocorreram cargas negativas entre 500-850 nm, região que é característica de absorções atribuídas aos óxidos de ferro (Madeira Netto; Baptista, 2000).

A classificação não supervisionada pelo método K-médias, utilizando os escores obtidos na ACP, resultou na separação das amostras de solos em seis grupos distintos (Figura 35). O número ótimo de grupos foi definido com base no menor valor do coeficiente de partição (= 0,59) e no maior valor da entropia de partição (= 0,87).

Figura 35 – Agrupamento das amostras de solos com escores da ACP na faixa vis-NIR-SWIR



Cada símbolo representa um perfil de solo identificado por seu número. Cada cor representa um grupo.
Fonte: A autora.

A quantidade de amostras de solo nos grupos, bem como a identificação dos horizontes pedológicos que integraram cada grupo e a respectiva classificação do solo pode ser visualizada na Tabela 2.

Tabela 2 – Identificação de amostras do solo por grupo na faixa vis-NIR-SWIR

Grupos	Horizontes							Total	Solos
	A	AB	E	BA	B	BC	C		
1	1	1		1	3	2		8	TXp, SNo, PVd, TCo, FTe
2	1	2		3	12		5	23	RQo, SXo, CXe, PVAd, LAd, PVAd, CXd
3		1			10			11	PACe, PAd, PAdx, SNo, SXe
4	12		3				12	27	RYq, RYn, GZn, SNo, CXe, RQg, SNo, PVd, SXe, RLe
5	6		1		2	1	15	25	SNo, TXp, RYn, GZn, PVAd, RYe, VEn, PVAd, CXd
6	10	4		1	1			16	RQo, PACe, PAd, GZn, PAdx, SNo, LAd, PVAd, FTe

As linhas representam os grupos e as colunas representam os horizontes.

Fonte: A autora.

Ao analisar os agrupamentos, observou-se, de modo geral, que os grupos 1 e 3 concentraram, principalmente, amostras do horizonte B textural e suas transições. Os grupos 2 e 5 reuniram amostras dos horizontes superiores e inferiores, embora, tenha havido predomínio de horizontes de subsuperfície. O grupo 4 caracterizou-se pela predominância de amostras superficiais A e subsuperficiais C, além de algumas ocorrências do horizonte E. Já no grupo 6 prevaleceram amostras dos horizontes superficiais e de suas transições, evidenciando a influência da posição do solo na resposta espectral.

De forma semelhante, Demattê *et al.* (2019) também identificaram seis grupos espectrais ao classificar espectros na faixa vis-NIR-SWIR de solos provenientes de diferentes estados do Brasil. Os autores observaram que o padrão espectral destas classes está diretamente ligada aos teores de carbono orgânico, aos óxidos de Fe, à mineralogia da argila e à distribuição granulométrica. Além dos atributos citados, no presente estudo o agrupamento dos solos também foi igualmente influenciado pelo acúmulo de sais, o que torna estes resultados inovadores.

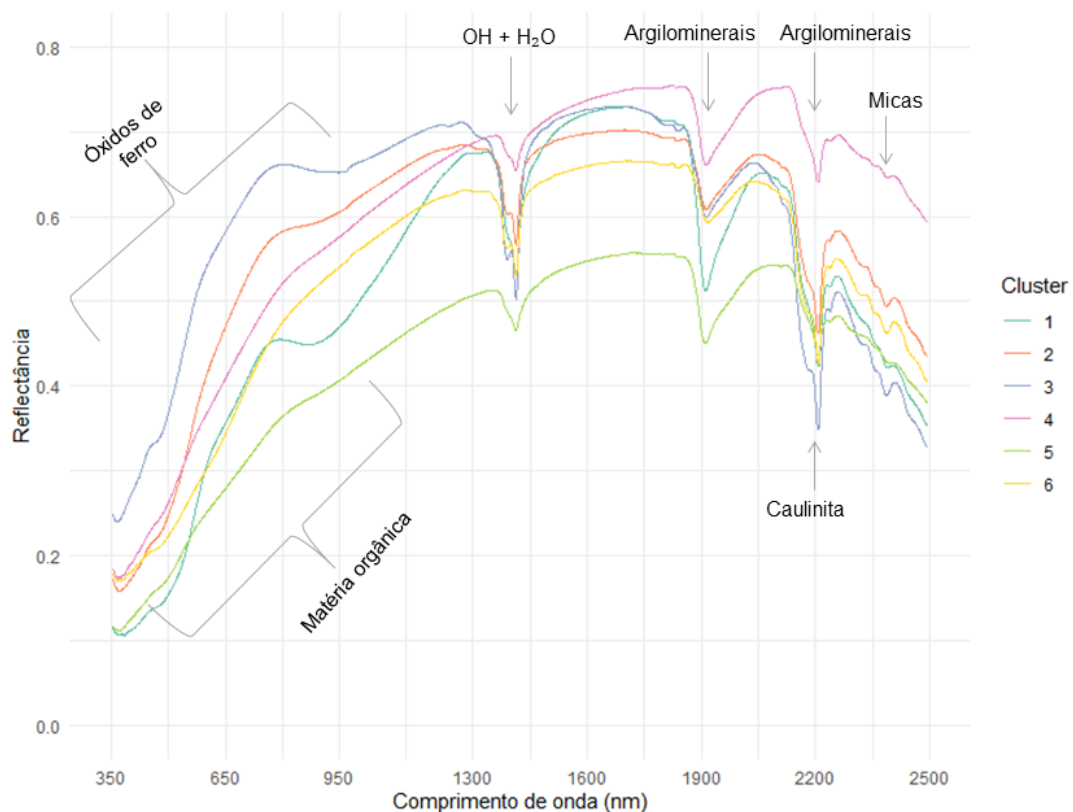
Os resultados obtidos indicaram que a clusterização das amostras de solos não acompanhou a classificação taxonômica dos perfis, uma vez que os solos pertencentes a uma mesma ordem foram distribuídos em clusters distintos. Entretanto, os agrupamentos refletiram uma tendência de distinção entre horizontes, sugerindo que as feições espectrais capturam diferenças estruturais e composicionais do solo. Embora os grupos tenham se diferenciado em

função dos horizontes, observou-se na classificação com a faixa vis-NIR-SWIR a tendência de agrupar amostras com maior estabilidade vertical, de modo que solos com horizontes mais homogêneos, como os Neossolos, mantiveram clusters estáveis ao longo do perfil.

A identificação dos horizontes pedológicos é uma prática indispensável para a classificação dos solos, visto que corresponde ao local de atuação dos processos pedogenéticos e preserva características fundamentais que auxiliam na compreensão da gênese (Zhang; Hartemink; Huang, 2021). Nesta perspectiva, a espectroscopia de reflectância demonstrou capacidade para captar nuances ligada à composição e à diferenciação pedogenética dos horizontes, o que se refletiu na organização espectral em função da estratificação vertical dos perfis de solo.

Esta tendência de distribuição dos agrupamentos dos solos também foi verificada por meio da análise do comportamento espectral médio de cada cluster, a partir dos dados de reflectância suavizados (Figura 36).

Figura 36 – Espectros de reflectância médio por grupo na faixa vis-NIR-SWIR



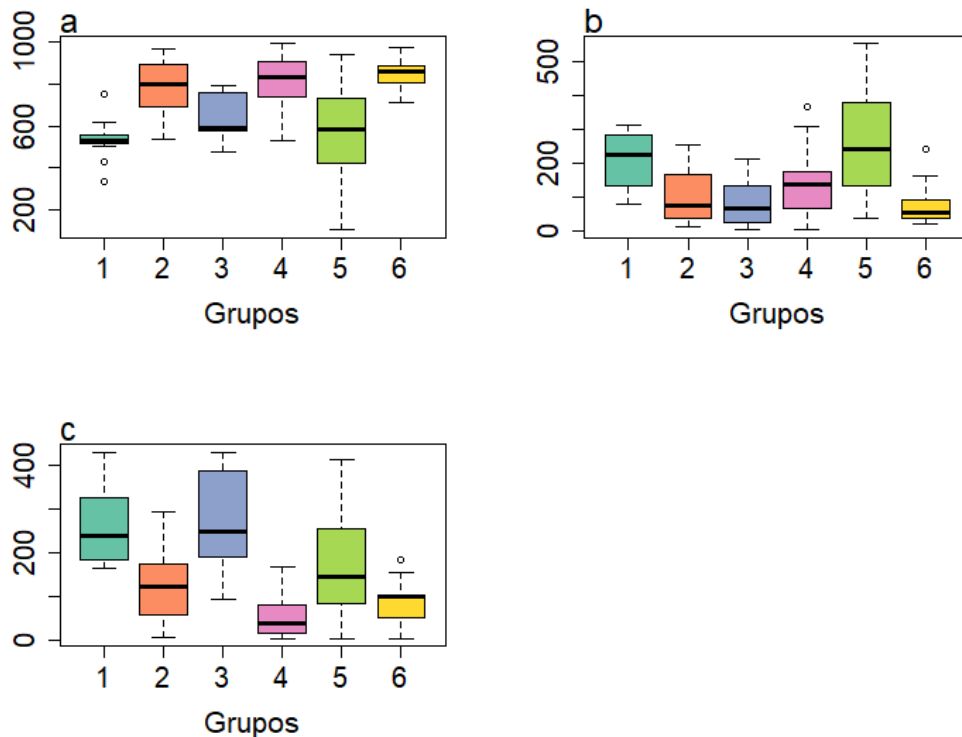
Fonte: A autora.

O comportamento espectral médio dos grupos formados apresentou alta reflectância, alcançando intensidade superior a 0,50 em todos os grupos. Corroborando este resultado, Demattê *et al.* (2019) também observaram elevado albedo nos solos do bioma

Caatinga, tendo sido este comportamento atribuído à predominância da fração areia nos solos, associado ao menor conteúdo de carbono de orgânico em virtude das altas temperaturas que promovem a aceleração da decomposição da matéria orgânica do solo.

Os grupos 1 e 3 apresentaram comportamento espectral médio similar, com feições típicas de óxidos de Fe - goethita e hematita na região vis-NIR. Os espectros desses grupos exibiram também absorções em 1400 e 1900 nm associadas às hidroxilas dos argilominerais 2:1 ou a água estrutural desses minerais. Além disso, observou-se absorções bem definidas em torno de 2200 nm com um ombro do lado esquerdo, atribuída à vibração da ligação Al-OH da caulinita (Meneses; Almeida; Baptista, 2019), e feições a partir de 2300 nm associadas às micas. O grupo 3 exibiu feição intensa em 2200 nm, indicando predominância da caulinita. Esses grupos reuniram horizontes subsuperficiais de Argissolos, Luvisolos, Planossolos e Plintossolos, se caracterizando pela presença de óxidos de Fe e acumulação de argila, que foi corroborado pelo teor superior dessa fração do solo (Figura 37c).

Figura 37 – Variabilidade dos atributos do solo (g kg^{-1}) por grupo na faixa vis-NIR-SWIR: a) areia; b) silte; c) argila



Fonte: A autora.

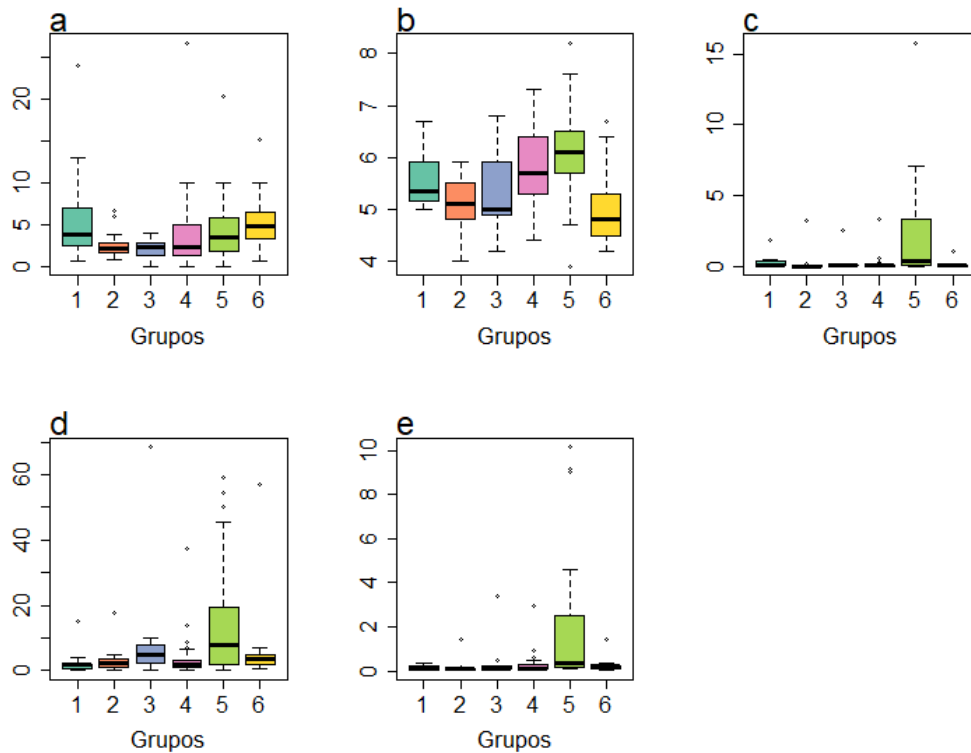
O grupo 2 apresentou feições características de óxidos de Fe na região vis-NIR, contudo estas feições foram suaves. Ocorreram, ainda, absorções em 1400, 1900 e 2200 nm, típicas de argilominerais. Neste cluster incidiram horizontes de Cambissolos, Neossolo

Quartzarênico, Argissolo Vermelho e Latossolo Amarelo. As feições dos óxidos de ferro são atribuídas aos dois últimos solos, enquanto os argilominerais compõem todas as classes de solos. Os resultados sugerem que este cluster não refletiu um processo pedogenético específico, visto que agregou solos com diferentes graus de intemperismo e formados por processos distintos. Em contrapartida, as amostras que compõem o grupo se assemelharam pelo alto conteúdo de areia (Figura 37a), resultando em elevada reflectância ($> 0,60$).

No grupo 4, observaram-se absorções em 1400, 1900 e 2200 nm, sendo as duas últimas feições mais profundas e sem ocorrência de degrau, indicando a prevalência de argilominerais 2:1. Este grupo apresentou o maior fator de reflectância ($> 0,70$), o que se deve a ocorrência de perfis de Neossolos e de horizontes superficiais de Cambissolos e Planossolos. Tais amostras caracterizam-se pelo elevado conteúdo de areia, conferindo ao grupo maior destaque para esse atributo (Figura 37a) e propiciando maiores reflectâncias. Além disso, ocorreram absorções na faixa 2300-2400 nm, típicas do grupo das micas, minerais comuns em solos menos evoluídos (Meneses; Almeida; Baptista, 2019). Estas características sugerem o predomínio de processos incipientes no grupo 4.

No grupo 5 incidiram absorções em torno de 1400, 1900 e 2200 nm, com a feição de 1900 nm mais intensa indicando o predomínio de argilominerais 2:1. O espectro médio deste cluster apresentou a menor reflectância de todos os grupos, não ocorrendo feições de absorção na região vis-NIR, que exibiu aspecto convexo. Estas características podem ser atribuídas ao maior conteúdo de argila (Figura 37c), associado ao alto teor de CO devido o agrupamento de horizontes superficiais (Figura 38a). Dentre os solos deste cluster, predominaram amostras de Gleissolo, Neossolo Fúvico, Planossolo Nátrico e Vertissolo, os quais sofrem efeito da água e exibiram problemas de sais, o que sugere o agrupamento, sobretudo, com base na CE, Na e PST (Figura 38), conferindo destaque para estes atributos.

Figura 38 – Variabilidade dos atributos do solo por grupo na faixa vis-NIR-SWIR: a) carbono orgânico (g kg^{-1}); b) pH; c) sódio ($\text{cmol}_c \text{kg}^{-1}$); d) PST; e) CE (dS m^{-1})

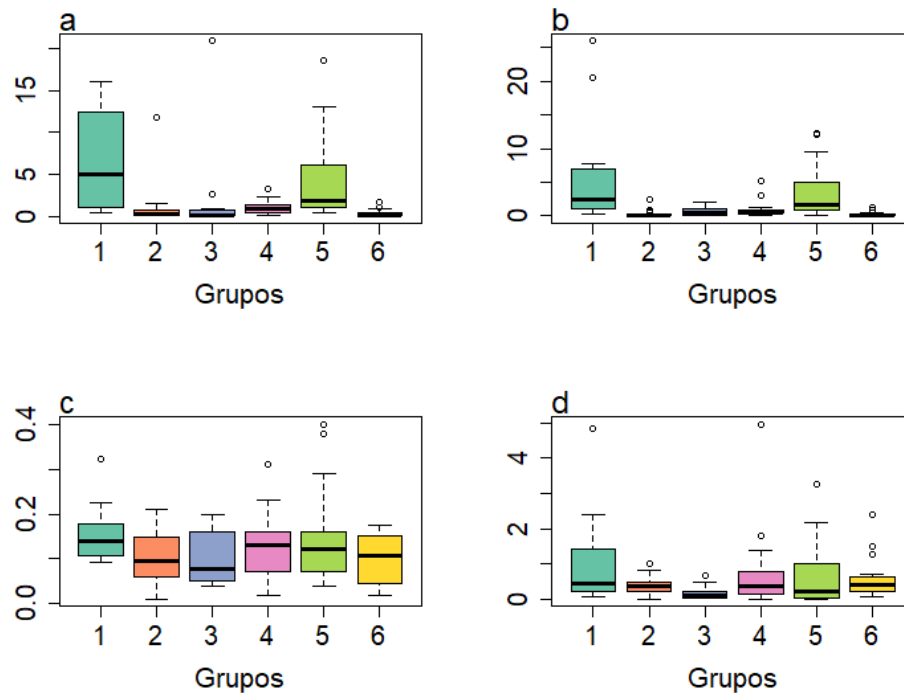


Fonte: A autora.

O comportamento espectral médio do grupo 6 apresentou feições típicas de absorções dos argilominerais, com destaque para as bandas mais intensas em torno de 1400 e 2200 nm, indicativas da presença de caulinita. Neste cluster, foram agrupadas amostras de Latossolo, Planossolo, Plintossolo e Argissolo, com destaque para a ocorrência de solos mais evoluídos e predomínio de horizontes superficiais, o que propiciou na faixa vis-NIR aspecto convexo, com ausência de feições de absorção. Este comportamento está relacionado ao elevado teor de CO presente nos horizontes superficiais (Figura 38a), visto que a matéria orgânica, formada por diferentes formas de C, é o principal responsável pela diminuição da refletância na região vis-NIR (Madeira Netto; Baptista, 2000). Com isso, evidencia-se que este cluster se caracterizou pelo agrupamento de amostras superficiais com alto teor de areia.

No que se referem aos nutrientes, estes não alteram diretamente o espectro, de modo a não apresentar características de absorção. Entretanto, normalmente encontram-se adsorvidos nos grupos funcionais de compostos minerais e orgânicos (Rizzo *et al.*, 2021). Neste contexto, as maiores concentrações de macronutrientes observadas nos grupos 1 e 5 (Figura 39) podem estar associadas aos conteúdos elevados de argila e carbono orgânico destes grupos (Figuras 37 e 38).

Figura 39 – Variabilidade dos atributos do solo ($\text{cmol}_c \text{ kg}^{-1}$) por grupo na faixa vis-NIR-SWIR: a) cálcio; b) magnésio; c) potássio; d) nitrogênio (g kg^{-1})

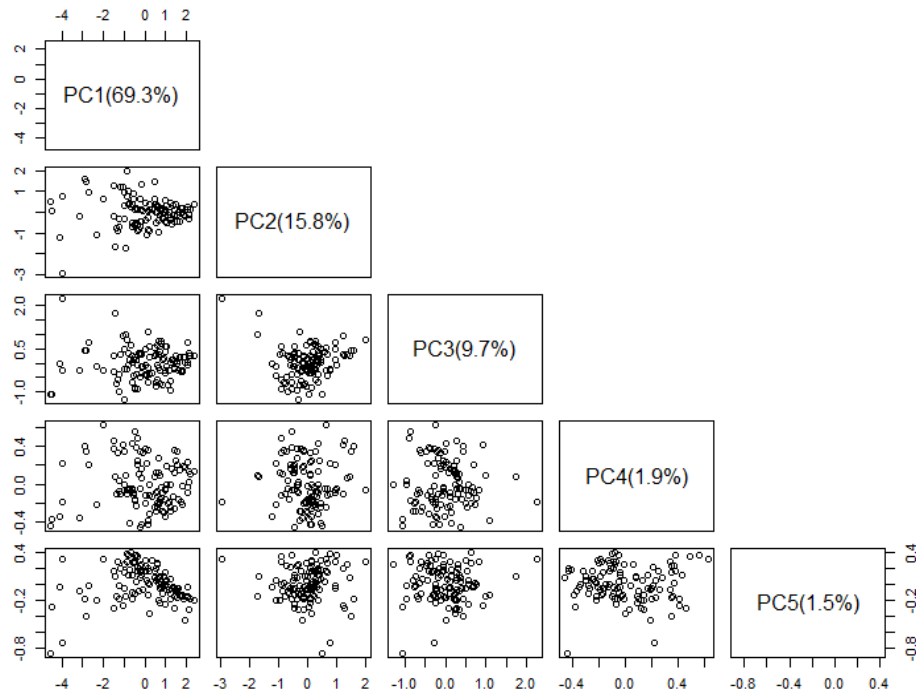


Fonte: A autora.

3.3.5 Agrupamento de horizontes do solo na faixa espectral MIR

Na análise de componentes principais (ACP) realizada com os espectros de reflectância MIR suavizados, os cinco primeiros componentes explicaram 98,2% da variabilidade total dos dados. O maior percentual de variação foi explicado pela primeira componente principal (CP1 = 69,3%), com redução progressiva nas subsequentes (Figura 40).

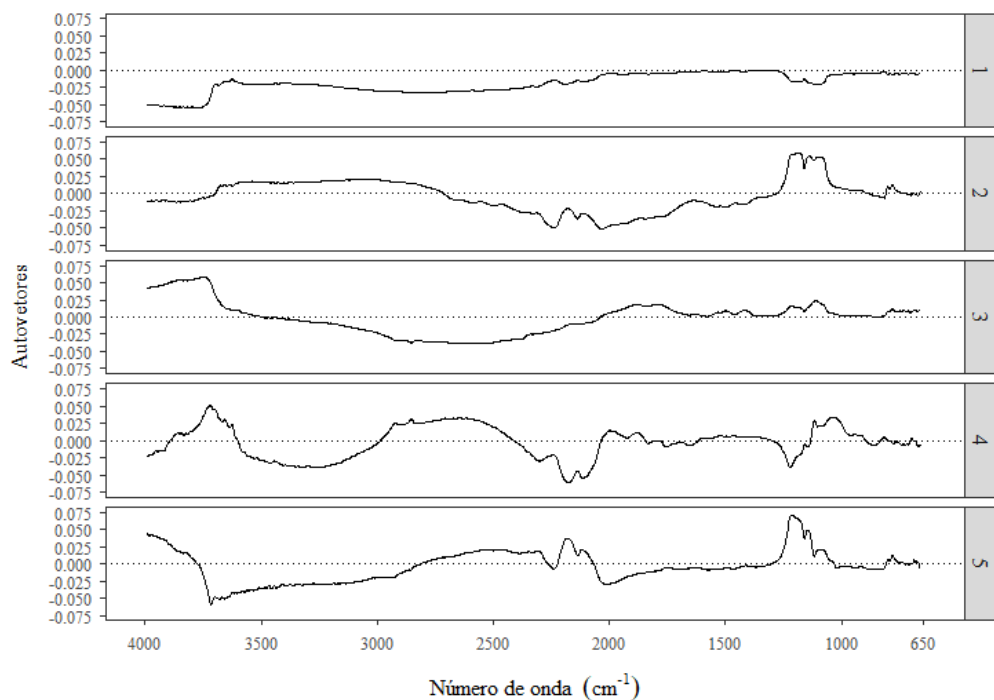
Figura 40 – Variância explicada pelas cinco primeiras componentes na faixa MIR



Fonte: A autora.

A partir da análise dos autovetores observaram-se as contribuições dos valores de reflectância para a produção dos escores de cada componente principal (Figura 41), o que propiciou destacar as regiões espectrais de maior importância.

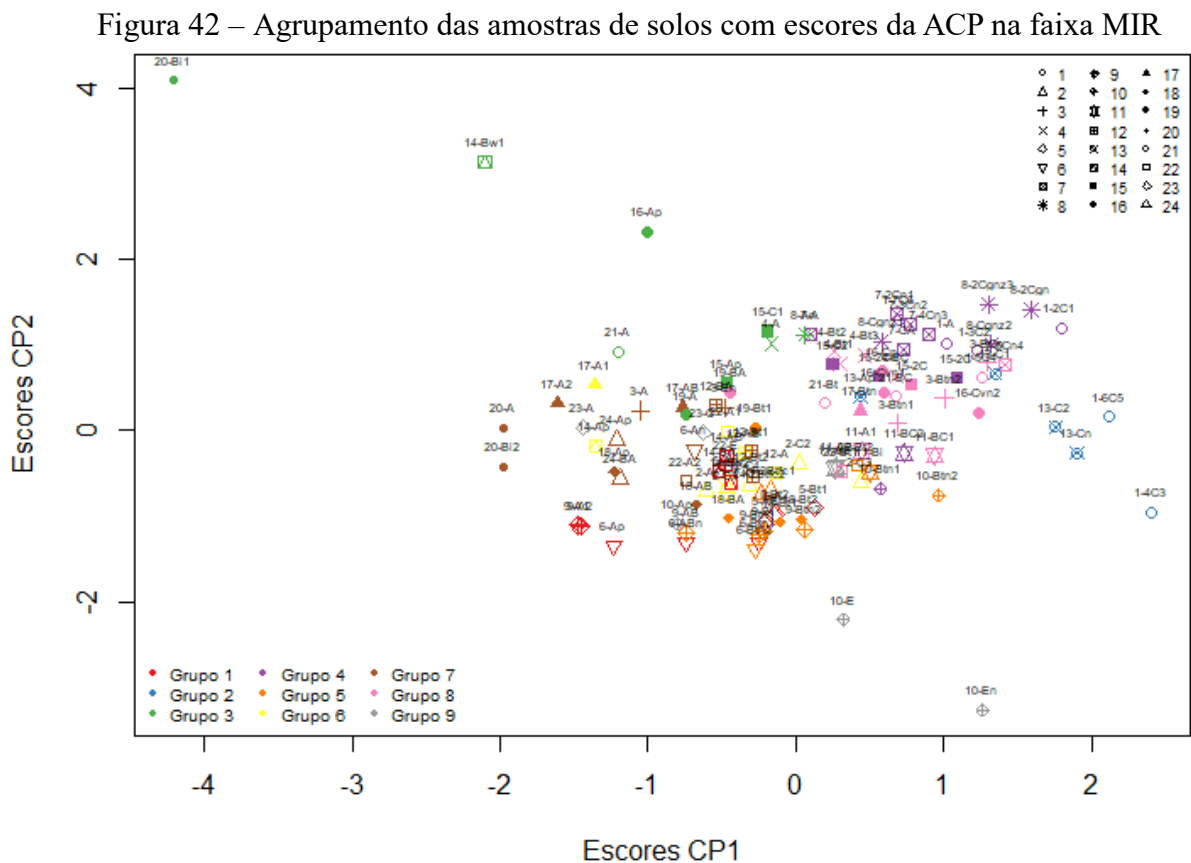
Figura 41 – Autovetores da análise de componentes principais na faixa MIR



Fonte: A autora.

As componentes exibiram padrões contrastantes com autovetores positivos e negativos, com exceção da primeira componente principal (CP1) em que os autovetores foram negativos. As CP1 e CP5 apresentaram forte contribuição negativa em torno de 3600 cm^{-1} , região caracterizada por absorções de filossilicatos 2:1 e 1:1. Nas CP2 e CP5 destacaram-se cargas positivas na faixa de $1230\text{-}1175\text{ cm}^{-1}$, com a formação de picos altos de reflectância. A CP3 também exibiu picos de reflectância nesta região, contudo menos intensos. Os picos por volta de 1200 cm^{-1} são atribuídos ao quartzo e ao ferro cristalino. A CP4, por sua vez, mostrou forte contribuição negativa na região de $2200\text{-}2169\text{ cm}^{-1}$. As bandas de absorção entre $2233\text{-}1625$ são atribuídas à sílica presente no quartzo e nos filossilicatos (Mendes *et al.*, 2022).

Para a classificação não supervisionada com o método K-médias foram utilizados os escores das cinco primeiras componentes principais. A classificação resultou na divisão das amostras de solos em nove grupos distintos (Figura 42), com três grupos a mais do que a classificação feita com os espectros de vis-NIR-SWIR. O número ótimo de grupos foi determinado com base no menor valor do coeficiente de partição ($= 0,64$) e o maior valor da entropia de partição ($= 0,83$).



Cada símbolo representa um perfil de solo identificado por seu número. Cada cor representa um grupo.
Fonte: A autora.

A quantidade de amostras de solo em cada grupo, a identificação dos horizontes pedológicos que integraram os grupos e a respectiva classificação taxonômica do solo pode ser observada na Tabela 3.

Tabela 3 – Identificação de amostras do solo por grupo na faixa MIR

Grupos	Horizontes							Total	Solos
	A	AB	E	BA	B	BC	C		
1	4	3	1	1	4			13	PACe, PAd, PAdx, LAd, SXe
2	1						5	6	RYq, RQg
3	6				2		1	9	TXp, GZn, LAd, RYe, VEn, PVd, CXd, TCo
4	2				1	1	14	18	RYq, RYn, GZn, SNo, CXe, RYe
5		1		1	6			8	PAd, PAdx, SNo, CXe, PVAd, PVd, SXe, FTe
6	6	1					5	12	RQo, PACe, PVAd, LAd, SNo, SXe
7	7	2	1	1	3			14	SNo, PAd, PVAd, SNo, PVAd, CXd, SXe, FTe
8	1			2	8	4	6	21	RYq, SNo, TXp, RYn, CXe, RYe, VEn, SNo, PVd, TCo, SXe
9	3	1	2				1	7	SNo, CXe, RLe

As linhas representam os grupos e as colunas representam os horizontes.

Fonte: A autora.

A análise dos agrupamentos evidenciou, de modo geral, que o grupo 1 concentrou horizontes superficiais e subsuperficiais, porém com prevalência do horizonte A e sua transição. Nos grupos 2 e 4 houve maior predominância de amostras do horizonte C. Os grupos 3, 6, 7 e 9 agruparam amostras tanto superficiais quanto subsuperficiais (E, B e C), embora tenha prevalecido o horizonte A. Nos grupos 5 e 8, por sua vez, verificou-se a ocorrência de amostras subsuperficiais, com predomínio do horizonte B textural.

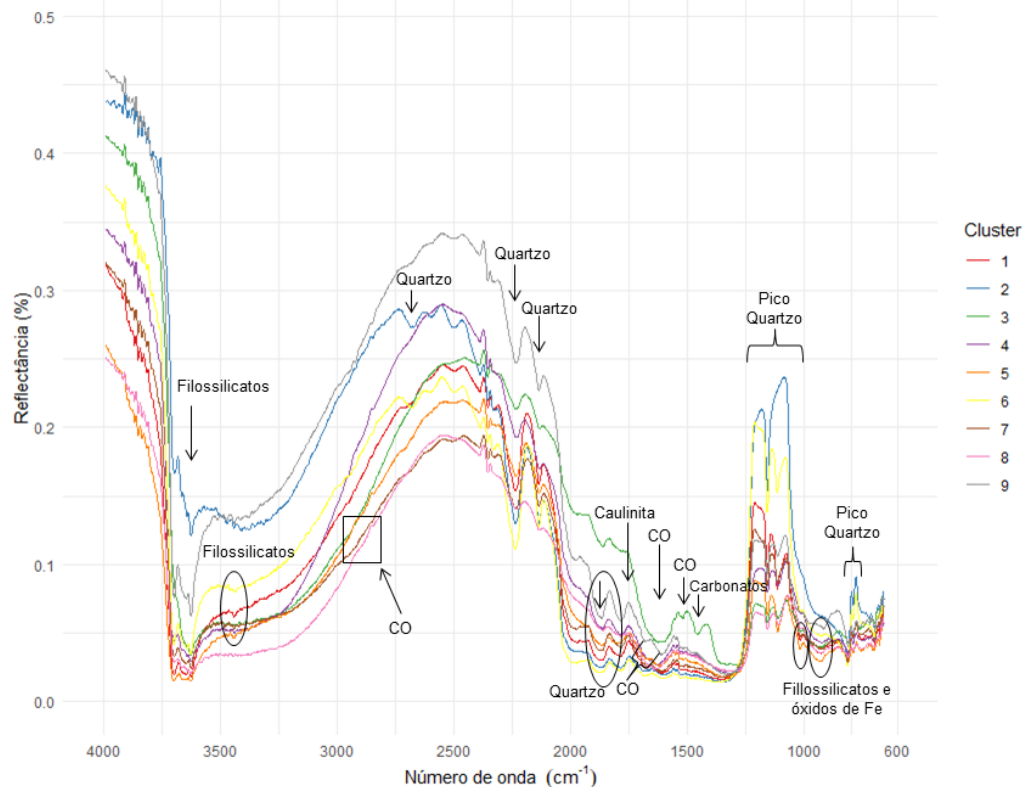
A classificação dos solos na faixa MIR seguiu a mesma tendência observada na faixa vis-NIR-SWIR, com o agrupamento estruturado principalmente em função dos horizontes. Entretanto, a região MIR apresentou maior sensibilidade para detectar variações internas ao longo do perfil, visto que perfis com heterogeneidade no material de origem, como o Neossolo Flúvico, mostraram maior diferenciação entre clusters. Isso deve-se ao fato de que, no MIR, manifestam-se as vibrações fundamentais da maioria dos compostos orgânicos e

minerais do solo, o que gera informações mais específicas sobre as características do solo em virtude do tipo de interação da energia (Garrett *et al.*, 2022).

De maneira análoga, Zhang; Hartemink; Huang (2021) observaram que amostras de diferentes ordem de solos podem ser agrupadas em um mesmo cluster em função de similaridades na composição, uma vez que as características espectrais dos solo estão intensamente relacionadas aos horizontes pedológicos e às propriedades associadas. Contudo, de modo oposto, estes autores identificaram menor número de grupos, totalizando 8 na faixa MIR. Do mesmo modo, Mendes *et al.* (2022) observaram apenas 5 grupos espectrais nesta faixa. Diferentemente do presente estudo, esses autores não avaliaram solos com expressivo acúmulo de sais, característica que possivelmente contribuiu para o maior número de grupos.

As tendências de distribuição seguidas pelos nove grupos espectrais da faixa MIR, foram melhores evidenciadas a partir da análise do comportamento espectral médio de cada cluster, empregando dados de reflectância suavizados. O maior número de feições observadas nesta região do espectro contribuiu para o aumento do número de clusters (Figura 43).

Figura 43 – Espectros de reflectância médio por grupo na faixa MIR



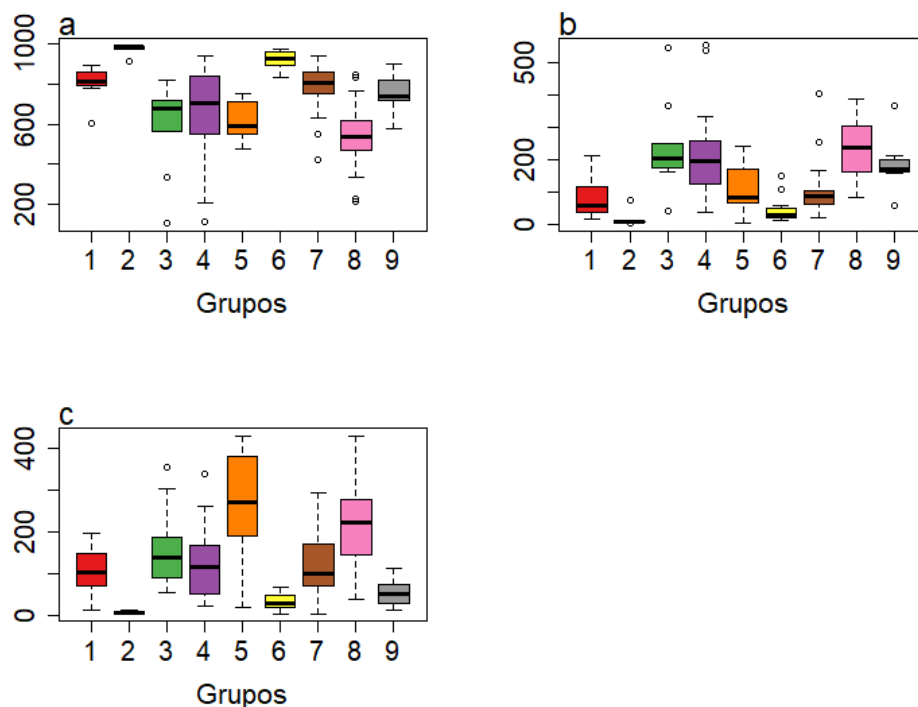
Fonte: A autora.

Avaliando-se o comportamento espectral médio dos grupos, observou-se que os clusters 2, 3, 6 e 9 destacaram-se por exibir comportamento distinto em algumas regiões. Os

grupos 2 e 9 apresentaram alta reflectância, com feições de absorção pronunciadas, atribuídas aos filossilicatos entre 3695-3622 e 3529-3394 cm^{-1} e ao quartzo em 2250-1620 cm^{-1} , evidenciando a forte contribuição destes atributos nos grupos. Todavia, o cluster 2 apresentou pico associado ao quartzo em 1250-1000 cm^{-1} mais pronunciado, em razão do maior conteúdo de areia (Figura 44a). Já o grupo 9, exibiu feições de caulinita nítidas com picos entre 1780-1500 cm^{-1} , e feição espectral estreita em 1820 cm^{-1} relacionada à presença de silicatos (Mendes *et al.*, 2022), além de absorções de CO entre 1700-1640 cm^{-1} (Rossel *et al.*, 2008).

Nesses grupos ocorreram, principalmente, amostras dos horizontes A e C, oriundas dos Neossolos, do Planossolo Nátrico e do Cambissolo Háplico, evidenciando o agrupamento de solos com desenvolvimento incipiente. No grupo 2 prevaleceram amostras do horizonte C, o que propiciou a alta reflectância devido ao elevado conteúdo de areia e reduzido teor de CO. No grupo 9, por sua vez, predominaram amostras do horizonte A e, embora tenha apresentado elevado conteúdo da fração areia, o alto teor de CO oriundo dos horizontes superficiais reduziu os picos reflectância (Figuras 44a e 45a).

Figura 44 – Variabilidade dos atributos do solo (g kg^{-1}) por grupo na faixa MIR: a) areia; b) silte; c) argila



Fonte: A autora.

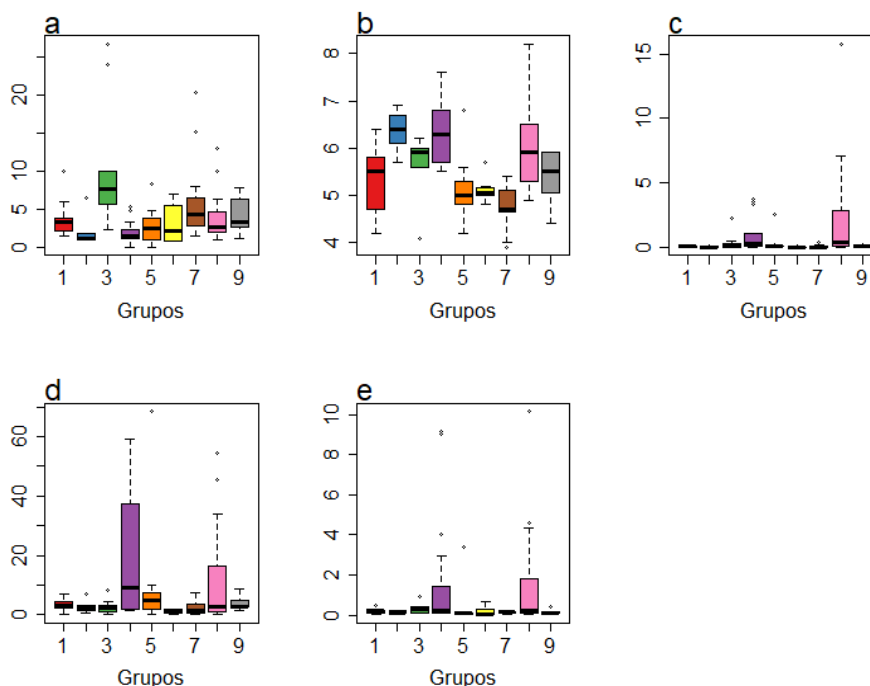
O grupo 3 apresentou albedo reduzido e comportamento espectral distinto de todos os clusters na faixa de 2000-1250 cm^{-1} . A baixa reflectância, com as feições típicas de quartzo reduzidas, deve-se ao menor conteúdo de areia e o teor mais elevado de CO (Figuras

44a e 45a). Por sua vez, as absorções entre $1750\text{-}1430\text{ cm}^{-1}$ são atribuídas ao alto teor de CO e a presença de carbonatos (Soriano-Disla *et al.*, 2014; Terra *et al.*, 2021). Além disso, o maior teor de argila deste grupo (Figura 44c) contribuiu para a ocorrência de feições pronunciadas.

No grupo 3 ocorreu, sobretudo, horizontes superficiais de Argissolo, Cambissolo, Gleissolo, Luvisolo, Neossolo Flúvico e Vertissolo. Diante disso, observou-se que o grupo reuniu amostras de solos menos desenvolvidos, e concentrou também amostras com alto conteúdo de CO, ricas em bases e com ocorrência de carbonatos, o que foi corroborado pelo maior conteúdo de macronutrientes (Figura 46). Esta característica é comum em solos do Semiárido, os quais podem ser formados a partir de rochas calcárias, apresentando horizonte superficial com alto conteúdo de MO e saturação por bases (Araújo Filho *et al.*, 2022).

O comportamento espectral do grupo 6 apresentou feições típicas de quartzo bem pronunciadas, embora este cluster tenha exibido baixa reflectância. As feições pronunciadas do quartzo entre $2250\text{-}2000$, 1250 e 800 cm^{-1} são atribuídas ao alto teor de areia do grupo (Figura 44a). Por outro lado, a baixa reflectância está associada a um maior conteúdo de CO (Figura 45a) e a ocorrência de óxidos de Fe, os quais promovem espectros descendentes (Mendes *et al.*, 2022). Este grupo concentrou, sobretudo, amostras superficiais de Argissolo Acinzentado, Argissolo Vermelho-Amarelo, Latossolo Amarelo e Neossolo Quartzarênico, evidenciando o agrupamento de solos com alto teor de areia e com presença de óxidos de Fe.

Figura 45 – Variabilidade dos atributos do solo por grupo na faixa MIR: a) carbono orgânico (g kg^{-1}); b) pH; c) sódio ($\text{cmol}_c\text{ kg}^{-1}$); d) PST; e) CE (dS m^{-1})

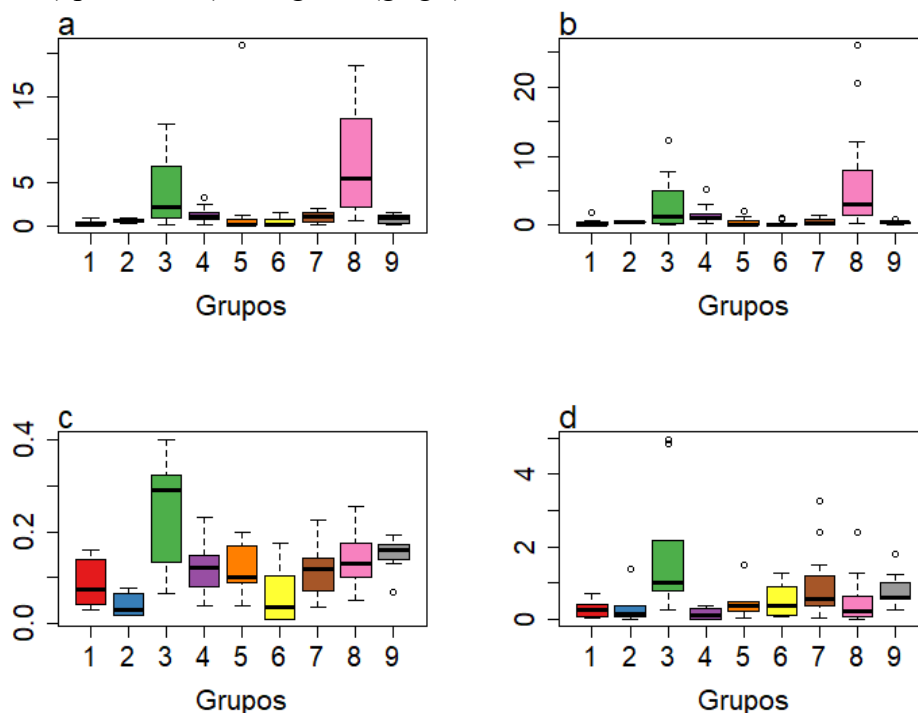


Fonte: A autora.

Quanto aos demais grupos (1, 4, 5, 7 e 8), observou-se que ocorreu comportamento espectral muito similar, porém com distinção da intensidade de reflectância. Estes grupos exibiram baixa reflectância e absorções mais suaves associadas aos filossilicatos e óxido de alumínio ($3695\text{-}3622$ e $3529\text{-}3394\text{ cm}^{-1}$), ao CO ($2924\text{-}2843\text{ cm}^{-1}$) e ao quartzo ($2250\text{-}1620$ e $1250\text{-}1000\text{ cm}^{-1}$). Nos grupos 1 e 7 se concentraram, sobretudo amostras do horizonte A, provenientes de Argissolos, Cambissolos, Latossolos, Planossolos e Plintossolos, os quais apresentam camada superficial mais arenosa. Já o cluster 4 reuniu amostras do horizonte C, oriundas de Gleissolo Sáfico, Neossolo Flúvico e Planossolo Nátrico, promovendo no grupo alto pH e elevada PST (Figura 45).

Para os grupos 5 e 8, observou-se que os picos típicos de quartzo em $1250\text{-}1000\text{ cm}^{-1}$ foram muito reduzidos, o que foi atribuído aos seus maiores teores de argila (Figura 44c). Estes clusters reuniram amostras subsuperficiais de Argissolo, Cambissolo, Luvisolo, Planossolo, Plintossolo e Vertissolo, evidenciando o agrupamento com base no processo de acumulação de argila. Além disso, verificou-se que o grupo 8 concentrou amostras com acúmulo de sais tanto no horizonte B quanto no C, conforme evidenciado pelos altos valores de Na, PST e CE deste grupo, associado ao acúmulo de Ca e MG (Figuras 45 e 46). Assim, estes aspectos sugerem o agrupamento com base no acúmulo de cátions trocáveis e sais.

Figura 46 – Variabilidade dos atributos do solo ($\text{cmol}_c\text{ kg}^{-1}$) por grupo na faixa MIR: a) cálcio; b) magnésio; c) potássio; d) nitrogênio (g kg^{-1})



Fonte: A autora.

Mediante os resultados obtidos na classificação, verificou-se que a faixa MIR apresentou maior capacidade de detectar alterações sutis ao longo do perfil, quando comparada à faixa vis-NIR-SWIR. Este comportamento corrobora os achados de Zhang; Hartemink; Huang (2021), que observaram boa diferenciação entre os horizontes do solo na faixa MIR, atribuídas às associações entre os atributos que compõem os horizontes do solo e a interação destes com a radiação eletromagnética nesta faixa.

Todavia, considerando que ambas as regiões espectrais foram capazes de detectar transições nítidas entre horizontes, agrupando amostras de horizontes com características semelhantes em clusters comuns, infere-se que a análise espectral tem potencial de ser usada na identificação de horizontes, especialmente daqueles com características contrastantes.

3.4 Conclusões

A análise do comportamento espectral dos solos fornece informações de extrema relevância para a Ciência do Solo, confirmando, conforme a hipótese proposta, a capacidade da espectroscopia de reflectância em caracterizar o solo de forma eficiente. Evidencia-se que a análise espectral permite identificar feições associadas a atributos usados na classificação do solo no primeiro nível categórico, como o acúmulo da argila, a presença de óxidos de Fe e de minerais menos intemperizados, o que reforça o potencial da técnica em estudos pedológicos.

Do ponto de vista dos agrupamentos, constata-se que a variabilidade espectral está diretamente relacionada às características dos horizontes, que se diferenciam em função da posição no perfil. Tendo em vista que os horizontes subsuperficiais são diagnósticos, e apresentam menor influência da matéria orgânica, as feições espectrais características das classes de solo são mais bem expressas nestes horizontes. Além disso, verifica-se uma complementariedade entre os espectros, com o vis-NIR-SWIR captando diferenças mais expressivas nos solos, como variações texturais, enquanto o MIR destaca variações mais sutis no perfil, como o acúmulo de sódio. Característica que não foi identificada em outros estudos.

Os resultados obtidos representam adequadamente e em primeira mão os comportamentos espectrais de solos do Nordeste Brasileiro, caracterizados pela alta reflectância, presença de feições de absorção indicadoras de minerais primários e secundários de fácil intemperização (filossilicatos do tipo 2:1) e indicadoras de carbonatos. Embora o acúmulo de sais, uma das principais características destes solos, não seja identificado diretamente no espectro, a diferenciação de grupos com essa característica contribui para o mapeamento de áreas susceptíveis a degradação por salinização e sodificação.

4 CAPÍTULO II - PREDIÇÃO DE ATRIBUTOS FÍSICOS E QUÍMICOS COM ESPECTROSCOPIA DO VISÍVEL AO INFRAVERMELHO MÉDIO EM SOLOS DO NORDESTE DO BRASIL

Resumo

O monitoramento das características edáficas é primordial para o manejo adequado e a conservação dos solos, sendo especialmente importante em áreas sob forte exploração e susceptíveis à degradação. Assim, o objetivo desse estudo foi quantificar os atributos físico-químicos, bem como a salinidade e sodicidade de solos do Nordeste brasileiro utilizando espectroscopia de reflectância na faixa de 350 – 15000 nm e algoritmos de estatística multivariada. Foram avaliadas 114 amostras de 24 perfis de solos provenientes de municípios do Ceará. Na análise do solo com metodologia convencional foi determinado a granulometria, carbono orgânico, nitrogênio, fósforo, potássio, cálcio, magnésio, sódio, alumínio trocável, percentagem de sódio trocável, condutividade elétrica, pH ($H_2O - 1:2,5$), soma de bases, capacidade de troca catiônica e saturação por bases. Na análise espectral foi avaliado a reflectância do solo nas faixas do visível, infravermelho próximo, infravermelho de ondas curtas (vis-Nir-SWIR) e infravermelho médio (MIR). O resultado da análise convencional foi avaliado com estatística descritiva. Os dados espectrais foram pré-processados com as técnicas de conversão para absorbância e suavização com o filtro Savitzky-Golay. Os modelos preditivos dos atributos foram desenvolvidos com os espectros brutos e pré-processados associados aos algoritmos de Regressão por Mínimos Quadrados Parciais (PLSR), Máquina de Vetor Suporte com funções Kernel lineares e radiais (SVM-Linear e SVM-Radial) e Algoritmo Cubista (CA). O desempenho dos modelos preditivos foi avaliado pelas métricas de R^2 , RMSE, RPD e RPIQ. Os modelos desenvolvidos na região do infravermelho médio superaram o desempenho das modelagens realizadas na faixa do visível ao infravermelho de ondas curtas, com exceção das predições de Na, PST e V. As predições da salinidade e sodicidade apresentaram desempenho razoável. Dentre os algoritmos de regressão e as técnicas de pré-processamento avaliadas, o algoritmo PLSR e a suavização com o filtro Savitzky-Golay se destacaram na produção dos melhores modelos. A espectroscopia foi capaz de prever os atributos do solo com, no mínimo, desempenho satisfatório, com exceção do cálcio, que apresentou desempenho insatisfatório em todas as faixas espectrais.

Palavras-chave: quantificação; atributos físico-químicos; salinidade; sodicidade.

Abstract

Monitoring soil characteristics is essential for proper soil management and conservation, and is especially important in areas under heavy exploitation and susceptible to degradation. Thus, the objective of this study was to quantify the physical-chemical attributes, as well as the salinity and sodicity of soils in Northeastern Brazil using reflectance spectroscopy in the range of 350–15,000 nm and multivariate statistical algorithms. A total of 114 samples from 24 soil profiles from municipalities in Ceará were evaluated. In the soil analysis using conventional methodology, the following were determined: particle size, organic carbon, nitrogen, phosphorus, potassium, calcium, magnesium, sodium, exchangeable aluminum, percentage of exchangeable sodium, electrical conductivity, pH (H₂O – 1:2.5), sum of bases, cation exchange capacity, and base saturation. In spectral analysis, soil reflectance was evaluated in the visible, near-infrared, short-wave infrared (vis-Nir-SWIR), and mid-infrared (MIR) ranges. The results of conventional analysis were evaluated using descriptive statistics. The spectral data were preprocessed using absorbance conversion techniques and smoothing with the Savitzky-Golay filter. The predictive models of the attributes were developed with the raw and preprocessed spectra associated with the Partial Least Squares Regression (PLSR), Support Vector Machine with linear and radial kernel functions (SVM-Linear and SVM-Radial), and Cubist Algorithm (CA) algorithms. The performance of the predictive models was evaluated using the metrics R², RMSE, RPD, and RPIQ. The models developed in the mid-infrared region outperformed the models developed in the visible to shortwave infrared range, with the exception of the predictions for Na, PST, and V. The predictions for salinity and sodicity showed reasonable performance. Among the regression algorithms and preprocessing techniques evaluated, the PLSR algorithm and smoothing with the Savitzky-Golay filter stood out in producing the best models. Spectroscopy was able to predict soil attributes with at least satisfactory performance, with the exception of calcium, which performed unsatisfactorily in all spectral ranges.

Keywords: quantification; physical-chemical attributes; salinity; sodicity.

4.1 Introdução

O monitoramento eficiente das características pedológicas é indispensável para identificar o potencial e as limitações do solo e promover o seu manejo sustentável (Beniaich *et al.*, 2025). Essa necessidade é especialmente importante em áreas sob intensa exploração antrópica e com solos susceptíveis à degradação, como o Nordeste do Brasil, em que as práticas agrícolas e extrativistas, intensificada pelas condições climáticas da região, têm acelerado o processo de degradação do solo (Souza; Leite; Medeiros, 2021).

A região Nordeste apresenta significativa variedade edafoclimática, abrigando quatro biomas e a maior diversidade edáfica do país. Essa variedade resulta em solos em diferentes estádios de desenvolvimento e com atributos muito heterogêneos (Souza; Leite; Medeiros, 2021). O bioma Caatinga, predominante na região, compõe as florestas tropicais sazonalmente secas, que apresentam-se distribuídas pelo mundo, contudo esse bioma é endêmico e ocorre exclusivamente no Brasil, caracterizando-se por um clima semiárido, com alta sazonalidade e variabilidade espacial das chuvas (Silva *et al.*, 2025).

Nesse contexto, a diversidade litológica da Caatinga propicia a formação de variados tipos de solos, sendo comum a ocorrência de solos pouco profundos e pouco desenvolvidos, se comparados aos de regiões tropicais úmidas. Nesses solos, os processos de formação incluem a argiluviação, salinização e sodificação (Souza *et al.*, 2022). Consequentemente, a presença de sais ocasionando solos salinos e sódicos, é frequente. Embora a degradação pelo acúmulo de sais seja uma preocupação global, este fenômeno é mais comum em regiões áridas e semiáridas, devido ao manejo inadequado e as condições climáticas (Hailu; Mehari, 2021).

Para o manejo adequado e a conservação desses solos, são essenciais as práticas de mapeamento e a caracterização dos atributos. Convencionalmente, essa caracterização é feita por meio de análises laboratoriais de química úmida, as quais, embora precisas, envolvem múltiplas etapas analíticas, com a utilização de reagentes químicos e equipamentos de elevado custo (Beniaich *et al.*, 2025). Além de possuírem potencial de causar contaminação ambiental pelo descarte inadequado dos resíduos gerados.

Como alternativa promissora de análise, a espectroscopia de reflectância destaca-se por ser um método rápido, não destrutivo, e isento de agentes químicos. Essa técnica baseia-se na interação entre e a radiação eletromagnética nas faixas do visível (vis: 350-700 nm), infravermelho próximo (NIR: 700-1100 nm), infravermelho de ondas curtas (SWIR: 1100-2500 nm) e infravermelho médio (MIR: 2.500-25.000 nm ou 4.000-400 cm^{-1}), e os

componentes orgânicos e minerais do solo (Mendes *et al.*, 2022).

A faixa vis-NIR-SWIR vem sendo mais amplamente estudada para a previsão dos atributos do solo (Padarian; Minasny; Mcbratney, 2019), o que deve-se principalmente a portabilidade do equipamento e o preparo simplificado de amostras. A faixa MIR por sua vez, embora necessite de equipamento mais oneroso e preparo rigoroso das amostras, os dados gerados possuem maior acurácia (Lotfollahi *et al.*, 2023). Estudos demonstram que modelos obtidos com dados MIR comumente superam o desempenho daqueles gerados com dados vis-NIR-SWIR (Dangal *et al.*, 2019), o que justifica o estudo mais profundo dessa faixa espectral.

Apesar dos avanços que a espectroscopia tem obtido para a predição dos atributos do solo (Tavakoli *et al.*, 2023), a heterogeneidade pedológica limita a adoção de modelos universais. Ademais, a aplicação dessa técnica em solos das regiões áridas e semiáridas ainda é incipiente (Taghdis; Farpoor; Mahmoodabadi, 2022). Torna-se, portanto, urgente realizar estudos espectrais nessas regiões, uma vez que modelos calibrados para uma condição edafoclimática particular raramente são aplicáveis em outra (Moura-Bueno *et al.*, 2020).

No Brasil, essa lacuna é ainda mais acentuada, os solos do semiárido, localizados majoritariamente na região Nordeste, são pouco investigados espectralmente, sobretudo na faixa MIR (Santos *et al.*, 2020). A baixa representação da região é clara nas bases de dados nacionais, de modo que a biblioteca espectral de solos do Brasil possui apenas 23% de suas amostras oriundas do Nordeste, com a maioria concentrada no estado de Pernambuco (Mendes *et al.*, 2022), o que não reflete completamente a variedade edáfica da região.

Diante desse cenário, parte-se da hipótese de que a espectroscopia de reflectância do visível ao infravermelho médio pode prever com precisão em solos do Nordeste brasileiro os atributos físico-químicos, como granulometria, salinidade, sodicidade e demais propriedades químicas, fornecendo uma alternativa eficiente às análises tradicionais. Adicionalmente, espera-se que a modelagem na faixa MIR proporcione ganhos significativos na qualidade das predições, em função das interações mais fortes da radiação com os constituintes do solo nessa região espectral.

4.1.1 Objetivos

O objetivo principal deste estudo foi quantificar os atributos físico-químicos, bem como a salinidade e sodicidade de solos do Nordeste brasileiro utilizando a espectroscopia de reflectância na faixa de 350 – 15000 nm e algoritmos de estatística multivariada.

Como objetivos específicos foram almejados:

- a) Investigar o potencial da espectroscopia para prever os seguintes atributos: granulometria, nitrogênio, fósforo disponível, potássio, cálcio, magnésio, sódio, alumínio, carbono orgânico, pH (H₂O), condutividade elétrica, capacidade de troca catiônica, soma de bases, saturação por bases e percentagem de sódio trocável;
- b) Quantificar os atributos relacionados à salinidade e sodicidade do solo;
- c) Identificar combinações ótimas de pré-processamentos (reflectância, absorbância e suavização) e algoritmos (regressão linear e aprendizado de máquinas) que potencializam a predição dos atributos;
- d) Avaliar o desempenho das predições por meio de métricas estatísticas e identificar o melhor modelo para cada atributo do solo.

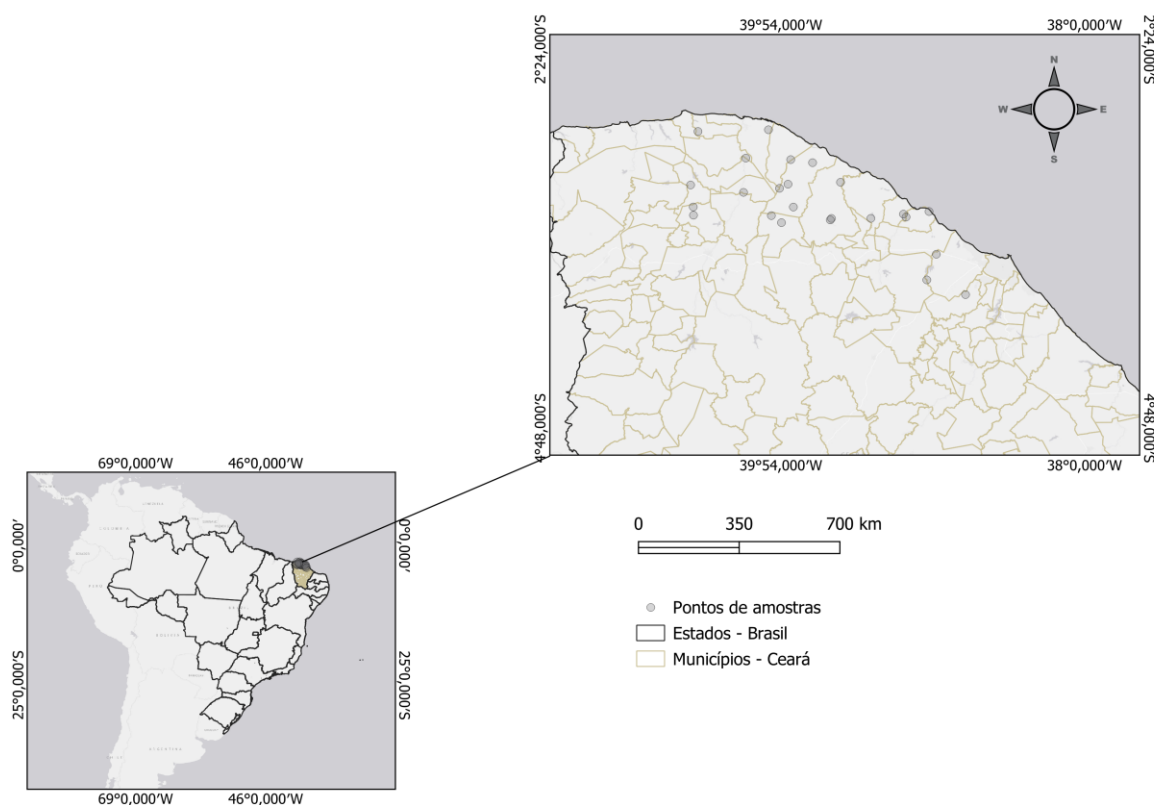
4.2 Material e métodos

Nesta seção são descritas as metodologias empregadas para a análise tradicional e espectral do solo, bem como os procedimentos estatísticos aplicados visando à quantificação dos atributos físico-químicos.

4.2.1 Seleção das amostras

O estudo foi conduzido no estado do Ceará, região Nordeste do Brasil. O estado possui 184 municípios distribuídos em sete mesorregiões. As amostras de solos avaliadas são provenientes de 13 municípios cearenses, onde predominam os climas subúmido úmido, subúmido seco e semiárido (Figura 47).

Figura 47 – Mapa com os municípios do estado do Ceará de coleta dos solos



Fonte: elaborada pela autora.

Foram avaliadas 114 amostras de solos oriundas de 24 pontos, de modo que cada ponto correspondeu a um perfil de solo e cada amostra representou um horizonte pedológico. Os perfis foram classificados em nove ordens taxonômicas segundo os critérios do Sistema Brasileiro de Classificação do Solo (Santos *et al.*, 2025), sendo estas: Argissolo, Cambissolo, Gleissolo, Latossolo, Luvisolo, Neossolo, Planossolo, Plintossolo e Vertissolo. Estes solos pertencem as classes mais representativas do Nordeste, ocupando cerca de 97,5% da região (Souza; Leite; Medeiros, 2021). A classificação pedológica dos perfis até o 4º nível categórico (subgrupo), e a identificação dos pontos de coleta estão disponíveis no Apêndice A.

As amostras de solos avaliadas neste estudo fazem parte do Levantamento de reconhecimento de média intensidade dos solos do Estado do Ceará, publicado em 2024, e compõem a área 7 do Levantamento. Os materiais de solo foram adquiridos no banco de dados do Laboratório de Análises de Solos, Águas, Tecidos e Adubos, que fica localizado no Departamento de Ciência do Solo da Universidade Federal do Ceará (UFC). As informações referentes à coleta das amostras e os resultados das análises de química úmida foram obtidas diretamente desse banco de dados.

4.2.2 Análises convencionais de química úmida

As avaliações do solo pelo método convencional foram realizadas no Laboratório de Análises de Solos, Águas, Tecidos e Adubos, pela própria equipe técnica do laboratório. Para iniciar as análises do solo foi realizado a obtenção da terra fina seca ao ar (TFSA), tendo sido as amostras de solo dispostas na sombra e ao ar para secagem, depois moídas e tamisadas em peneira com malha de abertura de 2 mm. A partir das amostras de TFSA foram efetuadas as avaliações convencionais e de espectroscopia de reflectância.

As análises de química úmida foram realizadas segundo a metodologia do Manual de Métodos de Análise de Solo da Embrapa (Teixeira *et al.*, 2017). Como análise física foi avaliada a granulometria pelo método da pipeta, que é uma técnica de determinação das partículas primárias do solo a partir da sedimentação dos sólidos.

Como atributos químicos foram avaliados: nitrogênio total pela técnica de oxidação com ácido sulfúrico; o fósforo disponível, potássio e sódio trocáveis foram extraídos com *Mehlich 1*; cálcio, magnésio e alumínio trocáveis foram extraídos com solução de KCl; carbono orgânico foi determinado por combustão úmida proposta por Walkley & Black; a condutividade elétrica (CE) foi avaliada na pasta de saturação do solo; o pH ($H_2O - 1:2,5$) foi determinado em água, com relação solo-água de 1:2,5; a soma de bases (SB) foi calculada pela soma de Ca^{+2} , Mg^{+2} , K^+ e Na^+ ; a capacidade de troca catiônica (T) foi obtida pela soma de S, H^+ e Al^{3+} ; a saturação de bases (V) foi a partir dos valores de S e de T; e a percentagem de saturação por sódio (PST) foi calculada a partir dos valores de Na^+ e de T.

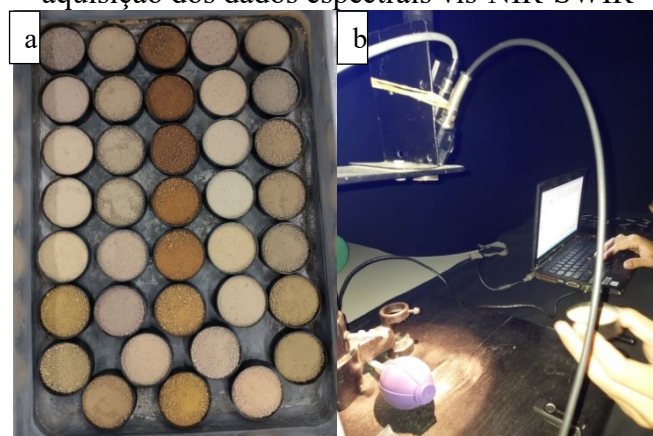
4.2.3 Análise espectral

A análise de espectroscopia de reflectância foi conduzida pela equipe desse estudo, sendo que as avaliações na faixa vis-NIR-SWIR foram executadas no Laboratório de Geoprocessamento do Departamento de Engenharia Agrícola, enquanto as análises na faixa MIR ocorreram no Laboratório de Química do Departamento de Ciência do Solo. Ambos os laboratórios ficam localizado na UFC.

Para a análise espectral do solo, as amostras de terra fina seca ao ar foram submetidas à secagem em estufa com circulação forçada de ar, a uma temperatura de 45 °C durante o período de 24 horas, conforme metodologia descrita por Demattê *et al.* (2014). Essa etapa de secagem visa homogeneizar os efeitos da umidade residual do solo e reduzir a interferência da água no espectro de reflectância.

Na obtenção dos espectros na faixa vis-NIR-SWIR, as amostras secas em estufa foram acondicionadas em recipientes de polipropileno preto medindo 5 cm de diâmetro e 1,5 cm de altura (Figura 48a). As leituras espectrais de reflectância foram realizadas com uma sonda de contato (*Hi-Brite Contact Probe*) acoplada a um espectrorradiômetro FieldSpec Pro FR 3 (Analytical Spectral Devices, Boulder, Colorado, USA), que realiza leitura na faixa do visível ao infravermelho de ondas curtas (350 – 2500 nm) e possui resolução espectral de 3 nm e 10 nm reamostrados para 1 nm e um campo de visão de 25° (Figura 48b).

Figura 48 – a) Amostras de solo preparadas para leitura espectral b) Equipamento de aquisição dos dados espectrais vis-NIR-SWIR



Fonte: elaborada pela autora.

A calibração do equipamento foi realizada com uma placa branca Spectralon, que é considerada como padrão de referência com 100% de reflectância. A partir da calibração do sensor foi realizado o cálculo do fator de reflectância bidirecional (FRB), que é obtido pela razão entre a radiância refletida pela amostra de solo e a radiância refletida pela placa de referência. A calibração foi feita a cada 20 minutos com uma nova leitura da placa padrão. Foram realizadas três leituras espectrais na superfície da amostra, sendo a amostra rotacionada aproximadamente 120° entre cada leitura para obter uma boa representatividade. O valor final de reflectância de cada amostra foi obtido com a média aritmética das três leituras realizadas.

Para a obtenção dos espectros na faixa de infravermelho médio foi realizado uma etapa adicional no preparo das amostras, a fim de obter partículas mais finas. Para isso, o solo foi triturado em almofariz de ágata, sendo posteriormente as amostras acondicionadas em tubos eppendorf e postas para secar em estufa. A leitura no MIR foi realizada usando o infravermelho com transformada de Fourier FTIR Cary 630 (Agilent Technologies) equipado com módulo de amostragem de reflectância difusa (DRIFTS), com leituras espectrais na faixa de 2500 a 15000 nm (4000 a 650 cm^{-1}) e resolução espectral $\leq 2 \text{ cm}^{-1}$ (Figura 49).

Figura 49 - Equipamento para leitura espectral na faixa MIR



Fonte: elaborada pela autora.

Em cada leitura espectral foi utilizado cerca 1 cm³ de solo, o qual foi disposto em suporte próprio do acessório DRIFTS e inserido no equipamento. A calibração do sensor foi realizada antes de cada nova leitura do solo. A placa de referência usada na calibração está posicionada na primeira posição do suporte e consiste de um espelho dourado de reflectância difusa que auxilia na remoção da radiação de *background* do espectro. As amostras de solo foram lidas em triplicata para obter os dados espectrais na faixa MIR, sendo o valor final de reflectância de cada amostra obtida pela média simples das três repetições.

4.2.4 Processamento dos dados espectrais

Os dados espectrais de reflectância obtidos nas faixas vis-NIR-SWIR e MIR foram submetidos a técnicas de pré-processamentos com o objetivo de remover ruídos e aperfeiçoar a interpretação das principais feições, bem como melhorar a estabilidade da regressão. Para o pré-processamento dos dados espectrais brutos de reflectância foram empregadas às técnicas de conversão dos valores para absorbância (A) e de suavização Savitzky-Golay (SG).

A transformação logarítmica de reflectância (R) para absorbância (A) preserva uma correlação linear entre a radiância e as concentrações dos componentes do solo. A técnica de filtragem (suavização) Savitzky-Golay é amplamente usada visando à redução do ruído e a

diferenciação do sinal (Rizzo *et al.*, 2021). Ressalta-se que aplicação dessa filtragem SG resulta na perda das janelas iniciais e finais da faixa espectral analisada.

4.2.5 Estatística descritiva

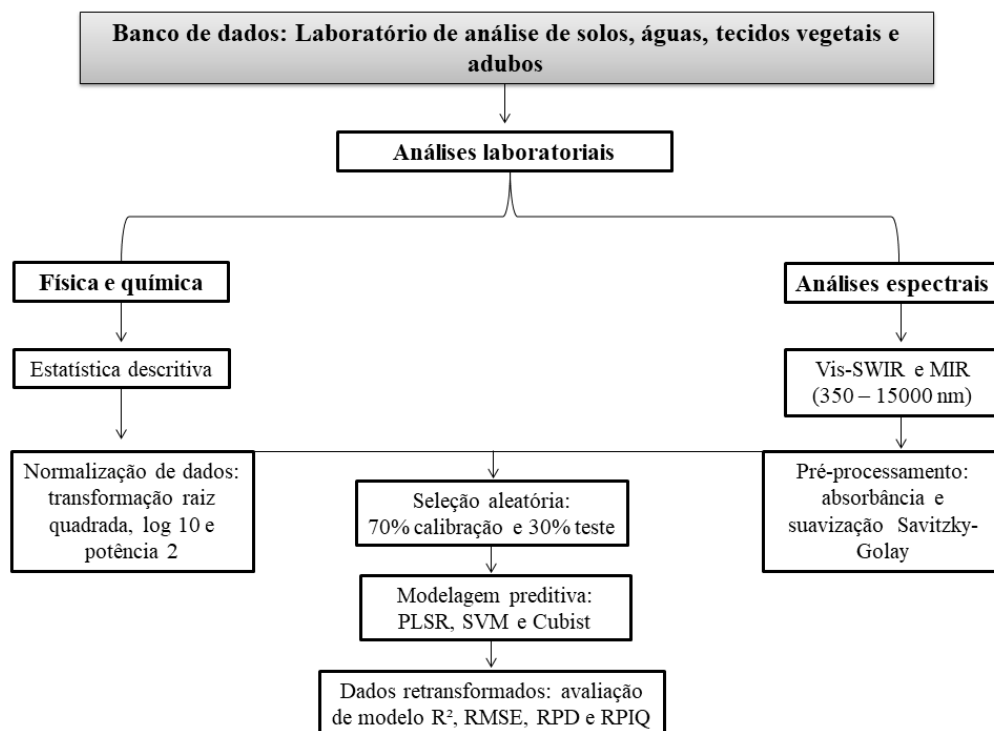
A análise dos dados produzidos com a metodologia convencional e espectral, bem como o pré-processamento dos dados espectrais foi executada no software R versão 2024.12.0.467 (R Core Team, 2024). A caracterização dos 17 atributos físico-químicos estudados foi realizada pela análise de estatística descritiva nos dados, tendo sido avaliada a média, mediana, mínimo, máximo, desvio padrão, primeiro e terceiro quartil, assimetria e curtose.

Foi avaliada, ainda, a normalidade dos atributos por meio do teste de hipótese Shapiro-Wilk a 5%. Após a realização do teste, diferentes transformações foram aplicadas nos atributos físico-químicos avaliados como não normais. As transformações logaritmo de base 10, potência ao quadrado e raiz quadrada foram empregadas visando obter valores normalmente distribuídos.

4.2.6 Modelagem preditiva – Calibração e Validação

Os modelos preditivos dos atributos físico-químicos foram desenvolvidos com os espectros brutos (vis-NIR-SWIR e MIR) e com os espectros processados pela conversão para absorbância e pela suavização Savitzky-Golay (Figura 50). Para a geração dos modelos de quantificação foi usado um algoritmo de regressão linear multivariada - Regressão por Mínimos Quadrados Parciais (PLSR), e algoritmos de aprendizado de máquina - Máquina de Vetor Suporte com funções Kernel lineares e radiais (SVM-Linear e SVM-Radial) e Algoritmo Cubista (CA).

Figura 50 - Fluxograma metodológico da predição de atributos físico-químicos do solo



Fonte: elaborada pela autora.

O algoritmo PLSR decompõe as variáveis dependentes e as independentes em *scores*, e pressupõe que há uma relação linear entre os dados avaliados (Meneses *et al.*, 2019). O método SVM é empregado em tarefas lineares e não lineares, de modo que quando os dados não são linearmente separáveis são usadas funções kernel para transformá-los em um espaço de maior dimensão e permitir a separação linear. A função mais adequada comumente é escolhida experimentalmente (Cosma *et al.*, 2017). O algoritmo CA é baseado em árvores de regressão e aprendizado em conjunto, sendo reconhecido por realizar predições com alta precisão e promover a interpretação conveniente do modelo (Coblinski *et al.*, 2020).

O conjunto de dados dos solos foi dividido uma parte para calibração e outra para teste com dados inéditos. Para tanto, foi realizada uma seleção aleatória das amostras de solo, tendo sido 70% (80 amostras) selecionadas para calibração e 30% (34 amostras) para o teste dos modelos em uma validação independente. Durante a etapa de calibração foi feito uma validação dos modelos por meio da validação cruzada *k-fold* 10 vezes.

O desempenho da precisão dos modelos de predição com os diferentes espectros e algoritmos testados foi avaliado usando as seguintes métricas: coeficiente de determinação (R^2) (Equação 1), raiz do erro quadrático médio (RMSE) (Equação 2), razão de desempenho do desvio (RPD) (Equação 3) e a razão de desempenho para intervalo interquartil (RPIQ) (Equação 4). Antes de calcular esses índices, os atributos modelados foram transformados de

volta para suas unidades originais.

$$R^2 = \frac{\sum_{i=1}^n 1 (\hat{y} - \bar{y})^2}{\sum_{i=1}^n 1 (y - \bar{y})^2} \quad (1)$$

Em que: \hat{Y} é o valor predito; Y representa o valor observado; \bar{Y} é a média dos valores observados e n é igual ao número de amostras.

$$RMSE = \sqrt{\sum_{i=1}^{n-m} \frac{(y_i' - y_i)^2}{n-m}} \quad (2)$$

Em que: n é igual ao número de amostras; m é o número de amostras usadas para predição; $y_i' - y_i$ são os valores preditos e observados, respectivamente.

$$RPD = \frac{\sigma_{Y_0}}{RMSE} \quad (3)$$

Em que: σ é o desvio padrão para os valores observados.

$$RPIQ = \frac{IQ}{RMSE} \quad (4)$$

Em que: IQ é o intervalo interquartil representado pela diferença entre o valor referente ao 3º quartil e o valor referente ao 1º quartil da distribuição dos dados observados.

Os modelos de predição foram classificados em categorias com base nos valores das métricas. A categorização pela R^2 foi realizada conforme critérios propostos por Terra; Demattê; Rossel (2015), sendo: $R^2 > 0,75$ - modelos bem ajustados para prever com precisão os atributos; $0,50 \leq R^2 \leq 0,75$ - modelos justos, mas que podem ser melhorados; e $R^2 < 0,50$ - modelos não confiáveis e sem capacidade de predição. Para a métrica de RPD, a classificação dos modelos seguiu Chang *et al.* (2001), sendo: $RPD > 2,00$: modelo excelente; $1,40 \leq RPD \leq 2,00$: modelo que necessita de ajustes; e $RPD < 1,40$: modelo não confiável.

Adicionalmente, a qualidade dos modelos foi avaliada com base nos valores de RPIQ. Essa métrica é amplamente empregada para analisar o desempenho de modelos, sendo considerada mais adequada que o RPD para avaliar a qualidade da predição (Bellon-Maurel *et al.*, 2010), visto que é comum a não normalidade dos dados do solo mesmo após sua

transformação, o que torna mais eficaz utilizar a diferença interquartil como medida de dispersão do que o desvio. A classificação dos modelos com base em RPIQ foi feita segundo Coblinski *et al.* (2020): $RPIQ > 2,00$: modelos excelentes; $1,40 \leq RPIQ \leq 2,0$: modelos razoáveis; $RPIQ < 1,4$: modelos não confiáveis.

4.3 Resultados e Discussão

A seguir serão apresentados os resultados da estatística descritiva aplicada aos dados das análises tradicionais e a modelagem preditiva realizada nas faixas vis-NIR-SWIR e MIR.

4.3.1 Estatística descritiva

A Tabela 4 apresenta os resultados da estatística descritiva dos atributos físico-químicos dos solos, considerando os dados antes de aplicar normalização. Ao avaliar a normalidade dos dados por meio do teste de Shapiro-Wilk a 5%, verificou-se que apenas o atributo pH apresentou distribuição normal, não demandando qualquer transformação. Para os atributos silte, argila, C, N, P, K, Mg, Na, Al, V e PST aplicou-se a transformação por raiz quadrada, ao passo que a areia foi transformada pela potência ao quadrado. Nos atributos Ca, SB, CTC e CE utilizou-se a transformação logaritmo de base 10. Apesar das transformações aplicadas, alguns atributos permaneceram com distribuição não normal.

Tabela 4 – Estatística descritiva para os atributos dos 114 solos avaliados sem normalização

Atributo	Média	Mediana	DP	Min.	Max.	As	Cu	1° Q.	3° Q.	S-W (p-value)
Areia (g kg ⁻¹)	710,35	738,00	197,24	100,00	995,00	-0,90	0,72	575,00	848,25	4,33E-05
Silte (g kg ⁻¹)	149,18	123,00	121,04	2,00	552,00	1,19	1,44	54,00	208,50	3,15E-07
Argila (g kg ⁻¹)	140,63	112,00	114,25	3,00	430,00	0,88	-0,04	48,75	191,00	1,10E-06
N (g kg ⁻¹)	0,58	0,36	0,82	0,00	4,96	3,28	13,40	0,10	0,65	2,33E-15
P (mg kg ⁻¹)	8,26	1,90	16,82	0,00	94,60	3,76	14,87	1,0	7,38	3,22E-17
K (cmolc kg ⁻¹)	0,12	0,11	0,07	0,01	0,40	1,14	2,36	0,07	0,16	1,02E-05
Ca (cmolc kg ⁻¹)	2,32	0,89	2,32	0,10	20,87	2,80	7,76	0,30	1,71	9,59E-17
Mg (cmolc kg ⁻¹)	1,78	0,48	1,78	0,00	26,01	4,25	21,35	0,18	1,42	2,21E-18
C (g kg ⁻¹)	4,09	2,70	4,25	0,01	26,76	3,08	12,01	1,80	5,34	2,87E-14
Al (cmolc kg ⁻¹)	0,56	0,17	0,77	0,00	3,45	1,76	2,79	0,00	0,90	8,56E-13
Na (cmolc kg ⁻¹)	0,63	0,07	1,86	0,00	15,75	5,64	39,93	0,04	0,21	3,68E-20
SB (cmolc kg ⁻¹)	4,83	1,64	7,60	0,32	34,57	2,34	4,94	0,66	3,73	6,59E-16
T (cmolc kg ⁻¹)	6,09	3,10	7,73	0,82	34,88	2,30	4,67	1,93	5,38	1,94E-15
V (%)	62,04	65,0	26,73	13,00	100,00	-0,21	-1,27	38,0	88,75	1,93E-05
PST (%)	7,40	2,75	13,36	0,00	68,40	3,02	8,68	1,30	6,40	1,92E-17
CE (dS m ⁻¹)	0,65	0,14	1,68	0,01	10,15	4,26	19,15	0,08	0,28	7,34E-20
pH H ₂ O	5,56	5,50	0,84	3,90	8,20	0,00	0,11	6,10	0,42	0,11

DP: desvio padrão; Min: mínimo; Max: máximo; As: assimetria; Cu: curtose; 1° Q: primeiro quartil; 3° Q: terceiro quartil; S-W: Teste de normalidade por Shapiro-Wilk.

Fonte: elaborada pela autora.

Os coeficientes de assimetria e curtose, de natureza adimensional, corroboraram os resultados do teste de Shapiro-Wilk. Esses coeficientes são frequentemente usados como método alternativo para verificar a distribuição dos dados e sua normalidade, sendo considerados normais os dados que possuem valor de assimetria próximo a 0 e curtose em torno de 3 (Groeneveld; Meeden, 1984; Santos; Ferreira, 2003). A ausência de normalidade é

uma característica comum em variáveis pedológicas, visto que a heterogeneidade natural dos solos é alta com uma ampla variação na distribuição dos atributos, ocasionando a falta de normalidade e uma distribuição muito assimétrica (Bellon-Maurel *et al.*, 2010).

Com relação aos valores médios dos atributos avaliados, observou-se quanto à fração granulométrica, que houve predominância da fração areia. Este resultado está associado à maior representatividade no conjunto de dados avaliados (Apêndice A) da classe de Neossolos que apresentam textura arenosa, e da classe de Argissolos, que possuem como característica intrínseca a presença de horizonte A com maior teor de areia em relação aos horizontes subsuperficiais (Santos *et al.*, 2025).

No que se refere aos atributos químicos, os solos apresentaram pH moderadamente ácido. Os valores médios indicaram elevada capacidade de troca catiônica (CTC) e teores altos de magnésio (Mg), concentrações intermediárias de fósforo (P), potássio (K), cálcio (Ca), alumínio (Al), saturação por bases (V) e soma de bases (SB), além de valores baixos de nitrogênio (N) e carbono orgânico (CO). Embora a lixiviação de bases seja pouco expressiva nas condições do Semiárido, a SB é muito variada devido ao material de origem dos solos (Souza; Leite; Medeiros, 2021).

Quanto às características de salinidade e sodicidade, os atributos porcentagem de saturação por sódio (PST) e condutividade elétrica (CE) devem atender alguns critérios para a classificação dos solos como salinos e/ou sódicos, sendo estes: salinos – $CE > 4 \text{ dS m}^{-1}$ e $PST < 15\%$; sódicos – $CE < 4 \text{ dS m}^{-1}$ e $PST > 15\%$; e salino-sódicos – $CE > 4 \text{ dS m}^{-1}$ e $PST > 15\%$ (FAO, 2024). Com base nos valores máximos observados para esses atributos, o conjunto de solos avaliados enquadra-se em salino-sódico. No entanto, ao se observar os valores médios, verifica-se que nenhum dos critérios é atendido, embora a PST exiba valores elevados.

Esses resultados são justificados pela ocorrência de alguns perfis de solos com caráter salino, sódico ou solódico identificados no terceiro e quarto níveis categóricos (Apêndice A). Os valores elevados de PST evidenciam que a sodicidade constitui um dos principais problemas de degradação dos solos do Nordeste, corroborando a necessidade de monitoramento constante a fim de mitigar os prejuízos associados. A maior parte dos prejuízos associados ao excesso de sais decorre do efeito deletério do sódio trocável, que promove a dispersão de argilas e a degradação da estrutura do solo (Vasconcelos *et al.*, 2013).

4.3.2 Modelagem preditiva com dados espectrais vis-NIR-SWIR

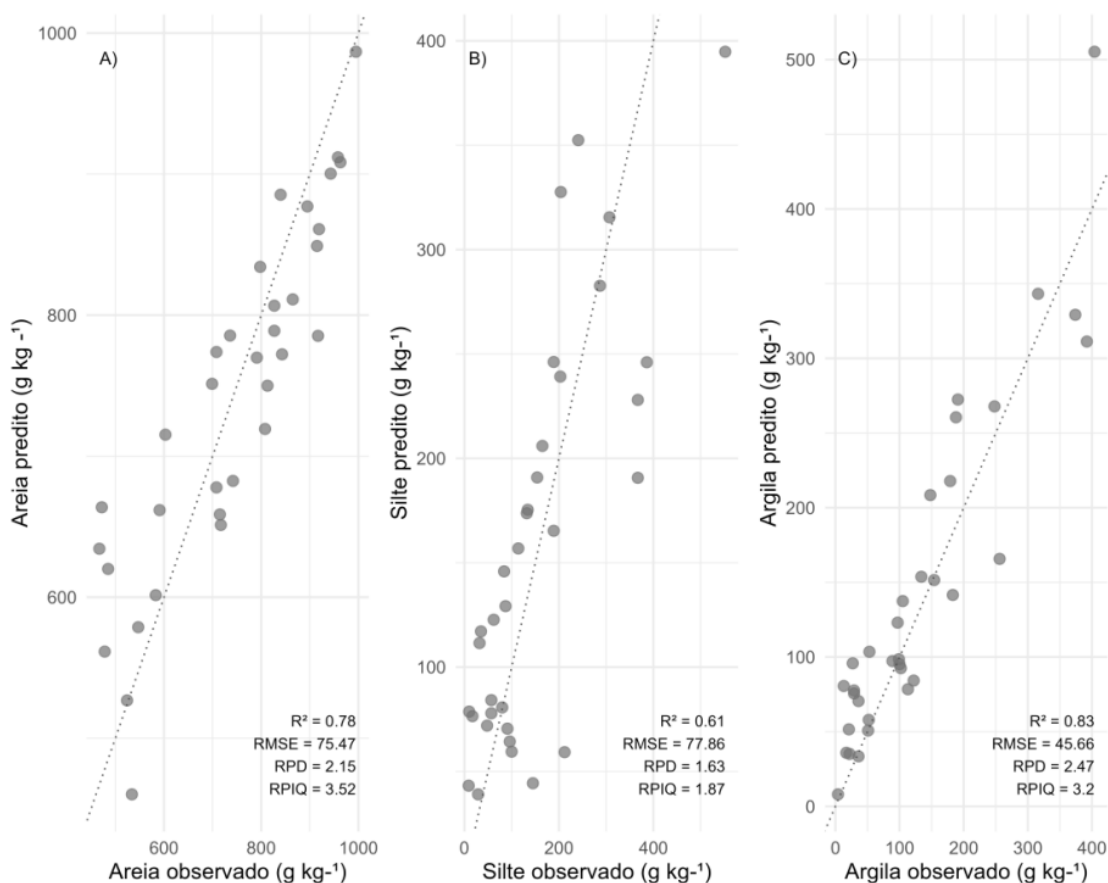
O desempenho dos modelos nas etapas de calibração e validação independente

para a predição dos atributos físicos e químicos dos solos, considerando os diferentes tipos de pré-processamentos e algoritmos multivariados empregados na faixa do visível ao infravermelho de ondas curtas, estão disponíveis nos Apêndices C e D.

O melhor modelo de predição para cada atributo avaliado foi determinado com base nos maiores valores de R^2 , RPD e RPIQ e menores valores de RMSE no conjunto de validação com dados inéditos, e pode ser verificado nas figuras a seguir. Nas figuras dos gráficos de dispersão, os pontos intimamente alinhados com a linha 1:1 (pontilhada) evidenciam a concordância entre os resultados de predições espectrais e as observações laboratoriais.

Para a predição dos atributos físicos (Figura 51), os modelos de areia e argila apresentaram a melhor precisão de predição quando modelados com o algoritmo Cubist, a partir de espectros convertidos para absorbância. Em contrapartida, a modelagem do silte alcançou o melhor desempenho utilizando o algoritmo PLSR associado aos dados espectrais suavizados com o filtro Savitzky-Golay (SG).

Figura 51 – Desempenho dos melhores modelos de validação para areia (A), silte (B) e argila (C) na faixa vis-NIR-SWIR



Fonte: elaborada pela autora.

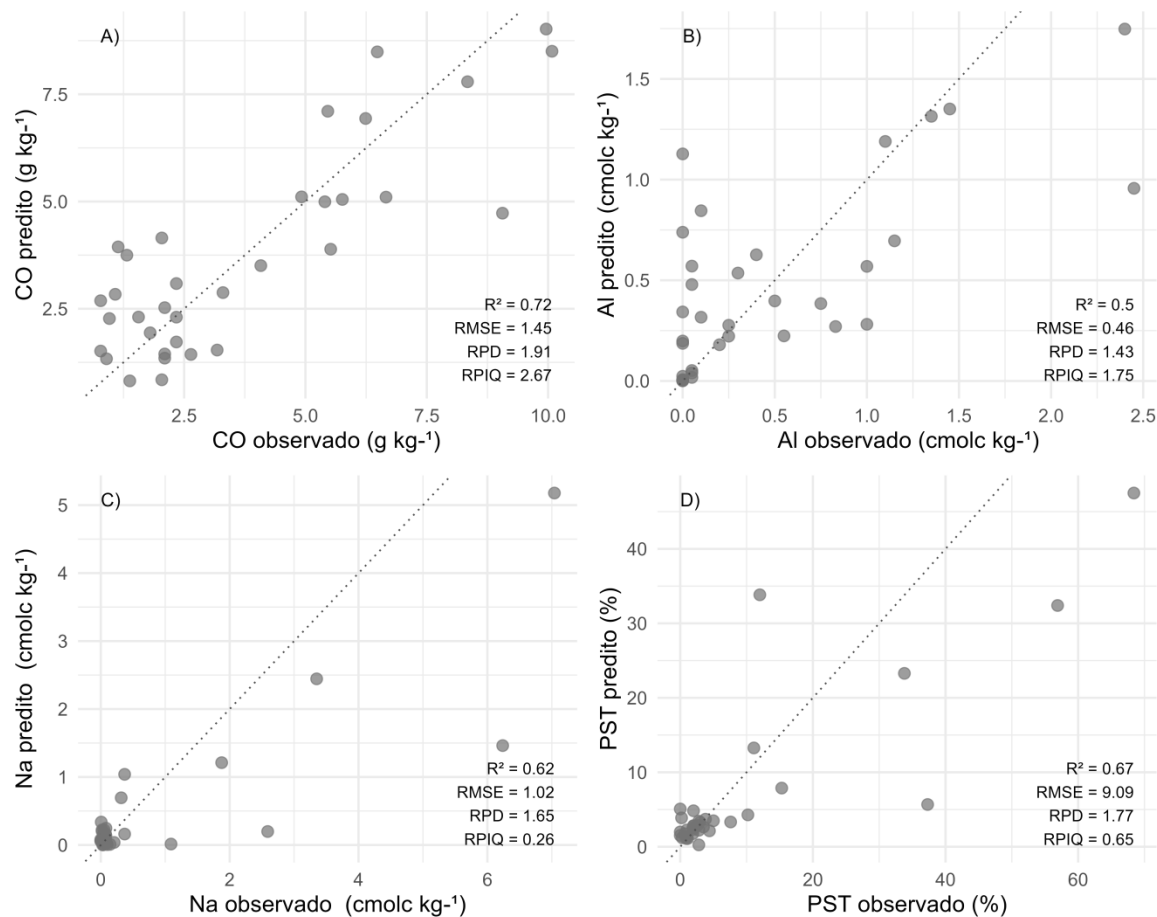
Ao analisar os modelos de validação dos atributos físicos com dados inéditos, constatou-se que a aplicação de técnicas de pré-processamento aos dados brutos foi eficaz em melhorar o desempenho preditivo desses atributos. Verificou-se, ainda, que conforme a categorização baseada nas métricas de avaliação, os modelos para areia e argila foram classificados como excelentes (RPD e $RPIQ > 2,00$). Em contrapartida, a predição do silte foi classificada como razoável necessitando de ajustes no modelo ($1,40 \leq RPD$ e $RPIQ \leq 2,00$), o que foi corroborado pelo valor do coeficiente de determinação ($0,50 \leq R^2 \leq 0,75$).

Os achados deste estudo estão em consonância com resultados de Coblinski *et al.* (2020) e Costa *et al.* (2022), os quais ao realizarem a predição da textura do solo com o algoritmo Cubist, também observaram maior acurácia na predição de areia e argila, em comparação ao modelo de silte. Coblinski *et al.* (2020) atribuíram o desempenho inferior da predição do silte ao fato de sua determinação ser indireta na metodologia convencional, sendo obtido por meio do cálculo de diferença entre os teores de argila e areia.

Os índices de desempenho (R^2 , RPD e $RPIQ$) obtidos neste estudo para areia e argila foram ligeiramente inferiores aos reportados por Terra; Demattê; Rossel (2015) e por Demattê *et al.* (2019). No entanto, apesar das diferenças nos tipos de solos e nas sequências metodológicas empregadas, os modelos aqui desenvolvidos foram classificados como excelentes, apresentando desempenho compatível com os índices alcançados por esses autores. Esse fato reforça que, mesmo diante de condições pedológicas e metodológicas distintas, é viável obter predições espectrais confiáveis dos atributos físicos do solo.

Com relação à predição dos atributos químicos dos solos avaliados, os melhores desempenhos preditivos para os elementos minerais carbono orgânico e sódio, foram observados com o uso dos dados brutos de reflectância combinados com o algoritmo Cubist e a regressão PLSR, respectivamente. Em contraste, a predição do alumínio apresentou maior acurácia quando se utilizou o algoritmo máquina de vetor suporte (SVM) com função Kernel radial, aliado aos dados espectrais suavizados por SG. A predição percentagem de sódio trocável, por sua vez, alcançou o melhor desempenho com o uso do algoritmo Cubist associado aos dados suavizados por SG (Figura 52).

Figura 52 – Desempenho dos melhores modelos de validação para carbono orgânico (A), alumínio (B), sódio (C) e percentagem de sódio trocável (D) na faixa vis-NIR-SWIR



Fonte: elaborada pela autora.

A análise da qualidade dos modelos, com base nas métricas R^2 e RPD, revelou que a predição desses atributos químicos apresentou desempenho razoável, demandando realizar ajustes nos modelos. Em contraste, ao se avaliar o RPIQ, observou-se uma variação significativa, visto que o modelo de CO passou a ser classificado como excelente e os de Na e PST mostraram-se não confiáveis ($RPIQ < 1,4$). Já a performance da predição de Al manteve-se dentro da faixa considerada como razoável.

O modelo obtido para o carbono orgânico superou os desempenhos reportados por Terra; Demattê; Rossel (2015) e por Taghdis; Farpoor; Mahmoodabadi (2022) na faixa vis-NIR-SWIR, no entanto, está alinhado aos resultados de Santos *et al.* (2020) e Ribeiro *et al.* (2021), com valor de R^2 superior a 0,70. Vale ressaltar que no trabalho de Ribeiro *et al.* (2021) foram avaliados apenas duas classes pedológicas, enquanto o presente estudo abrange solos de nove classes oriundos da mesma região geográfica, indicando que a maior variabilidade pedológica não prejudicou a precisão da modelagem espectral do CO.

Para a predição do alumínio, o modelo desenvolvido superou o desempenho

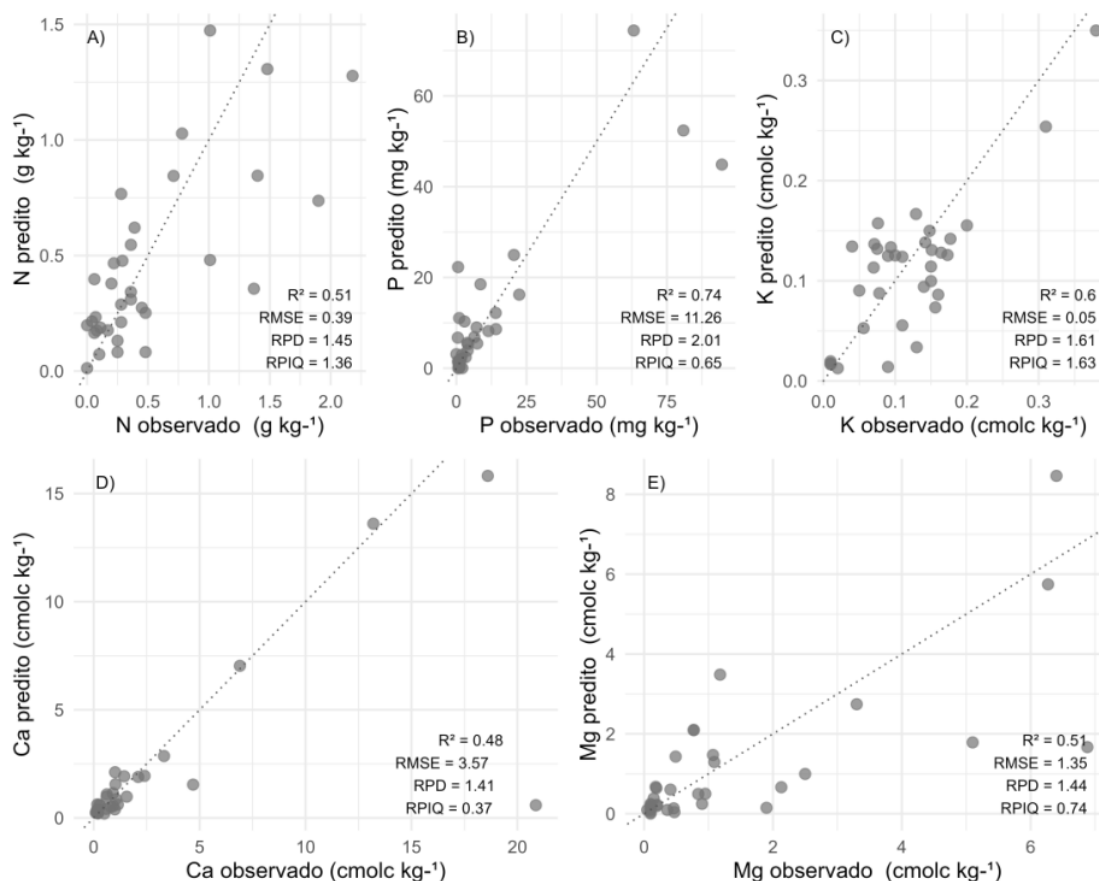
reportado por Beniaich *et al.* (2025), que também empregaram o algoritmo SVM com função Kernel radial na faixa vis-NIR-SWIR. Além disso, o índice de R^2 obtido neste estudo foi mais elevado que o resultado encontrado por Terra; Demattê; Rossel (2015), contudo, estes autores alcançaram maior valor do índice RPIQ, indicando maior precisão do modelo.

O modelo desenvolvido para o Na apresentou desempenho semelhante ao trabalho de O'Rourke *et al.* (2016), com valor de R^2 considerado razoável, porém com RPIQ não confiável. Ainda assim, o modelo obtido superou os resultados de Zhao *et al.* (2021) e de Salazar *et al.* (2023), que utilizaram espectros brutos na faixa de 1350 a 2500 nm. De modo similar, o modelo de PST obtido superou o desempenho reportado por Lotfollahi *et al.* (2023), que realizaram a predição com o algoritmo Cubist na faixa vis-NIR-SWIR, sendo os valores alcançados para RPIQ baixos, em concordância com os resultados deste estudo.

Ressalta-se que há a escassez de trabalhos na literatura voltados à estimativa espectral de sódio e da percentagem de sódio trocável, quando comparado a modelagem de outros atributos químicos. Essa limitação pode estar relacionada ao fato desses atributos serem rotineiramente analisados apenas em solos da região Semiárida, onde a sodicidade é um fator crítico de degradação. Nesse sentido, fica evidente a relevância científica do presente estudo, ao contribuir com conhecimento científico para a região.

Para a predição dos macronutrientes, os melhores modelos de nitrogênio (N) e magnésio (Mg), foram obtidos, respectivamente, com os dados brutos de reflectância associado com o algoritmo Cubist e a regressão PLSR. Para o fósforo (P), potássio (K) e cálcio (Ca), os melhores desempenhos ocorreram com o algoritmo PLSR, sendo a predição de fósforo realizada com os espectros suavizados por SG e os demais nutrientes modelados com os dados convertidos para valores de absorbância (Figura 53).

Figura 53 – Desempenho dos melhores modelos de validação para nitrogênio (A), fósforo (B), potássio (C), cálcio (D) e magnésio (E) na faixa vis-NIR-SWIR



Fonte: elaborada pela autora.

A avaliação da qualidade dos modelos dos macronutrientes variou em função das métricas consideradas. Pela métrica de RPIQ, apenas a predição do K apresentou desempenho razoável ($1,40 \leq \text{RPIQ} \leq 2,00$), enquanto os demais elementos foram classificados como não confiáveis ($\text{RPIQ} < 1,40$). Com base nos valores de RPD, a modelagem de P foi classificada como excelente ($\text{RPD} > 2,0$), com os demais nutrientes apresentando uma predição razoável ($1,4 \leq \text{RPD} \leq 2,0$). Pela métrica de R^2 , o modelo de Ca teve desempenho insatisfatório ($R^2 < 0,50$), enquanto a predição dos demais nutrientes foi razoável ($0,50 \leq R^2 \leq 0,75$).

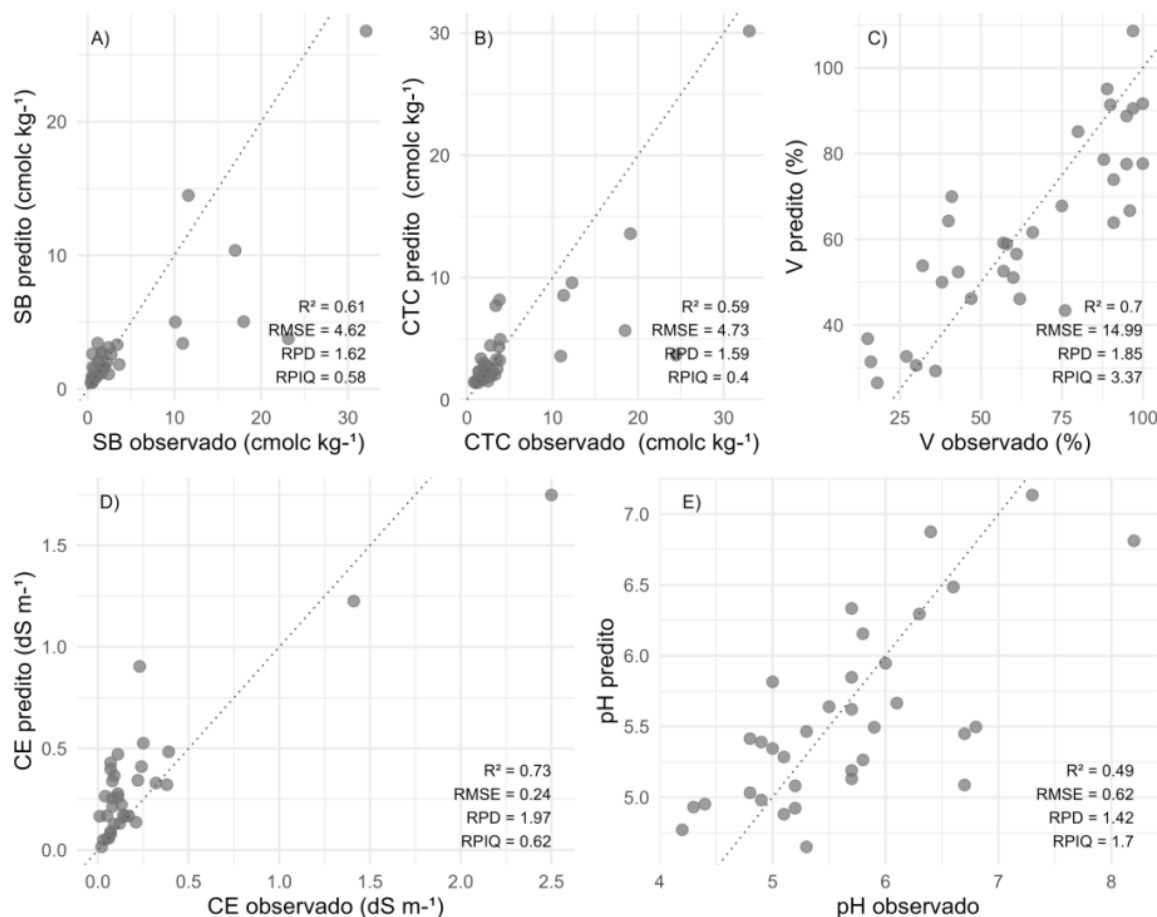
O resultado da modelagem de nitrogênio corroborou os achados de Clingensmith; Grunwald (2022), que também identificaram que o algoritmo Cubist foi o mais adequado para a predição desse nutriente. Entretanto, no que se refere ao desempenho da predição, o modelo obtido foi inferior aos reportados por Santos *et al.* (2020), Asrat *et al.* (2024) e Mondal *et al.* (2025). Essas diferenças podem ser atribuídas a variações nos tipos de solos estudados e nas metodologias empregadas, inclusive para a profundidade de amostragem.

Para as predições de potássio, cálcio e magnésio, os desempenhos obtidos foram

inferiores aos encontrados por Tavares *et al.* (2021). Para o fósforo, potássio, cálcio e magnésio, os modelos desenvolvidos superaram os resultados reportados por Terra; Demattê; Rossel (2015) e Yu *et al.* (2023) em termos de R^2 , porém com valores de RPIQ inferiores. Essa oposição entre os índices de avaliação evidencia que, embora os modelos preditivos estejam capturando bem a variabilidade dos dados, a precisão da predição é limitada e deficiente.

Para a predição dos atributos químicos soma de bases (SB), saturação por bases (V) e pH, os melhores modelos foram obtidos com o uso do algoritmo Cubist em combinação com os dados suavizados por SG. Em relação à capacidade de troca catiônica (CTC) e a condutividade elétrica (CE), os modelos preditivos mais eficazes foram gerados, respectivamente, empregando a regressão PLSR aplicada aos dados brutos de reflectância e aos dados suavizados por SG (Figura 54).

Figura 54 – Desempenho dos melhores modelos de validação para soma de bases (A), capacidade de troca de cátions (B), saturação por bases (C), condutividade elétrica (D) e pH (E) na faixa vis-NIR-SWIR



Fonte: elaborada pela autora.

A análise do desempenho dos modelos preditivos, com base nos valores do índice RPIQ, revelou que a predição de V obteve uma acurácia excelente, enquanto o pH foi classificado como razoável. Já os modelos de SB, CTC e CE foram classificados como não confiáveis. Quando avaliados com as métricas RPD e R^2 , todos os modelos alcançaram desempenho razoável, exceto a predição de pH, que se mostrou não confiável apresentando R^2 inferior a 0,50.

Os modelos de soma de bases e saturação por bases superaram os resultados preditivos de Beniaich *et al.* (2025) na faixa vis-NIR-SWIR, no entanto, esses autores alcançaram um maior valor de RPIQ na predição de SB. Por outro lado, o modelo obtido para SB está em concordância com a modelagem realizada por Demattê *et al.* (2019) para o Ceará, porém, com um erro quadrático médio inferior. O modelo desenvolvido para V obteve desempenho superior ao reportado por Di Raimo *et al.* (2022), contudo, foi inferior as predições realizadas por Tavares *et al.* (2021) e Wei *et al.* (2022), considerando a métrica R^2 .

Para a predição da capacidade de troca catiônica, o desempenho alcançado superou o resultado de Tavares *et al.* (2021), mas foi inferior às modelagens de Terra; Demattê; Rossel (2015) e Taghdis; Farpoor; Mahmoodabadi (2022). Embora o modelo obtido tenha apresentado R^2 superior à predição realizada por Di Raimo *et al.* (2022), o índice RPIQ obtido ficou abaixo do valor reportado por esses autores.

O modelo desenvolvido para a condutividade elétrica apresentou desempenho inferior ao trabalho de Sun *et al.* (2024). No entanto, corroborando os resultados alcançados por esses autores, o valor de RPIQ obtido também foi significativamente menor do que as demais métricas, sugerindo limitações na acurácia preditiva desse atributo. Por outro lado, em termos das métricas R^2 e RPD, o modelo apresentou desempenho superior ao relatado por Lotfollahi *et al.* (2023) na predição de CE empregando o algoritmo PLSR.

Em relação à predição do pH, o modelo obtido foi inferior aos resultados encontrados por Clingensmith; Grunwald (2022), Di Raimo *et al.* (2022) e Sun *et al.* (2024). Embora o modelo desenvolvido tenha apresentado um valor de R^2 consideravelmente menor do que o reportado por Demattê *et al.* (2019) na predição em solos do Ceará, a métrica obtida de RPIQ foi superior, indicando que, apesar da baixa variância explicada, a distribuição dos resíduos quanto à variabilidade dos dados permitiu obter uma predição de precisão razoável.

A análise das métricas obtidas na faixa vis-NIR-SWIR revelou uma relação inversa entre a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação (R^2), de modo que quanto maior a variância explicada, menor o erro. De forma geral, os valores de R^2 seguiram as variações do índice de razão da performance do desvio (RPD), corroborando os

achados de Shen *et al.* (2022). Contudo, o índice da razão de desempenho para intervalo interquartil (RPIQ) não seguiu essa tendência, exibindo comportamento distinto na predição de Na, P, Ca, Mg, SB, CTC e CE. A ocorrência de divergência nas métricas, observada em alguns modelos, indica que a predição apresenta precisão limitada.

As técnicas de pré-processamento espectral utilizadas foram eficientes em melhorar a estabilidade da regressão da maioria dos atributos dos solos, não tendo promovido incrementos na predição dos atributos CO, N, Mg, Na e CTC (Apêndices C e D). A conversão dos valores espectrais para absorvância melhorou a precisão da modelagem de areia, argila, K e Ca, ao passo que a suavização com o filtro Savitzky-Golay foi eficiente em melhorar a predição de silte, Al, P, PST, SB, V, pH e CE.

Corroborando esses resultados, o efeito positivo do pré-processamento sobre o desempenho preditivo de atributos do solo é relatado por diversos autores, como em Santos *et al.* (2020), Asrat *et al.* (2024) e Sun *et al.* (2024). As técnicas de pré-processamento podem melhorar a capacidade de distinção de características espectrais importantes para modelagem (Asrat *et al.*, 2024), como a predição da salinidade, por exemplo, em que o tratamento espectral destaca de modo eficiente pequenas diferenças nos dados espectrais, auxiliando no aumento da sensibilidade da regressão a variações na salinidade do solo (Sun *et al.*, 2024).

Os algoritmos de regressão PLSR e Cubist foram responsáveis por produzir as melhores modelagens da maioria dos atributos avaliados na faixa vis-NIR-SWIR, enquanto o algoritmo SVM usando a função Kernel radial alcançou o melhor desempenho somente na predição do Al e com a função linear não houve produção de bons modelos. De modo semelhante, Di Raimo *et al.* (2022) observaram que as regressões PLSR e Cubist alcançaram destaque entre os métodos de modelagem testados. Por outro lado, Clingensmith; Grunwald (2022) alcançaram os melhores resultados com os modelos cubistas, enquanto o PLSR produziu previsões ruins.

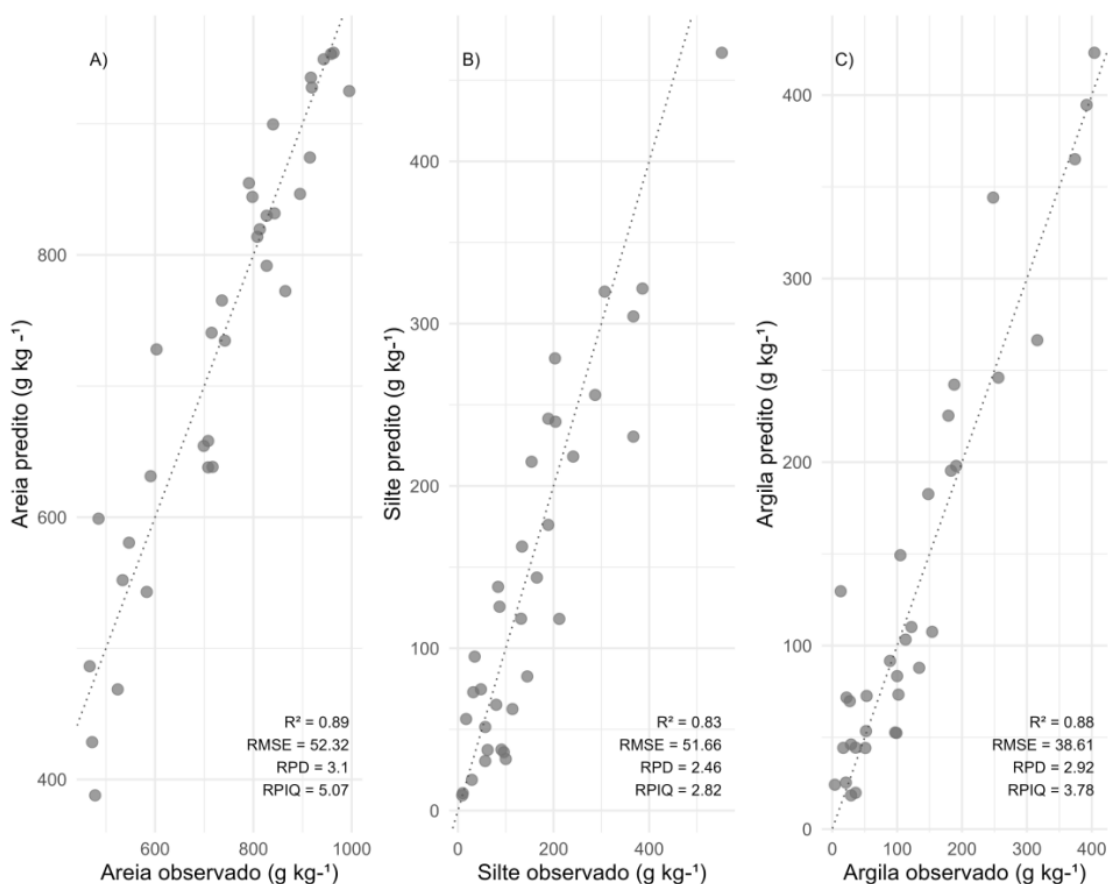
4.3.3 Modelagem preditiva com dados espectrais MIR

Os resultados dos modelos de calibração e validação independente para a predição dos atributos físico-químicos do solo, na faixa do infravermelho médio, estão apresentados nos Apêndices E e F. A modelagem foi conduzida a partir da aplicação de diferentes tipos de pré-processamentos espectrais combinados a algoritmos multivariados. A melhor predição de cada atributo foi definida na validação com dados inéditos com base nos maiores valores de R^2 , RPD e RPIQ, bem como os menores valores de RMSE. O desempenho dos melhores

modelos pode ser visualizado nas figuras com gráficos de dispersão dispostas a seguir.

Para os atributos físicos (Figura 55), os melhores modelos para areia e silte foram obtidos, respectivamente, com os algoritmos Cubist e PLSR, combinados com dados brutos de reflectância. Em contrapartida, a predição de argila apresentou o melhor desempenho com o algoritmo SVM com função Kernel radial, associado aos dados espectrais suavizados por meio do filtro Savitzky-Golay (SG).

Figura 55 – Desempenho dos melhores modelos de validação para areia (A), silte (B) e argila (C) na faixa MIR



Fonte: elaborada pela autora.

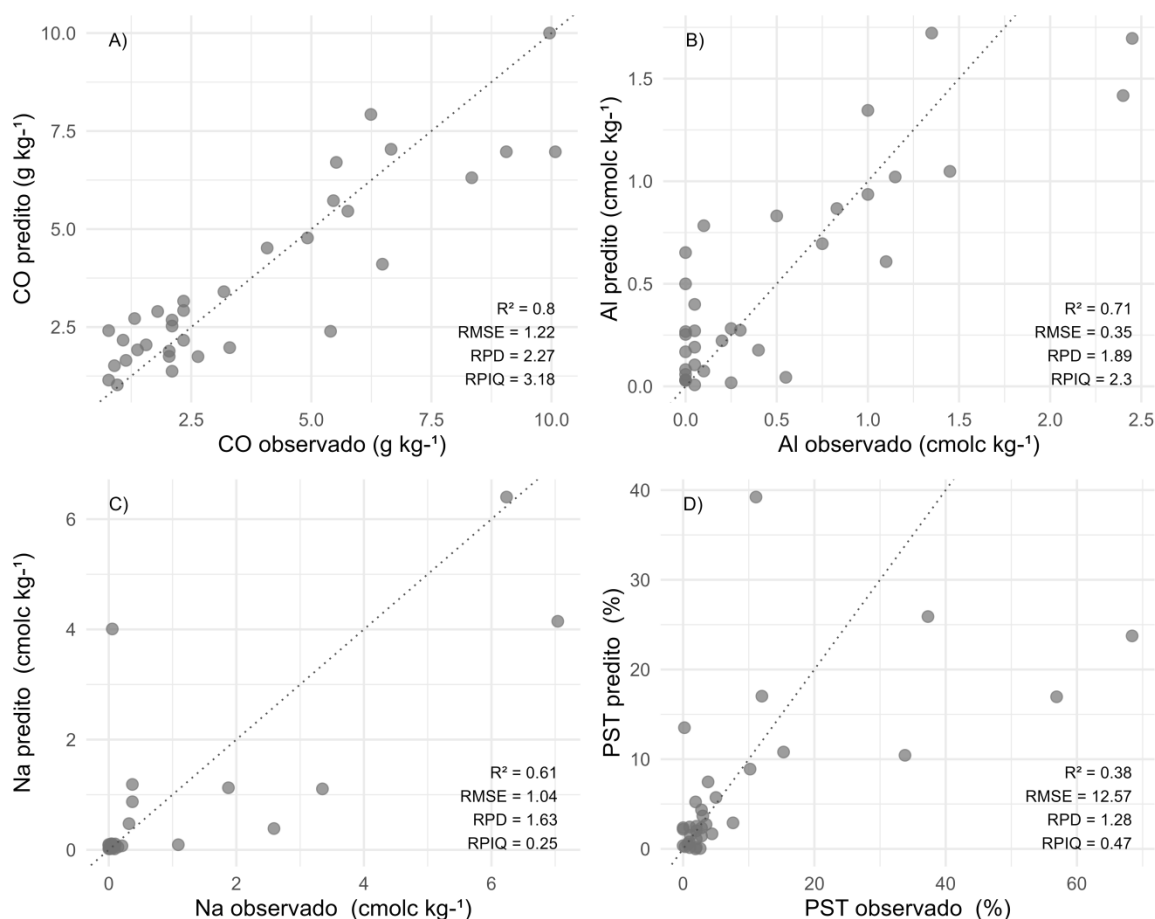
A avaliação dos modelos de validação dos atributos físicos revelou desempenho excelente para as predições de areia, silte e argila para todas as métricas avaliadas, exibindo $R^2 > 0,75$, RPD e RPIQ $> 2,0$. A precisão preditiva desses modelos foi maior na faixa MIR em comparação com aquela obtida com o espectro Vis-NIR-SWIR, resultando também em uma diminuição expressiva do erro.

A performance obtida para os atributos físicos superou os resultados reportados por Wijewardane *et al.* (2018) e Di Raimo *et al.* (2022), estando em consonância com os

achados de Terra; Demattê; Rossel (2015) e Mendes *et al.* (2022) para a predição de areia e argila na faixa MIR. De modo semelhante, os modelos desenvolvidos para areia e argila apresentaram índices compatíveis aos reportados por Ng *et al.* (2022) e Beniaich *et al.* (2025), que foram classificados como excelentes, no entanto, a modelagem de silte alcançou desempenho superior ao obtido por esses autores.

No que se referem aos atributos químicos do solo, os melhores resultados para a predição do carbono orgânico e sódio foram alcançados por meio do algoritmo Cubist, aplicado aos dados espectrais convertidos para absorbância. Por sua vez, os melhores modelos preditivos para o alumínio e percentagem de sódio trocável foram obtidos, respectivamente, com os dados suavizados com o filtro SG associado aos algoritmos PLSR e SVM com função Kernel linear (Figura 56).

Figura 56 – Desempenho dos melhores modelos de validação para carbono orgânico (A), alumínio (B) sódio (C) e percentagem de sódio trocável (D) na faixa MIR



Fonte: elaborada pela autora.

A análise da qualidade dos modelos, considerando as métricas R^2 e RPD, indicou acurácia excelente para as predições de CO, enquanto as modelagens de Al e Na apresentaram

desempenho razoável ($0,50 \leq R^2 \leq 0,75$; $1,4 \leq RPD \leq 2,0$), sugerindo a necessidade de aprimoramento. Em contraste, ao se utilizar o índice RPIQ como critério de avaliação, observou-se uma mudança na classificação, de modo que a predição de Na passou a apresentar desempenho insatisfatório ($RPIQ < 1,4$), Al passou a ter acurácia excelente, enquanto CO manteve desempenho excelente ($RPIQ > 2,0$). Já a predição de PST, obteve resultado insatisfatório para todas as métricas avaliadas.

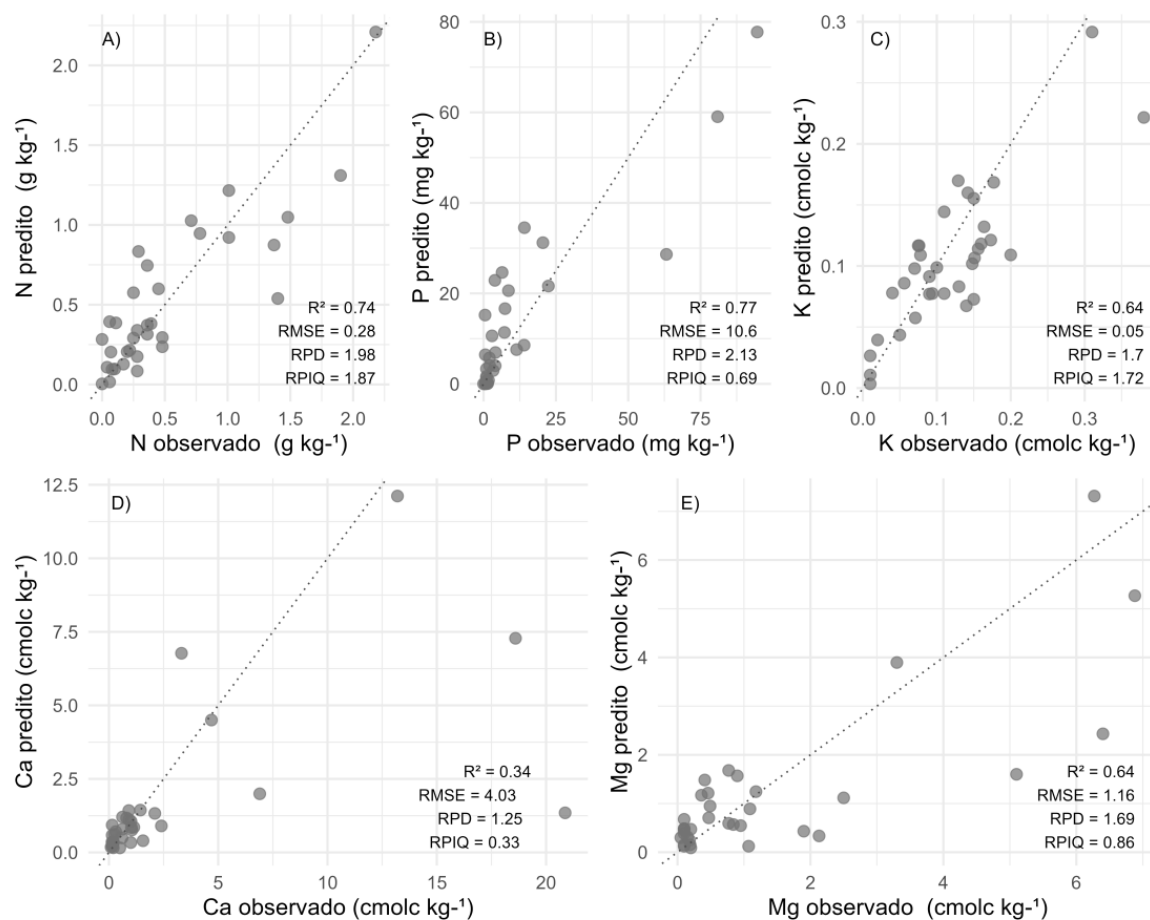
A modelagem de carbono orgânico apresentou desempenho inferior ao reportado por Wijewardane *et al.* (2018), porém, superou o modelo obtido por Mendes *et al.* (2022). Por outro lado, o modelo desenvolvido foi consistente com os resultados encontrados por Santos *et al.* (2020), que modelaram o CO a partir de espectros de absorbância de sete classes de solos do Nordeste brasileiro. Esses achados sugerem que o uso de bancos de dados regionais com uma ampla diversidade pedológica não compromete a precisão preditiva de CO.

Embora os modelos obtidos para carbono orgânico e alumínio tenham apresentando valores inferiores aos reportados por Ng *et al.* (2022), o desempenho das predições mantiveram-se com nível de acurácia excelente. Além disso, as predições de CO e Al estão em concordância com os resultados encontrados por Terra; Demattê; Rossel (2015), e superaram os resultados alcançados por Beniaich *et al.* (2025).

Para o Na, o desempenho do modelo obtido foi inferior ao relatado por Ng *et al.* (2022), porém, superou os resultados encontrados por Rossel *et al.* (2008) e Janik; Forrester; Rawson (2009). De modo análogo, a predição realizada para a PST apresentou desempenho superior ao alcançado por Lotfollahi *et al.* (2023), ao utilizarem o algoritmo Cubist na faixa MIR, sendo o melhor desempenho relatado por esses autores para o modelo baseado na distância de Mahalanobis. No entanto, independentemente do modelo empregado, os valores de RPIQ foram muito baixos, assim como os obtidos neste estudo, o que indica que a precisão da predição para a PST necessita de aprimoramento.

Em relação aos macronutrientes (Figura 57), os melhores desempenhos preditivos para nitrogênio e potássio foram obtidos, respectivamente, com a regressão PLSR aplicada aos espectros suavizados pelo filtro SG e com os dados espectrais em absorbância. A predição do fósforo foi mais eficaz com o algoritmo SVM de função Kernel linear, associado a espectros suavizados com o filtro SG. Para cálcio e magnésio, o melhor ajuste foi obtido com o algoritmo SVM de função Kernel radial, utilizando dados em absorbância e os espectros suavizados com o filtro SG.

Figura 57 – Desempenho dos melhores modelos de validação para nitrogênio (A), fósforo (B), potássio (C), cálcio (D) e magnésio (E) na faixa MIR



Fonte: elaborada pela autora.

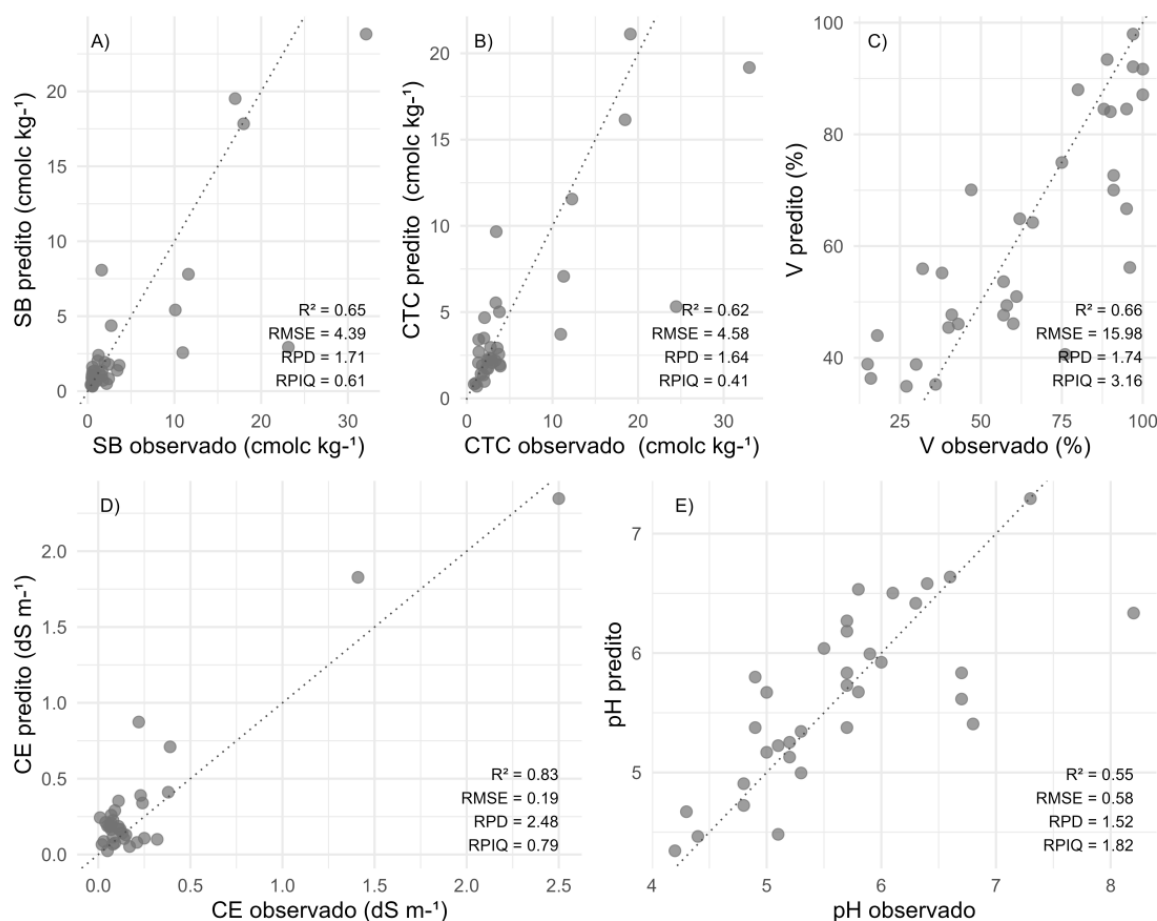
O desempenho dos modelos para os macronutrientes variou conforme a métrica utilizada. Pela métrica de RPIQ, N e K apresentaram desempenho razoável ($1,40 \leq \text{RPIQ} \leq 2,00$), enquanto os modelos dos demais nutrientes foram classificados como de baixa acurácia preditiva ($\text{RPIQ} < 1,40$). Por outro lado, pelas métricas de R^2 e RPD, a predição de P foi considerada excelente ($R^2 > 0,75$ e $\text{RPD} > 2,0$). Os demais elementos, com exceção de Ca que teve desempenho inferior para todas as métricas, foram considerados razoáveis ($0,50 \leq R^2 \leq 0,75$; $1,4 \leq \text{RPD} \leq 2,0$).

A predição de N apresentou desempenho inferior aos modelos de Madari *et al.* (2006) e Wijewardane *et al.* (2018), porém foi consistente com os resultados de Santos *et al.* (2020), que utilizaram para a predição o mesmo algoritmo e pré-processamento deste estudo. Do mesmo modo, a qualidade dos modelos de N e Ca foram inferiores aos obtidos por Garrett *et al.* (2022). Embora a predição de Ca não tenha alcançado desempenho confiável, o melhor resultado foi obtido na modelagem com SVM de função Kernel radial, corroborando o potencial desse algoritmo, também evidenciado por Beniaich *et al.* (2025).

O desempenho dos modelos desenvolvidos para fósforo e potássio superaram os resultados de Wijewardane *et al.* (2018) em todas as métricas avaliadas. As modelagens de fósforo e magnésio também apresentaram R^2 superiores aos valores reportados por Terra; Demattê; Rossel (2015), embora os valores de RPIQ tenham sido inferiores. Em contrapartida, os modelos de potássio e magnésio alcançaram desempenho inferior ao registrado por Ng *et al.* (2022).

Para os atributos soma de bases e capacidade de troca catiônica, os melhores modelos foram obtidos com o algoritmo SVM de função Kernel linear, combinado aos dados suavizados com o filtro SG. A modelagem da saturação por bases apresentou o melhor desempenho com o algoritmo Cubist aplicado aos dados brutos de reflectância. Já os atributos condutividade elétrica e pH, alcançaram os melhores resultados preditivos, respectivamente, com a regressão PLSR associada aos dados espectrais suavizados com SG, e com os espectros convertidos em absorbância (Figura 58).

Figura 58 – Desempenho dos melhores modelos de validação para soma de bases (A), capacidade de troca de cátions (B), saturação por bases (C), condutividade elétrica (D) e pH (E) na faixa MIR



Fonte: elaborada pela autora.

A avaliação dos modelos preditivos com base no índice RPIQ revelou acurácia excelente para a predição de V e desempenho razoável para o modelo de pH. Em contrapartida, os modelos de SB, CTC e CE apresentaram baixos valores desse índice, sendo considerados pouco confiáveis. Por outro lado, quando analisadas as métricas R^2 e RPD, todos os modelos atingiram desempenho razoável, com exceção da predição de CE, cujo desempenho foi excelente, confirmando divergência entre as métricas empregadas.

Os modelos desenvolvidos para SB e CTC apresentaram desempenho inferior aos resultados de Terra; Demattê; Rossel (2015). Do mesmo modo, as modelagens de CTC, V e pH foram inferiores às reportadas por Garrett *et al.* (2022), enquanto as predições de CTC e pH também ficaram abaixo dos resultados obtidos por Wijewardane *et al.* (2018) e Beniaich *et al.* (2025). Ressalta-se que, embora os trabalhos citados também tenham avaliado o solo na faixa MIR, foram adotadas metodologias distintas e avaliado diferentes classes pedológicas, o que contribui para a variação dos resultados apresentados.

Para a predição da condutividade elétrica, o desempenho obtido superou, em termos de R^2 , os valores relatados por Janik; Forrester; Rawson (2009) e Ng *et al.* (2022), contudo apresentou RPIQ inferior. O modelo gerado está alinhado com os achados de Lotfollahi *et al.* (2023) para a modelagem na faixa MIR com o algoritmo PLSR. De modo semelhante ao observado nesse estudo, esses autores também relataram valores de RPIQ substancialmente menores aos das métricas R^2 e RPD, indicando que a alta assimetria na distribuição dos dados de CE afetou diretamente a precisão preditiva.

Quando a população analisada no solo possui distribuição muito assimétrica, a avaliação da capacidade dos modelos preditivos com base no desvio padrão da população torna-se limitada, visto que os valores de RPD obtidos para distribuição normal e log-normal não são diretamente comparáveis. Nesse contexto, o índice RPIQ, que é baseado em quartis, representa melhor a distribuição da população, uma vez que determina faixas equivalentes de dispersão. Em contrapartida, a métrica RPD calculada para distribuições log-normal pode, enganosamente, indicar um bom desempenho (Bellon-Maurel *et al.*, 2010).

Corroborando os resultados obtidos na faixa vis-NIR-SWIR, as técnicas de pré-processamento espectral mostraram-se eficientes em aumentar o poder preditivo para a maioria dos atributos avaliados, com exceção da predição de areia, silte e V (Apêndices E e F). A suavização com o filtro Savitzky-Golay promoveu melhorias na predição de argila, Al, N, P, Mg, SB, CTC, PST e CE, enquanto a conversão dos valores espectrais para absorbância melhorou a precisão da modelagem de CO, K, Ca, Na e pH.

O algoritmo de regressão PLSR foi responsável por produzir as melhores

predições para a maioria dos atributos, comportamento semelhante ao observado na faixa vis-NIR-SWIR. Contudo, na modelagem realizada na faixa MIR, os algoritmos SVM com função Kernel radial e com função linear apresentaram desempenho equivalente algoritmo Cubist. Em contraste, Beniaich *et al.* (2025) relataram que a predição realizada com o SVM-Linear apresentou os melhores resultados, enquanto Santos *et al.* (2020) observaram que os modelos SVM e PLSR apresentaram desempenhos preditivos semelhantes.

4.3.4 Melhores modelos preditivos

O desempenho dos modelos de validação com dados espectrais na região do infravermelho médio superou as modelagens realizadas na faixa do visível ao infravermelho de ondas curtas, tendo em vista que os índices de avaliação (R^2 , RPD e RPIQ) alcançaram os maiores valores em mais de 70% dos atributos nessa faixa (Tabela 5). O atributo cálcio não foi modelado com confiança em nenhuma das regiões espectrais, pois todos os modelos apresentaram R^2 inferior a 0,50, por isso, seu resultado não foi apresentado na tabela a seguir.

Tabela 5 – Resultado dos melhores modelos de validação por atributo do solo

Atributo	Região espectral	Par.	Algoritmo	Tratamento espectral	R^2 valid.	RMSE valid.	RPD	RPIQ
Areia	MIR	20/9	Cubist	Bruto	0,893	52,321	3,095	5,074
Silte	MIR	15	PLSR	Bruto	0,830	51,656	2,462	2,817
Argila	MIR	16	SVM radial	SG	0,879	38,614	2,922	3,781
CO	MIR	20/0	Cubist	Abs	0,800	1,221	2,271	3,182
N	MIR	14	PLSR	SG	0,738	0,283	1,984	1,866
P	MIR	1	SVM linear	SG	0,773	10,600	2,132	0,689
K	MIR	6	PLSR	Abs	0,644	0,046	1,700	1,716
Mg	MIR	32	SVM radial	SG	0,638	1,156	1,686	0,865
Na	vis-NIR-SWIR	14	PLSR	Bruto	0,623	1,020	1,653	0,255
Al	MIR	7	PLSR	SG	0,712	0,352	1,890	2,303
SB	MIR	1	SVM linear	SG	0,648	4,387	1,710	0,609
CTC	MIR	1	SVM linear	SG	0,616	4,578	1,637	0,412
V	vis-NIR-SWIR	1/9	Cubist	SG	0,699	14,995	1,850	3,368
pH	MIR	10	PLSR	Abs	0,553	0,576	1,518	1,822
PST	vis-NIR-SWIR	10/9	Cubist	SG	0,673	9,095	1,775	0,651
CE	MIR	9	PLSR	SG	0,832	0,188	2,478	0,785

Par: parâmetros do modelo; SG: Suavização por Savitzky-Golay; Abs: absorbância; R^2 valid.: coeficiente de determinação da validação; RMSE valid.: raiz do erro quadrático médio da validação; RPD: razão da performance do desvio; RPIQ: razão de desempenho para intervalo interquartil.

Fonte: Elaborado pela autora.

As predições realizadas na faixa do visível ao infravermelho de ondas curtas foram superiores às obtidas com dados espectrais do infravermelho médio apenas para o sódio, percentagem de saturação por sódio e saturação por bases. A menor precisão preditiva observada na região vis-NIR-SWIR está associada à baixa absorção nessa faixa que apresenta fraca assinatura espectral, se relacionando somente com os tons e combinações das bandas moleculares fundamentais presentes no MIR (Ng *et al.*, 2019).

O predomínio de melhores resultados com dados MIR, em comparação a predição no vis-NIR-SWIR, também foi relatado por Terra; Demattê; Rossel (2015), Ng *et al.* (2019) e Beniaich *et al.* (2025) para atributos físicos e químicos do solo, por Terra; Rossel; Demattê (2019) para carbono e por Santos *et al.* (2020) para modelagem de carbono e nitrogênio. Em contraste, Di Raimo *et al.* (2022) observaram que o espectro fundido vis-NIR-SWIR + MIR apresentou o melhor desempenho, seguido do vis-NIR-SWIR, enquanto os modelos exclusivos com a faixa MIR alcançaram resultados inferiores.

Entre os atributos modelados, destacaram-se areia, silte, argila, carbono orgânico, alumínio e saturação por bases, que apresentaram acurácia classificada como excelente. Embora as predições de Al e V tenham exibido valores de R^2 indicativos de desempenho razoável, os altos valores de RPIQ demonstram a boa precisão preditiva dos modelos. Para os demais atributos, a qualidade preditiva foi considerada razoável, em razão da divergência entre as métricas de avaliação, pois, enquanto R^2 e RPD variaram de excelente a razoável, os valores de RPIQ foram, em sua maioria, mais baixos, situando-se entre as classes de razoável e não confiável.

Os baixos valores de RPIQ na modelagem decorrem das características de distribuição dos dados. Para Clingensmith; Grunwald, (2022) os menores valores dessa métrica são justificados pelo alto grau de assimetria e curtose dos dados. De modo complementar, Ng *et al.* (2022) observaram existir uma relação log-linear com o intervalo interquartil (IQR), assim, variáveis que apresentam $IQR < 1$ tendem a ter menores valores de RPIQ e baixa precisão preditiva.

O bom desempenho preditivo da areia, silte, argila e carbono orgânico em todas as faixas espectrais avaliadas, é resultado de suas propriedades intrínsecas, que constituem relações espectrais de primeira ordem. Tais atributos afetam diretamente o espectro do solo, alterando as intensidades de reflectância e as características de absorção (Terra *et al.*, 2021). Por sua vez, o melhor desempenho observado para esses atributos na região MIR é decorrente da forma de interação entre a radiação eletromagnética e os grupos funcionais dos compostos minerais e orgânicos do solo, predominando as vibrações fundamentais nessa faixa, o que

torna a resposta espectral mais expressiva (Beniaich *et al.*, 2025).

O alumínio e a saturação por bases, apesar de não alterarem diretamente o espectro por possuírem relação espectral de segunda ordem, puderam ser modelados com precisão na faixa MIR e vis-NIR-SWIR, respectivamente. Os atributos com relação espectral de segunda ordem não apresentam características de absorção nem modificam diretamente a intensidade de reflectância. Contudo, como geralmente estão adsorvidos ou dependem de grupos funcionais de compostos minerais e orgânicos, podem ser previstos por meio de sua correlação com os atributos de primeira ordem (Terra *et al.*, 2021).

Sob essa perspectiva, Terra; Demattê; Rossel (2015) observaram que propriedades do solo indicativas de acidez, como Al e pH, podem ser estimadas pela sua correlação significativa com o conteúdo de carbono orgânico, o qual apresenta forte interação com a região MIR. Em consonância com esses achados, no presente estudo o carbono orgânico, alumínio trocável e pH apresentaram as melhores previsões na faixa espectral MIR. O resultado obtido reforça que os atributos relacionados à acidez foram modelados por previsões de segunda ordem a partir de sua relação com o CO.

Ainda nessa perspectiva, os macronutrientes são preditos a partir da correlação entre o elemento avaliado e os atributos de primeira ordem (Rizzo *et al.*, 2021). Os nutrientes Ca, Mg e K são normalmente estimados em função da sua covariação com as propriedades mineralógicas (Chang *et al.*, 2001). O N, por sua vez, é modelado pela sua alta correlação com o conteúdo de carbono, enquanto o P é associado tanto a mineralogia da argila quanto ao conteúdo de matéria orgânica (Terra *et al.*, 2021).

Embora exista grande interesse no uso da espectroscopia de reflectância para prever macronutrientes e atributos relacionados à fertilidade química do solo, a literatura evidencia resultados muito variáveis (Terra *et al.*, 2021). Em consonância, neste estudo a predição dos macronutrientes apresentou desempenho variado, com os modelos de N e K alcançando os melhores valores das métricas de ajuste, enquanto o P e Mg mostraram resultados contrastantes para as métricas. O mesmo comportamento foi observado para o Na, também cátion trocável, sugerindo tratar-se de uma previsão de segunda ordem, associada com as propriedades mineralógicas.

As previsões de CE e PST foram classificadas como de terceira ordem, por estarem relacionadas à atributos de segunda ordem. A condutividade elétrica do solo está ligada ao acúmulo de sais solúveis em água, como Na, Ca e Mg, enquanto a percentagem de sódio trocável possui relação direta com os valores de Na e CTC, sendo, portanto, influenciada pela composição catiônica do solo. Os cátions Ca e Mg desempenham papel

expressivo na formação dos carbonatos e na estrutura dos argilominerais do tipo 2:1, os quais afetam diretamente o espectro do solo (Lotfollahi *et al.*, 2023).

Considerando o desempenho razoável dos modelos de CE e PST, acredita-se que ajustes metodológicos, como a aplicação de diferentes algoritmos e a ampliação do conjunto de dados, possam aumentar a precisão preditiva. Di Raimo *et al.* (2022) destacaram que acréscimos na base de dados e na amplitude dos valores dos atributos podem promover ganhos significativos no desempenho dos modelos, especialmente na etapa de validação. Assim, tais ajustes metodológicos não devem ser negligenciados, sobretudo diante da escassez de estudos espectrais desses atributos na faixa do MIR, reforçando a importância de pesquisas que avancem nessa direção.

Com relação aos algoritmos de regressão avaliados, a regressão PLSR foi a mais eficiente, produzindo os melhores modelos para sete atributos (silte, N, K, Na, Al, pH e CE), enquanto os métodos de aprendizado de máquina, apresentaram eficiência ligeiramente menor, tendo os três algoritmos testados (SVM radial, SVM linear e Cubist) promovido os melhores modelos para os demais atributos. Esses resultados contrastam com os relatados por Dangal *et al.* (2019), que observaram superioridade do algoritmo Cubist em relação à regressão PLSR na predição de atributos do solo em uma biblioteca nacional, tendo o Cubist sido ligeiramente superior a outros métodos de aprendizado de máquina.

É importante destacar que nenhum algoritmo pode ser considerado o melhor, de modo que a sua eficiência depende do conjunto de dados e da região especificada (Mondal *et al.*, 2025). No presente estudo, como o conjunto de dados avaliado era relativamente pequeno e oriundo de uma mesma região geográfica, acredita-se que não havia predomínio de relações muito complexas entre os atributos do solo e os dados espectrais. Nesses casos em que as relações tendem a ser mais simples, o algoritmo PLSR pode obter bons resultados preditivos.

A regressão PLSR é apropriada para a predição com conjunto de dados relativamente homogêneo e com relação linear, entretanto, quando se trata de dados heterogêneos seu desempenho é limitado, sendo necessário usar técnicas mais complexas e não lineares, como os métodos de aprendizado de máquina (Shen *et al.*, 2022). Nessas circunstâncias, os algoritmos Cubist e SVM podem produzir bons resultados, uma vez que capturam tanto relações lineares quanto não lineares, além de apresentarem menor sensibilidade a valores discrepantes (Clingensmith; Grunwald, 2022; Beniaich *et al.*, 2025).

No que se refere à eficiência dos métodos de pré-processamento, a suavização com o filtro Savitzky-Golay destacou-se como a técnica mais eficaz, resultando nos melhores desempenhos para a maioria dos atributos avaliados. Em contrapartida, os dados de

reflectância bruta e os convertidos em absorbância proporcionaram ganhos mais restritos, promovendo melhorias em um menor número de atributos. Diferentemente dos resultados obtidos, Santos *et al.* (2020) relataram que, dentre os sete tipos de pré-processamento avaliados, a técnica de Savitzky-Golay apresentou o menor desempenho. Esses achados ratificam que não há uma técnica de processamento universalmente aplicável.

Considerando que apenas a modelagem de cálcio apresentou desempenho não confiável, sendo classificada como incapaz de gerar predição precisa, entende-se que a adoção de outras abordagens metodológicas pode melhorar a precisão preditiva dos modelos com desempenho entre razoável e excelente. Nesse sentido, as previsões classificadas como razoáveis podem ser melhoradas por meio de ajustes nos dados de calibração e do uso de modelos estatísticos mais robustos; contudo, os modelos enquadrados na faixa de não confiável, provavelmente, não apresentam potencial de melhora (Chang *et al.*, 2001).

Nessa perspectiva, o aumento da base de dados com adição de amostras da região estudada e a estratificação dos dados considerando características pedológicas ou espectrais podem ser abordagens promissoras, conforme foi relatado por Wijewardane *et al.* (2018). Os autores observaram que a estratificação das amostras pedológicas se embasando no horizonte ou na ordem de solo é uma estratégia eficaz para melhorar o desempenho preditivo.

4.4 Conclusões

Os resultados obtidos neste estudo validam a hipótese proposta de que a espectroscopia de reflectância do visível ao infravermelho médio (vis-MIR) é capaz de prever com precisão os atributos físico-químicos de solos do Nordeste brasileiro, constituindo uma alternativa eficiente aos métodos tradicionais de análise do solo. O atributo cálcio apresenta-se como exceção, pela obtenção de modelos sem confiabilidade em todas as faixas avaliadas.

Adicionalmente, confirma-se o ganho preditivo da faixa do infravermelho médio para a maioria dos atributos avaliados, evidenciado pelo aumento dos valores das métricas de R^2 , RPD e RPIQ. As interações fundamentais entre a radiação e os constituintes do solo na faixa MIR resultam na melhoria da variabilidade explicada e da precisão preditiva dos modelos, corroborando a conjectura do maior potencial preditivo desta região do espectro.

O estudo demonstra que o desempenho dos modelos é fortemente influenciado pelas técnicas quimiométricas adotadas. Assim, a aplicação de técnicas de pré-processamento, especialmente a suavização Savitzky-Golay, representa uma etapa fundamental para extrair

informações importantes e melhorar a qualidade das regressões. Além disso, constata-se que o tipo de algoritmo de regressão tem grande impacto, evidenciando que técnicas consolidadas, como a regressão por mínimos quadrados parciais, podem apresentar desempenho equivalente ou superior aos métodos de aprendizado de máquina mais complexos.

Por fim, a predição da salinidade e sodicidade por meio da quantificação da condutividade elétrica e da percentagem de sódio trocável, representam um avanço significativo, dada a escassez de estudos de espectroscopia, principalmente na faixa do MIR, dedicadas a estes atributos. O desempenho razoável obtido nos modelos abre espaço para novas investigações que visem melhorar a precisão preditiva, evidenciando o potencial de utilização da espectroscopia de reflectância como técnica rápida e eficiente para o monitoramento de solos susceptíveis à degradação.

5 CONSIDERAÇÕES FINAIS

Os resultados obtidos ratificam o potencial da espectroscopia de reflectância como uma ferramenta alternativa e eficiente para a análise pedológica. Corroborando as hipóteses propostas, esta técnica demonstra capacidade para caracterizar o comportamento espectral e os atributos dos solos do Nordeste brasileiro, bem como para realizar previsões dos atributos de forma confiável. Nesse contexto, as avaliações qualitativas e quantitativas dos dados espectrais mostram-se complementares, configurando uma metodologia robusta para a caracterização dos solos, especialmente em áreas extensas e heterogêneas, como o Nordeste.

Os solos avaliados caracterizam-se pelos elevados teores de areia, pela presença de minerais primários e secundários menos intemperizados e pela ocorrência frequente de carbonatos. Estas características diferenciam os solos do Nordeste daqueles de regiões tropicais úmidas e influenciam diretamente o comportamento espectral. Tais aspectos refletem-se na alteração da intensidade de reflectância e na presença de feições de absorção específicas nas curvas espectrais, observadas, principalmente, nos horizontes subsuperficiais, os quais possuem relevância diagnóstica para a classificação dos solos.

Além disso, os solos do Nordeste destacam-se pela alta concentração de sais, o que lhes confere características de salinidade e sodicidade. Embora tais atributos não sejam identificáveis no espectro, a aplicação da técnica de classificação não supervisionada possibilita a identificação de grupos de amostras com estas características, sobretudo quando usado dados da faixa do infravermelho médio. Resultado que é inovador para a caracterização dos solos desta região.

O acúmulo de sais observado em muitos dos perfis de solos analisados evidencia a expressiva ocorrência da salinidade e sodicidade na região Nordeste, corroborando a susceptibilidade desses solos à degradação. Assim, técnicas com potencial para avaliar essas características de forma rápida e de baixo custo devem ser priorizadas. Nessa perspectiva, as análises espectrais configuram-se como uma ferramenta promissora, uma vez que os resultados obtidos neste estudo já evidenciam desempenho razoável. Portanto, recomenda-se o desenvolvimento de novas pesquisas visando aprimorar o desempenho da modelagem espectral para a previsão da salinidade e sodicidade.

REFERÊNCIAS

- ALVES, J. J. A.; ARAÚJO, M. A. de; NASCIMENTO, S. S.. DEGRADAÇÃO DA CAATINGA: UMA INVESTIGAÇÃO ECOGEOGRÁFICA. **Caminhos de Geografia**, Uberlândia, v. 9, n. 27, p. 143–155, 2008. DOI: <https://doi.org/10.14393/RCG92715740>.
- ARAUJO FILHO, J. C. de; MARQUES, F. A.; AMARAL, A. J. do; CUNHA, T. J. F.; SOUZA JÚNIOR, V. S. DE; GALVÃO, P. V. M. Solos do Semiárido: características e estoque de carbono. In: GIONGO, V.; ANGELOTTI, F. (eds.). **Agricultura de baixa emissão de carbono em regiões semiáridas: experiência brasileira**. Brasília: EMBRAPA, 2022. p. 93–112.
- ASRAT, T. G.; BREURE, T.; SAKRABANI, R.; CORSTANJE, R.; HASSALL, K. L.; HAMMA, A.; KEBEDE, F.; HAEFELE, S. M. A Moroccan soil spectral library use framework for improving soil property prediction: Evaluating a geostatistical approach. **Geoderma**, [s. l.], v. 452, p. 117116, 2024. DOI: <https://doi.org/10.1016/j.geoderma.2024.117116>.
- BELLINASSO, H.; DEMATTÊ, J. A. M.; ROMEIRO, S. A. Soil spectral library and its use in soil classification. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 34, p. 861-870, 2010. DOI: <https://doi.org/10.1590/S0100-06832010000300027>.
- BELLON-MAUREL, V.; FERNANDEZ-AHUMADA, E.; PALAGOS, B.; ROGER, J. M.; MCBRATNEY, A. Critical review of chemometric indicators commonly used for assessing the quality of the prediction of soil attributes by NIR spectroscopy. **TrAC Trends in Analytical Chemistry**, [s. l.], v. 29, p. 1073-1081, 2010. DOI: <https://doi.org/10.1016/j.trac.2010.05.006>.
- BENIAICH, A.; TERRA, F. S.; DEMATTÊ, J. A. M.; HORÁK-TERRA, I.; MARTINS, J. K. D.; SOUSA-BARACHO, I. P. Enhancing soil property predictions using spectral fusion: Comparisons between outer product analysis and vector concatenation and among modeling algorithms. **Soil and Tillage Research**, [s. l.], v. 251, p. 106546, 2025. DOI: <https://doi.org/10.1016/j.still.2025.106546>.
- BEZDEK, J. C. Cluster Validity with Fuzzy Sets. **Journal of Cybernetics**, [s. l.], v. 3, p. 58–73, 1974. DOI: <https://doi.org/10.1080/01969727308546047>.
- CEZAR, E.; NANNI, M. R.; CHICATI, M. L.; SOUZA JÚNIOR, I. G.; COSTA, A. C. S. Uso de dados espectrais para estimar a relação entre óxidos de ferro e minerais 2: 1 com suas respectivas reflectâncias. **Semina: Ciências Agrárias**, Londrina, v. 34, p. 1479-1491, 2013. DOI: <https://doi.org/10.5433/1679-0359.2013v34n4p1479>.
- CHANG, C.-W.; LAIRD, D. A.; MAUSBACH, M. J.; HURBURGH, C. R. Near-Infrared Reflectance Spectroscopy–Principal Components Regression Analyses of Soil Properties. **Soil Science Society of America Journal**, [s. l.], v. 65, p. 480–490, 2001. DOI: <https://doi.org/10.2136/sssaj2001.652480x>.
- CLINGENSMITH, C. M.; GRUNWALD, S. Predicting Soil Properties and Interpreting Vis-NIR Models from across Continental United States. **Sensors**, Basel, v. 22, p. 3187, 2022. DOI: <https://doi.org/10.3390/s22093187>.

COBLINSKI, J. A.; GIASSON, É.; DEMATTÊ, J. A. M.; DOTTO, A. C.; COSTA, J. J. F.; VAŠÁT, R. Prediction of soil texture classes through different wavelength regions of reflectance spectroscopy at various soil depths. **Catena**, [s. l.], v. 189, p. 104485, 2020. DOI: <https://doi.org/10.1016/j.catena.2020.104485>.

COSMA, G.; BROWN, D.; ARCHER, M.; KHAN, M.; GRAHAM POCKLEY, A. A survey on computational intelligence approaches for predictive modeling in prostate cancer. **Expert Systems with Applications**, New York, v. 70, p. 1–19, 2017. DOI: <https://doi.org/10.1016/j.eswa.2016.11.006>.

COSTA, J. J. F.; GIASSON, É.; DA SILVA, E. B.; TIECHER, T.; DE SENA, A. F. S.; SILVA, R. G. P. O. Soil texture prediction through stratification of a regional soil spectral library. **Pedosphere**, [s. l.], v. 32, p. 294–306, 2022. DOI: [https://doi.org/10.1016/S1002-0160\(21\)60074-7](https://doi.org/10.1016/S1002-0160(21)60074-7).

DALMOLIN, R. S. D.; GONÇALVES, C. N.; KLAMT, E.; DICK, D. P. Relação entre os constituintes do solo e seu comportamento espectral. **Ciência Rural**, Santa Maria, v. 35, p. 481–489, 2005. DOI: <https://doi.org/10.1590/S0103-84782005000200042>.

DANGAL, S. R. S.; SANDERMAN, J.; WILLS, S.; RAMIREZ-LOPEZ, L. Accurate and precise prediction of soil properties from a large mid-infrared spectral library. **Soil Systems**, Switzerland, v. 3, p. 1–23, 2019. DOI: <https://doi.org/10.3390/soilsystems3010011>.

DEMATTÊ, J. A. M. Characterization and discrimination of soils by their reflected electromagnetic energy. **Pesquisa Agropecuária Brasileira**, Brasília, v. 37, p. 1445–1458, 2002. DOI: <https://doi.org/10.1590/S0100-204X2002001000013>.

DEMATTÊ, J. A. M. et al. Genesis and properties of wetland soils by VIS-NIR-SWIR as a technique for environmental monitoring. **Journal of Environmental Management**, [s. l.], v. 197, p. 50–62, 2017. DOI: <https://doi.org/10.1016/j.jenvman.2017.03.014>.

DEMATTÊ, J. A. M. et al. The Brazilian Soil Spectral Library (BSSL): A general view, application and challenges. **Geoderma**, [s. l.], v. 354, p. 113793, 2019. DOI: <https://doi.org/10.1016/j.geoderma.2019.05.043>.

DEMATTÊ, J. A. M.; BELLINASSO, H.; ROMERO, D. J.; FONGARO, C. T. Morphological Interpretation of Reflectance Spectrum (MIRS) using libraries looking towards soil classification. **Scientia Agricola**, Piracicaba, v. 71, p. 509–520, 2014. DOI: <https://doi.org/10.1590/0103-9016-2013-0365>.

DEMATTÊ, J. A. M.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Influência da matéria orgânica e de formas de ferro na reflectância de solos tropicais. **Bragantia**, Campinas, v. 62, p. 451–464, 2003. DOI: <https://doi.org/10.1590/S0006-87052003000300012>.

DEMATTÊ, J. A. M.; SILVA, M. L. S.; ROCHA, G. C.; CARVALHO, L. A.; FORMAGGIO, A. R.; FIRME, L. P. Variações espectrais em solos submetidos à aplicação de torta de filtro. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, p. 317–326, 2005. DOI: <https://doi.org/10.1590/S0100-06832005000300001>.

DEMATTE, J. A. M.; SOUSA, A. A.; ALVES, M. C.; NANNI, M. R.; FIORIO, P. R.; CAMPOS, R. C. Determining soil water status and other soil characteristics by spectral proximal sensing. **Geoderma**, [s. l.], v. 135, p. 179-195, 2006. DOI: <https://doi.org/10.1016/j.geoderma.2005.12.002>.

DEMATTE, J. A. M.; TERRA, F. DA S. Spectral pedology: A new perspective on evaluation of soils along pedogenetic alterations. **Geoderma**, [s. l.], v. 217, p. 190–200, 2014. DOI: <https://doi.org/10.1016/j.geoderma.2013.11.012>.

DEWITTE, O.; JONES, A.; ELBELRHITI, H.; MONTANARELLA, L. Satellite remote sensing for soil mapping in Africa: An overview. **Progress in Physical Geography**, [s. l.], v. 36, p. 514–538, 2012. DOI: <https://doi.org/10.1177/0309133312446981>.

DI RAIMO, L. A. D. L. et al. Characterizing and Modeling Tropical Sandy Soils through VisNIR-SWIR, MIR Spectroscopy, and X-ray Fluorescence. **Remote Sensing**, Basel, v. 14, p. 1–24, 2022. DOI: <https://doi.org/10.3390/rs14194823>.

EPIPHANIO, J. C. N.; FORMAGGIO, A. R.; VALERIANO, M. M.; OLIVEIRA, J. B. **Comportamento espectral de solos do Estado de São Paulo**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 1992.

FAO – FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **A primer on soil analysis using visible and near-infrared (vis-NIR) and mid-infrared (MIR) spectroscopy**. Roma: FAO, 2022. Disponível em: <https://openknowledge.fao.org/handle/20.500.14283/cd4502en>. Acesso em: 10 fev. 2025.

FAO – FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **Global status of salt-affected soils**. Rome: FAO, 2024. DOI: <https://doi.org/10.4060/cd3044en>.

GARRETT, L. G.; SANDERMAN, J.; PALMER, D. J.; DEAN, F.; PATEL, S.; BRIDSON, J. H.; CARLIN, T. Mid-infrared spectroscopy for planted forest soil and foliage nutrition predictions, New Zealand case study. **Trees, Forests and People**, Amsterdam, v. 8, p. 100280, 2022. DOI: <https://doi.org/10.1016/j.tfp.2022.100280>.

GE, Y.; WADOUX, A.; PENG, Y. **A primer on soil analysis using visible and near-infrared (vis-NIR) and mid-infrared (MIR) spectroscopy**. Rome: FAO, 2022. DOI: <https://doi.org/10.4060/cb9005en>.

GENÚ, A. M.; DEMATTE, J. A. M.; FIORIO, P. R. Análise espectral de solos da Região de Mogi-Guaçu (SP). **Semina: Ciências Agrárias**, Londrina, v. 31, p. 1235-1244, 2010. DOI: <https://doi.org/10.5433/1679-0359.2010v31n4Sup1p1235>.

GROENEVELD, R. A.; MEEDEN, G. Measuring Skewness and Kurtosis. **The Statistician**, London, v. 33, p. 391-399, 1984. DOI: <https://doi.org/10.2307/2987742>.

HAILU, B.; MEHARI, H. Impacts of Soil Salinity/Sodicity on Soil-Water Relations and Plant Growth in Dry Land Areas: A Review. **Journal of Natural Sciences Research**, Hong Kong, v. 12, p. 1–10, 2021. DOI: <https://doi.org/10.7176/JNSR/12-3-01>.

JANIK, L. J.; FORRESTER, S. T.; RAWSON, A. The prediction of soil chemical and physical properties from mid-infrared spectroscopy and combined partial least-squares regression and neural networks (PLS-NN) analysis. **Chemometrics and Intelligent Laboratory Systems**, [s. l.], v. 97, p. 179–188, 2009. DOI: <https://doi.org/10.1016/j.chemolab.2009.04.005>.

KÄMPF, N.; CURI, N. Formação e evolução do solo (pedogênese). In: KER, J. C.; CURI, N.; SCHAEFER, C. E. G. R.; VIDAL-TORRADO, P. (eds.). **Pedologia: Fundamentos**. Viçosa: Sociedade Brasileira de Ciência do Solo, 2012. p. 207–302.

LEVANTAMENTO de reconhecimento de média intensidade dos solos do estado do Ceará. Fortaleza: Coletivo Duas Catitas, 2024.

LOTFOLLAHI, L.; DELAVAR, M. A.; BISWAS, A.; FATEHI, S.; SCHOLTEN, T. Spectral prediction of soil salinity and alkalinity indicators using visible, near-, and mid-infrared spectroscopy. **Journal of Environmental Management**, [s. l.], v. 345, p. 118854, 2023. DOI: <https://doi.org/10.1016/j.jenvman.2023.118854>.

LUCE, M. S.; ZIADI, N.; ROSSEL, R. A. V. GLOBAL-LOCAL: A new approach for local predictions of soil organic carbon content using large soil spectral libraries. **Geoderma**, [s. l.], v. 425, p. 116048, 2022. DOI: <https://doi.org/10.1016/j.geoderma.2022.116048>.

MADEIRA NETTO, J. S.; BAPTISTA, G. M. M. **Reflectância espectral de solos**. Planaltina: Embrapa Cerrados, 2000.

MADARI, B. E.; REEVES, J. B.; MACHADO, P. L. O. A.; GUIMARÃES, C. M.; TORRES, E.; MCCARTY, G. W. Mid- and near-infrared spectroscopic assessment of soil compositional parameters and structural indices in two Ferralsols. **Geoderma**, [s. l.], v. 136, p. 245–259, 2006. DOI: <https://doi.org/10.1016/j.geoderma.2006.03.026>.

MENDES, W. S. et al. The Brazilian soil Mid-infrared Spectral Library: The Power of the Fundamental Range. **Geoderma**, [s. l.], v. 415, p. 115776, 2022. DOI: <https://doi.org/10.1016/j.geoderma.2022.115776>.

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

MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. (Org.). **Reflectância dos materiais terrestres: análise e interpretação**. São Paulo: Oficina de textos, 2019.

MONDAL, B. P.; SAHOO, R. N.; DAS, B.; AHMED, N.; BANDYOPADHYAY, K. K.; MUKHERJEE, J.; ARORA, A.; MOURSRY, A. R. A. Comparison of multivariate machine learning models for major soil nutrients prediction using laboratory-based and airborne (AVIRIS-NG) visible near-infrared spectroscopy. **European Journal of Agronomy**, Amsterdam, v. 170, p. 127726, 2025. DOI: <https://doi.org/10.1016/j.eja.2025.127726>.

MOURA-BUENO, J. M.; DALMOLIN, R. S. D.; HORST-HEINEN, T. Z.; TEN CATEN, A.; VASQUES, G. M.; DOTTO, A. C.; GRUNWALD, S. When does stratification of a subtropical soil spectral library improve predictions of soil organic carbon content? **Science of the Total Environment**, [s. l.], v. 737, p. 139895, 2020. DOI:

<https://doi.org/10.1016/j.scitotenv.2020.139895>.

MUKAKA, M. M. Statistics corner: A guide to appropriate use of correlation coefficient in medical research. **Malawi Medical Journal**, Blantyre, v. 24, p. 69–71, 2012. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC3576830/>. Acesso em: 15 jun. 2025.

NAIMI, S.; AYOUBI, S.; RAIMO, L. A. D. L.; DEMATTÊ, J. A. M. Quantification of some intrinsic soil properties using proximal sensing in arid lands: Application of Vis-NIR, MIR, and pXRF spectroscopy. **Geoderma Regional**, [s. l.], v. 28, p. e00484, 2022. DOI: <https://doi.org/10.1016/j.geodrs.2022.e00484>.

NG, W.; MINASNY, B.; JEON, S. H.; MCBRATNEY, A. Mid-infrared spectroscopy for accurate measurement of an extensive set of soil properties for assessing soil functions. **Soil Security**, [s. l.], v. 6, p. 100043, 2022. DOI: <https://doi.org/10.1016/j.soisec.2022.100043>.

NG, W.; MINASNY, B.; MONTAZEROLGHAEM, M.; PADARIAN, J.; FERGUSON, R.; BAILEY, S.; MCBRATNEY, A. B. Convolutional neural network for simultaneous prediction of several soil properties using visible/near-infrared, mid-infrared, and their combined spectra. **Geoderma**, [s. l.], v. 352, p. 251–267, 2019. DOI: <https://doi.org/10.1016/j.geoderma.2019.06.016>.

O'ROURKE, S. M.; STOCKMANN, U.; HOLDEN, N. M.; MCBRATNEY, A. B.; MINASNY, B. An assessment of model averaging to improve predictive power of portable vis-NIR and XRF for the determination of agronomic soil properties. **Geoderma**, [s. l.], v. 279, p. 31–44, 2016. DOI: <https://doi.org/10.1016/j.geoderma.2016.05.005>.

PADARIAN, J.; MINASNY, B.; MCBRATNEY, A. B. Using deep learning to predict soil properties from regional spectral data. **Geoderma Regional**, [s. l.], v. 16, p. e00198, 2019. DOI: <https://doi.org/10.1016/j.geodrs.2018.e00198>.

PAIVA, A. F. S.; POPPIEL, R. R.; ROSIN, N. A.; GRESCHUK, L. T.; ROSAS, J. T. F.; DEMATTÊ, J. A. M. The Brazilian Program of soil analysis via spectroscopy (ProBASE): Combining spectroscopy and wet laboratories to understand new technologies. **Geoderma**, [s. l.], v. 421, p. 115905, 2022. DOI: <https://doi.org/10.1016/j.geoderma.2022.115905>.

PAL, N. R.; BEZDEK, J. C. On cluster validity for the fuzzy c-means model. **IEEE Transactions on Fuzzy Systems**, [s. l.], v. 3, p. 370–379, 1995. DOI: <https://doi.org/10.1109/91.413225>.

PESSOA, L. G. M.; FREIRE, M. B. G. dos S.; GREEN, C. H. M.; MIRANDA, M. F. A.; ARAÚJO FILHO, José C.; PESSOA, W. R. L. S. Assessment of soil salinity status under different land-use conditions in the semiarid region of Northeastern Brazil. **Ecological Indicators**, [s. l.], v. 141, p. 109139, 2022. DOI: <https://doi.org/10.1016/j.ecolind.2022.109139>.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2024. Disponível em: <https://www.r-project.org/>. Acesso em: 10 nov. 2024.

RIBEIRO, S. G. et al. Soil Organic Carbon Content Prediction Using Soil-Reflected Spectra: A Comparison of Two Regression Methods. **Remote Sensing**, Basel, v. 13, p. 4752, 2021.

DOI: <https://doi.org/10.3390/rs13234752>.

RIZZO, R. et al. Point and Imaging Spectroscopy in Geospatial Analysis of Soils. In: MITRAN, T.; MEENA, R. S.; CHAKRABORTY, A. (Ed.). **Geospatial Technologies for Crops and Soils**. Singapore: Springer, 2021. p. 277-317.

ROSSEL, R. A. V.; JEON, Y. S.; ODEH, I. O. A.; MCBRATNEY, A. B. Using a legacy soil sample to develop a mid-IR spectral library. **Australian Journal of Soil Research**, Clayton, v. 46, p. 1–16, 2008. DOI: <https://doi.org/10.1071/SR07099>.

RUAN, H. D.; FROST, R. L.; KLOPROGGE, J. T.; DUONG, L. Infrared spectroscopy of goethite dehydroxylation: III. FT-IR microscopy of in situ study of the thermal transformation of goethite to hematite. **Spectrochimica Acta - Part A Molecular and Biomolecular Spectroscopy**, [s. l.], v. 58, p. 967–981, 2002. DOI: [https://doi.org/10.1016/S1386-1425\(01\)00574-1](https://doi.org/10.1016/S1386-1425(01)00574-1).

SALAZAR, O. et al. Evaluation of a miniaturized portable NIR spectrometer for the prediction of soil properties in Mediterranean central Chile. **Geoderma Regional**, [s. l.], v. 34, p. e00675, 2023. DOI: <https://doi.org/10.1016/j.geodrs.2023.e00675>.

SANTOS, A. C.; FERREIRA, D. F. Definição do tamanho amostral usando simulação Monte Carlo para o teste de normalidade baseado em assimetria e curtose: I. Abordagem univariada. **Ciência e Agrotecnologia**, Lavras, v. 27, p. 432–437, 2003. DOI: <https://doi.org/10.1590/S1413-70542003000200025>.

SANTOS, H. G. et al. **Sistema Brasileiro de Classificação de Solos**. 6. ed. Brasília: EMBRAPA, 2025.

SANTOS, H. G. *et al.* **Sistema brasileiro de classificação de solos**. 5ª ed. Brasília: EMBRAPA, 2018.

SANTOS, U. J.; DEMATTÊ, J. A. M.; MENEZES, R. S. C.; DOTTO, A. C.; GUIMARÃES, C. C. B.; ALVES, B. J. R.; PRIMO, D. C.; SAMPAIO, E. V. S. B. Predicting carbon and nitrogen by visible near-infrared (Vis-NIR) and mid-infrared (MIR) spectroscopy in soils of Northeast Brazil. **Geoderma Regional**, [s. l.], v. 23, p. e00333, 2020. DOI: <https://doi.org/10.1016/j.geodrs.2020.e00333>.

SARAIVA, S. M.; FRAGA, V. S.; ARAÚJO FILHO, J. C.; SANTOS, R. F.; FELIX, E. S.; CARNEIRO, K. A. A. Mineralogia de Luvisolos formados sob gradiente pluviométrico no semiárido paraibano. **Brazilian Journal of Animal and Environmental Research**, Curitiba, v. 3, p. 4416-4433, 2020. DOI: <https://doi.org/10.34188/bjaerv3n4-142>.

SAVITZKY, Abraham; GOLAY, Marcel J. E. Smoothing and Differentiation of Data. **Analytical Chemistry**, [s. l.], v. 36, p. 1627, 1964. DOI: <https://doi.org/10.1021/ac60214a047>.

SHEN, Z. et al. Deep transfer learning of global spectra for local soil carbon monitoring. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 188, p. 190–200, 2022. DOI: <https://doi.org/10.1016/j.isprsjprs.2022.04.009>.

SHEPHERD, K. D.; FERGUSON, R.; HOOVER, D.; EGMOND, F. V.; SANDERMAN, J.; GE, Y. A global soil spectral calibration library and estimation service. **Soil Security**, [s. l.], v. 7, p. 100061, 2022. DOI: <https://doi.org/10.1016/j.soisec.2022.100061>.

SILVA, J. R. I.; SOUZA, R.; SOUZA, E.; BEZERRA, A. C.; SAMPAIO, E. V. S. B.; ORESCA, D.; LIMA, J. R. S.; MENEZES, R. S. C.; ANTONINO, A. C. D.; MONTENEGRO, S. M. G. L. Ecohydrological consequences of the replacement of Caatinga with pasture in the semiarid of Brazil. **Science of the Total Environment**, [s. l.], v. 1002, p. 180464, 2025. DOI: <https://doi.org/10.1016/j.scitotenv.2025.180464>.

SILVERO, N. E. Q. et al. Effects of water, organic matter, and iron forms in mid-IR spectra of soils: Assessments from laboratory to satellite-simulated data. **Geoderma**, [s. l.], v. 375, p. 114480, 2020. DOI: <https://doi.org/10.1016/j.geoderma.2020.114480>.

SORIANO-DISLA, J. M.; JANIK, L. J.; ROSSEL, R. A. V.; MACDONALD, L. M.; MCLAUGHLIN, M. J. The performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical, and biological properties. **Applied Spectroscopy Reviews**, [s. l.], v. 49, p. 139–186, 2014. DOI: <https://doi.org/10.1080/05704928.2013.811081>.

SOUSA JUNIOR, J. G. A.; DEMATTÊ, J. A. M.; GENUÍ, A. M. Comportamento espectral dos solos na paisagem a partir de dados coletados por sensores terrestre e orbital. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, p. 727-738, 2008. DOI: <https://doi.org/10.1590/S0100-06832008000200027>.

SOUZA, D. M.; MADARI, B. E.; GUIMARÃES, F. F. Aplicação de técnicas variáveis e inteligência artificial análise de espectros de infravermelho para determinação de matéria orgânica em amostras de solos. **Química Nova**, São Paulo, v. 35, p. 1738-1745, 2012. DOI: <https://doi.org/10.1590/S0100-40422012000900007>.

SOUZA, D. T. M. **Espectroscopia de reflectância aplicada a estudos pedogenéticos em ambientes semiáridos**. 2020. Tese (Doutorado em Geociências Aplicadas e Geodinâmica) - Instituto de Geociências, Universidade de Brasília, Brasília, 2020.

SOUZA, H. A.; LEITE, L. F. C.; MEDEIROS, J. C. **Solos sustentáveis para a agricultura no Nordeste**. Brasília: Embrapa, 2021.

SOUZA, J. J. L. L. et al. Organic carbon rich-soils in the brazilian semiarid region and paleoenvironmental implications. **Catena**, [s. l.], v. 212, p. 106101, 2022. DOI: <https://doi.org/10.1016/j.catena.2022.106101>.

SOUZA, S. F. F.; ARAÚJO, M. S. B.; DEMATTÊ, J. A. M.; ARAÚJO FILHO, J. C. Spectral patterns in the mid-ir of soils in the northeast of Brazil and their relation to the taxonomic classification. **Revista Brasileira de Geografia Física**, Recife, v. 13, p. 3698–3711, 2021. DOI: <https://doi.org/10.26848/rbgf.v13.07.p3698-3711>.

SUN, M.; LIU, H.; LI, P.; GONG, P.; YU, X.; YE, F.; GUO, Y.; WU, Z. Effects of salt content and particle size on spectral reflectance and model accuracy: Estimating soil salt content in arid, saline-alkali lands. **Microchemical Journal**, Netherlands, v. 207, p. 111666, 2024. DOI: <https://doi.org/10.1016/j.microc.2024.111666>.

TAGHDIS, S.; FARPOOR, M. H.; MAHMOODABADI, M. Pedological assessments along an arid and semi-arid transect using soil spectral behavior analysis. **Catena**, [s. l.], v. 214, p. 106288, 2022. DOI: <https://doi.org/10.1016/j.catena.2022.106288>.

TAVAKOLI, H.; CORREA, J.; SABETIZADE, M.; VOGEL, S. Predicting key soil properties from Vis-NIR spectra by applying dual-wavelength indices transformations and stacking machine learning approaches. **Soil and Tillage Research**, [s. l.], v. 229, p. 105684, 2023. DOI: <https://doi.org/10.1016/j.still.2023.105684>.

TAVARES, T. R.; MOLIN, J. P.; HAMED JAVADI, S.; DE CARVALHO, H. W. P.; MOUAZEN, A. M. Combined use of vis-nir and xrf sensors for tropical soil fertility analysis: Assessing different data fusion approaches. **Sensors**, Basel, v. 21, p. 1–23, 2021. DOI: <https://doi.org/10.3390/s21010148>.

TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. **Manual de métodos de análise de solo**. 3. ed. Brasília: Embrapa, 2017.

TERRA, F. S.; DEMATTÊ, J. A. M.; ROSSEL, R. A. V. Proximal spectral sensing in pedological assessments: vis–NIR spectra for soil classification based on weathering and pedogenesis. **Geoderma**, [s. l.], v. 318, p. 123–136, 2018. DOI: <https://doi.org/10.1016/j.geoderma.2017.10.053>.

TERRA, F. S.; DEMATTÊ, J. A. M.; ROSSEL, R. A. V. Spectral libraries for quantitative analyses of tropical Brazilian soils: Comparing vis–NIR and mid-IR reflectance data. **Geoderma**, [s. l.], v. 255, p. 81–93, 2015. DOI: <https://doi.org/10.1016/j.geoderma.2015.04.017>.

TERRA, F. S.; RIZZO, R.; DOR, E. B.; DEMATTÊ, J. A. M. Soil Sensing by Visible and IR Radiation. In: CIURCZAK, Emil W.; IGNE, Benoît; WORKMAN JR., Jerome; BURNS, Donald A. (eds.). **Handbook of Near-Infrared Analysis**. 4. ed. Boca Raton: CRC Press, 2021. p. 836–855.

TERRA, F. S.; ROSSEL, R. A. V.; DEMATTÊ, J. A. M. Spectral fusion by Outer Product Analysis (OPA) to improve predictions of soil organic C. **Geoderma**, [s. l.], v. 335, p. 35–46, 2019. DOI: <https://doi.org/10.1016/j.geoderma.2018.08.005>.

VASAVA, H. B.; DAS, B. S. Assessment of Soil Properties using Spectral Signatures of Bulk Soils and Their Aggregate Size Fractions. **Geoderma**, [s. l.], v. 417, p. 115837, 2022. DOI: <https://doi.org/10.1016/j.geoderma.2022.115837>.

VASCONCELOS, R. R. A. de; BARROS, M. de F. C.; SILVA, Ê. F. de F. e; GRACIANO, E. S. A.; FONTENELE, A. J. P. B.; SILVA, N. M. L. da. Características físicas de solos salino-sódicos do semiárido pernambucano em função de diferentes níveis de gesso. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 17, p. 1318–1325, 2013. DOI: [10.1590/S1415-43662013001200010](https://doi.org/10.1590/S1415-43662013001200010).

WEI, M. C. F.; CANAL FILHO, R.; TAVARES, T. R.; MOLIN, J. P.; VIEIRA, A. M. C. Dimensionality Reduction Statistical Models for Soil Attribute Prediction Based on Raw Spectral Data. **AI**, [s. l.], v. 3, p. 809–819, 30 Sep. 2022. DOI:

<https://doi.org/10.3390/ai3040049>.

WIJEWARDANE, N. K.; GE, Y.; WILLS, S.; LIBOHOVA, Z. Predicting Physical and Chemical Properties of US Soils with a Mid-Infrared Reflectance Spectral Library. **Soil Science Society of America Journal**, [s. l.], v. 82, p. 722–731, 2018. DOI: <https://doi.org/10.2136/sssaj2017.10.0361>.

XIMENES, L. F.; SILVA, M. S. L.; BRITO, L. L. (Ed.). **Tecnologias de convivência com o Semiárido brasileiro**. Série Ciência e Tecnologia. Fortaleza: Banco do Nordeste do Brasil, 2019.

YU, B.; YAN, C.; YUAN, J.; DING, N.; CHEN, Z. Prediction of soil properties based on characteristic wavelengths with optimal spectral resolution by using Vis-NIR spectroscopy. **Spectrochimica Acta - Part A: Molecular and Biomolecular Spectroscopy**, [s. l.], v. 293, p. 122452, 2023. DOI: <https://doi.org/10.1016/j.saa.2023.122452>.

ZHANG, Y.; HARTEMINK, A. E.; HUANG, J. Spectral signatures of soil horizons and soil orders – An exploratory study of 270 soil profiles. **Geoderma**, [s. l.], v. 389, p. 114961, 2021. DOI: <https://doi.org/10.1016/j.geoderma.2021.114961>.

ZHAO, D.; ARSHAD, M.; WANG, J.; TRIANTAFILIS, J. Soil exchangeable cations estimation using Vis-NIR spectroscopy in different depths: Effects of multiple calibration models and spiking. **Computers and Electronics in Agriculture**, [s. l.], v. 182, p. 105990, 2021. DOI: <https://doi.org/10.1016/j.compag.2021.105990>.

APÊNDICE A - CLASSIFICAÇÃO DOS SOLOS E IDENTIFICAÇÃO DO PONTO DO PERFIL NO LEVANTAMENTO DOS SOLOS DO ESTADO DO CEARÁ

Classe (subgrupo)	Subordem	Nº. Perfil	Cidade	Nº. Campo
NEOSSOLO FLÚVICO Psamítico típico	RY	1	Caucaia	7P-123C
NEOSSOLO QUARTZARÊNICO Órtico típico	RQ	2	Acaraú	7P-02P
PLANOSSOLO NÁTRICO Órtico típico	SN	3	Miraíma	7P-09P
LUVISSOLO HÁPLICO Pálico abrupto	TX	4	Miraíma	7P-011P
ARGISSOLO ACINZENTADO Eutrófico típico	PAC	5	Itarema	7P-016P
ARGISSOLO AMARELO Distrófico típico	PA	6	Amontada	7P-17P
NEOSSOLO FLÚVICO Sódico típico	RY	7	Amontada	7P-018P
GLEISSOLO SÁLICO Sódico típico	GZ	8	Amontada	7P-019P
ARGISSOLO AMARELO Distrocoesolódico	PA	9	Itapipoca	7P-20P
PLANOSSOLO NÁTRICO Órtico mésico	SN	10	Itapipoca	7P-023P
CAMBISSOLO HÁPLICO Tb Eutrófico típico	CX	11	Itapipoca	7P-28P
ARGISSOLO VERMELHO-AMARELO Distrófico arênico	PVA	12	Amontada	7P-34P
NEOSSOLO QUARTZARÊNICO Hidromórfico típico	RQ	13	Paracuru	7P-50P
LATOSSOLO AMARELO Distrófico psamítico	LA	14	Trairi	7P-40P
NEOSSOLO FLÚVICO Ta Eutrófico solódico	RY	15	Paraipaba	7P-46P
VERTISSOLO EBÂNICO Sódico salino	VE	16	Paraipaba	7P-49P
PLANOSSOLO NÁTRICO Órtico mésico	SN	17	Caucaia	7P-118C
ARGISSOLO VERMELHO-AMARELO Distrófico arênico	PVA	18	Cruz	7P-59P
ARGISSOLO VERMELHO Distrófico nitossólico	PV	19	Maranguape	7P-111C
CAMBISSOLO HÁPLICO Tb Distrófico saprolítico	CX	20	Massapê	7P-85P
LUVISSOLO CRÔMICO Órtico abrupto	TC	21	Massapê	7P-72P
PLANOSSOLO HÁPLICO Eutrófico típico	SX	22	Massapê	7P-74P
NEOSSOLO LITÓLICO Eutrófico típico	RL	23	Acaraú	7P-80P
PLINTOSSOLO ARGILÚVICO Eutrófico petrolítico	FT	24	Marco	7P-88P

APÊNDICE B – ESTATÍSTICA DESCRITIVA POR CLASSE DE SOLO

Parâmetros estatísticos	Areia	Silte g kg ⁻¹	Argila	K	Ca	Mg	Na	N	C	CE dS m ⁻¹	PST %	pH (H ₂ O)
ARGISSOLO												
Média	759,2	86,3	153,8	0,1	0,5	0,3	0,1	0,6	4,9	0,2	3,7	5,0
Desvio Padrão	118,5	65,9	114,3	0,1	0,4	0,3	0,1	5,1	1,0	0,2	2,7	0,6
Mínimo	528,0	4,0	13,0	0,0	0,1	0,0	0,0	0,0	0,1	0,0	0,0	4,2
Máximo	919,0	242,0	429,0	0,3	1,6	1,9	0,2	5,0	26,8	0,9	10,2	6,4
Mediana	787,0	67,0	102,0	0,1	0,5	0,2	0,1	0,4	3,3	0,2	3,5	5,0
1º Quartil	633,0	45,0	67,0	0,1	0,2	0,1	0,1	0,1	2,2	0,1	1,8	4,7
3º Quartil	865,0	100,0	197,0	0,2	0,7	0,3	0,1	0,5	5,8	0,2	5,0	5,2
CAMBISSOLO												
Média	659,7	207,6	133,2	0,1	0,9	0,5	0,1	0,9	5,9	0,1	2,1	5,1
Desvio Padrão	107,7	78,2	45,0	0,1	0,5	0,2	0,0	0,9	6,1	0,1	1,2	0,9
Mínimo	422,0	162,0	59,0	0,1	0,3	0,2	0,0	0,1	1,8	0,1	0,5	3,9
Máximo	767,0	403,0	197,0	0,2	1,7	0,9	0,1	3,3	20,4	0,3	3,8	5,9
Mediana	699,0	173,0	122,0	0,2	0,8	0,5	0,1	0,6	3,0	0,1	2,5	5,5
1º Quartil	657,0	172,0	113,0	0,1	0,7	0,4	0,0	0,5	2,2	0,1	0,9	4,1
3º Quartil	708,0	189,0	176,0	0,2	1,2	0,7	0,1	1,0	6,0	0,2	3,0	5,6
GLEISSOLO												
Média	334,6	415,4	250,2	0,1	3,2	4,6	3,2	0,1	2,1	5,1	39,1	6,6
Desvio Padrão	278,2	178,4	104,6	0,1	3,7	4,5	0,6	0,2	2,3	3,9	19,2	1,0
Mínimo	100,0	187,0	105,0	0,0	0,9	1,5	2,2	0,0	0,0	0,4	8,3	5,5
Máximo	708,0	552,0	356,0	0,3	9,7	12,2	3,7	0,5	5,6	9,2	59,1	7,6
Mediana	203,0	537,0	260,0	0,1	1,6	2,2	3,4	0,0	2,1	4,1	40,6	6,8
1º Quartil	110,0	257,0	191,0	0,0	1,3	2,1	3,3	0,0	0,0	3,0	37,3	5,6
3º Quartil	552,0	544,0	339,0	0,1	2,4	5,1	3,5	0,2	2,9	9,1	50,3	7,3
LATOSSOLO												
Média	844,8	38,8	116,8	0,1	0,2	0,1	0,0	0,5	3,7	0,2	2,2	5,5
Desvio Padrão	36,2	2,6	36,0	0,0	0,0	0,0	0,0	0,4	2,0	0,1	0,8	0,3
Mínimo	815,0	35,0	60,0	0,1	0,1	0,0	0,0	0,3	2,1	0,1	0,8	5,0
Máximo	900,0	42,0	148,0	0,2	0,2	0,1	0,0	1,3	7,0	0,4	2,8	5,7
Mediana	827,0	39,0	134,0	0,1	0,2	0,1	0,0	0,4	3,4	0,1	2,4	5,5
1º Quartil	819,0	38,0	103,0	0,1	0,2	0,1	0,0	0,3	2,3	0,1	2,4	5,5
3º Quartil	863,0	40,0	139,0	0,2	0,2	0,1	0,0	0,5	3,8	0,2	2,8	5,6

Continua...

Parâmetros estatísticos	Areia	Silte g kg ⁻¹	Argila	K	Ca	Mg	Na	N	C	CE dS m ⁻¹	PST %	pH (H ₂ O)
LUVISSOLO												
Média	517,1	275,9	207,5	0,2	11,3	8,6	0,2	1,0	6,8	0,2	1,4	5,7
Desvio Padrão	109,2	34,6	108,1	0,1	3,5	9,4	0,2	1,6	7,2	0,1	1,0	0,5
Mínimo	336,0	230,0	53,0	0,1	6,9	2,1	0,1	0,1	2,3	0,1	0,2	5,0
Máximo	717,0	319,0	430,0	0,4	16,0	26,0	0,4	4,8	24,1	0,4	2,8	6,2
Mediana	523,0	282,5	189,0	0,1	12,4	3,5	0,3	0,4	4,4	0,1	1,5	5,8
1º Quartil	486,0	244,8	170,0	0,1	8,0	2,7	0,1	0,2	3,1	0,1	0,3	5,3
3º Quartil	545,5	301,0	228,2	0,2	13,5	10,9	0,4	1,0	6,0	0,2	2,0	6,0
NEOSSOLO												
Média	824,3	114,1	61,9	0,1	1,1	0,8	0,2	0,4	2,5	0,3	5,6	6,0
Desvio Padrão	160,6	108,6	59,5	0,1	0,8	0,7	0,6	0,5	2,3	0,7	10,0	0,8
Mínimo	485,0	2,0	3,0	0,0	0,1	0,1	0,0	0,0	0,6	0,0	0,7	4,8
Máximo	995,0	367,0	225,0	0,2	3,2	3,1	3,6	2,2	10,0	4,6	54,6	7,2
Mediana	902,0	74,0	37,0	0,1	1,0	0,6	0,1	0,2	1,4	0,1	2,0	6,1
1º Quartil	692,5	20,0	18,0	0,0	0,4	0,4	0,0	0,1	1,1	0,1	1,5	5,7
3º Quartil	960,5	203,5	101,0	0,1	1,4	1,2	0,1	0,4	2,9	0,2	4,5	6,5
PLANOSSOLO												
Média	712,7	151,1	136,7	0,1	3,8	1,9	1,0	0,5	3,3	0,7	12,0	5,4
Desvio Padrão	147,4	68,0	125,7	0,1	3,8	1,9	1,0	0,5	3,3	0,7	18,95	5,4
Mínimo	467,0	57,0	4,0	0,1	0,1	0,0	0,0	0,0	0,7	0,1	0,2	4,2
Máximo	939,0	386,0	404,0	0,2	20,9	9,1	7,0	1,4	7,6	3,4	68,4	6,8
Mediana	751,0	145,0	99,0	0,1	0,9	0,9	0,2	0,5	2,6	0,2	4,1	5,1
1º Quartil	579,0	114,0	22,0	0,1	0,4	0,3	0,0	0,2	2,1	0,1	0,9	5,0
3º Quartil	822,5	167,5	252,0	0,1	3,0	1,8	1,5	0,7	4,2	0,9	13,7	5,8
PLINTOSSOLO												
Média	665,8	87,5	247,8	0,1	1,3	1,1	0,1	1,2	6,6	0,1	1,2	5,1
Desvio Padrão	136,8	19,2	128,7	0,0	0,3	0,1	0,0	1,0	6,5	0,0	0,5	0,5
Mínimo	547,0	69,0	100,0	0,1	1,1	0,9	0,0	0,4	0,7	0,0	0,6	4,6
Máximo	814,0	114,0	374,0	0,2	1,7	1,2	0,1	2,4	15,2	0,1	1,7	5,6
Mediana	651,0	83,5	258,5	0,1	1,2	1,1	0,0	1,0	5,3	0,1	1,3	5,1
1º Quartil	550,8	77,25	161,5	0,1	1,1	1,0	0,0	0,4	2,1	0,0	0,9	4,8
3º Quartil	766,0	93,75	344,8	0,1	1,3	1,2	0,1	1,7	9,8	0,1	1,6	5,4
VERTISSOLO												
Média	308,0	349,8	342,5	0,3	5,9	8,4	6,2	0,9	5,5	4,0	23,6	6,9

APÊNDICE C - RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS PREDITIVOS PARA OS ATRIBUTOS FÍSICOS COM ESPECTROS VIS-NIR-SWIR

Algoritmo	Tratamento - dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
Areia (g/kg) (DP = 161,953)							
PLSR	Bruto	0,490	148,959	0,609	99,761	1,623	2,660
	Abs	0,556	139,092	0,627	97,464	1,662	2,724
	SG	0,475	151,158	0,649	94,482	1,714	2,810
SVM - radial	Bruto	0,505	146,850	0,467	116,441	1,391	2,280
	Abs	0,519	144,642	0,478	115,240	1,405	2,304
	SG	0,503	147,032	0,468	116,411	1,391	2,281
SVM - linear	Bruto	0,602	131,548	0,567	105,015	1,542	2,528
	Abs	0,739	106,550	0,625	97,685	1,658	2,718
	SG	0,543	141,038	0,646	94,970	1,705	2,796
Cubist	Bruto	0,507	146,454	0,627	97,505	1,661	2,723
	Abs	0,647	123,967	0,776	75,471	2,146	3,518
	SG	0,634	126,290	0,676	90,765	1,784	2,925
Silte (g/kg) (DP = 127,192)							
PLSR	Bruto	0,509	82,903	0,602	79,055	1,609	1,840
	Abs	0,620	72,964	0,602	79,071	1,609	1,840
	SG	0,496	84,045	0,614	77,860	1,634	1,869
SVM - radial	Bruto	0,538	80,407	0,086	119,830	1,060	1,214
	Abs	0,262	101,636	0,166	114,453	1,110	1,270
	SG	0,256	102,091	0,176	113,759	1,118	1,279
SVM - linear	Bruto	0,667	68,246	0,442	93,633	1,358	1,554
	Abs	0,748	59,396	0,516	87,171	1,459	1,669
	SG	0,610	73,882	0,522	86,592	1,469	1,680
Cubist	Bruto	0,540	80,228	0,451	92,856	1,370	1,567
	Abs	0,473	85,948	0,309	104,139	1,221	1,397
	SG	0,496	84,053	0,353	100,799	1,262	1,443
Argila (g/kg) (DP = 112,820)							
PLSR	Bruto	0,654	67,334	0,650	65,740	1,716	2,221
	Abs	0,698	62,890	0,753	55,208	2,044	2,645
	SG	0,705	62,205	0,692	61,665	1,830	2,368
SVM - radial	Bruto	0,728	59,655	0,630	67,582	1,669	2,160
	Abs	0,710	61,669	0,628	67,771	1,665	2,154
	SG	0,759	56,254	0,621	68,433	1,649	2,133
SVM - linear	Bruto	0,739	58,432	0,759	54,608	2,065	2,674
	Abs	0,845	45,114	0,734	57,305	1,969	2,548
	SG	0,697	63,007	0,755	55,037	2,050	2,653
Cubist	Bruto	0,635	69,186	0,783	51,769	2,179	2,820
	Abs	0,728	59,703	0,831	45,657	2,471	3,198
	SG	0,755	56,687	0,731	57,686	1,956	2,531

**APÊNDICE D - RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS
PREDITIVOS PARA OS ATRIBUTOS QUÍMICOS COM ESPECTROS VIS-NIR-
SWIR**

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
Carbono orgânico (g/kg) (DP = 2,772)							
PLSR	Bruto	0,797	2,127	0,716	1,456	1,904	2,669
	Abs	0,790	2,162	0,614	1,698	1,633	2,288
	SG	0,770	2,261	0,708	1,475	1,879	2,633
SVM - radial	Bruto	0,736	2,421	0,390	2,134	1,299	1,821
	Abs	0,791	2,154	0,348	2,206	1,257	1,761
	SG	0,736	2,424	0,388	2,136	1,298	1,819
SVM - linear	Bruto	0,751	2,353	0,678	1,550	1,788	2,506
	Abs	0,813	2,037	0,529	1,874	1,479	2,073
	SG	0,716	2,512	0,674	1,559	1,779	2,493
Cubist	Bruto	1,000	0,086	0,716	1,454	1,906	2,671
	Abs	0,999	0,114	0,697	1,504	1,844	2,584
	SG	1,000	0,082	0,476	1,977	1,403	1,965
Nitrogênio (g/kg) (DP = 0,561)							
PLSR	Bruto	0,842	0,358	0,452	0,409	1,371	1,289
	Abs	0,801	0,402	0,433	0,416	1,348	1,268
	SG	0,813	0,389	0,449	0,410	1,368	1,286
SVM - radial	Bruto	0,806	0,397	0,378	0,436	1,287	1,210
	Abs	0,921	0,254	0,117	0,519	1,080	1,016
	SG	0,893	0,294	0,201	0,494	1,136	1,068
SVM - linear	Bruto	0,823	0,379	0,338	0,450	1,248	1,173
	Abs	0,873	0,322	0,328	0,453	1,238	1,164
	SG	0,736	0,463	0,367	0,440	1,276	1,200
Cubist	Bruto	0,734	0,464	0,510	0,387	1,450	1,364
	Abs	0,789	0,414	0,446	0,412	1,363	1,282
	SG	0,613	0,560	0,282	0,468	1,198	1,126
Fósforo (mg/kg) (DP = 22,603)							
PLSR	Bruto	0,897	4,343	0,733	11,497	1,966	0,635
	Abs	0,533	9,244	0,412	17,073	1,324	0,428
	SG	0,871	4,856	0,745	11,257	2,008	0,648
SVM - radial	Bruto	0,522	9,355	0,255	19,218	1,176	0,380
	Abs	0,537	9,209	0,318	18,388	1,229	0,397
	SG	0,500	9,572	0,258	19,186	1,178	0,380
SVM - linear	Bruto	0,655	7,952	0,482	16,025	1,410	0,456
	Abs	0,543	9,149	0,365	17,738	1,274	0,412
	SG	0,625	8,287	0,502	15,714	1,438	0,465

Continua...

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
Cubist	Bruto	0,529	9,281	0,240	19,412	1,164	0,376
	Abs	0,498	9,585	0,165	20,346	1,111	0,359
	SG	0,380	10,658	0,213	19,752	1,144	0,370
Potássio (cmol _e /kg) (DP = 0,078)							
PLSR	Bruto	0,385	0,057	0,247	0,067	1,170	1,180
	Abs	0,559	0,048	0,605	0,048	1,615	1,630
	SG	0,523	0,050	0,338	0,063	1,248	1,259
SVM - radial	Bruto	0,160	0,064	0,153	0,071	1,103	1,113
	Abs	0,224	0,064	0,139	0,071	1,094	1,104
	SG	0,215	0,064	0,154	0,071	1,103	1,114
SVM - linear	Bruto	0,614	0,045	0,387	0,060	1,296	1,308
	Abs	0,609	0,045	0,494	0,055	1,427	1,441
	SG	0,508	0,051	0,363	0,061	1,272	1,284
Cubist	Bruto	0,998	0,003	0,116	0,072	1,079	1,089
	Abs	0,056	0,070	0,128	0,072	1,087	1,097
	SG	0,048	0,070	0,091	0,073	1,064	1,074
Cálcio (cmol _e /kg) (DP = 5,032)							
PLSR	Bruto	0,622	2,129	0,274	4,225	1,191	0,315
	Abs	0,352	2,789	0,481	3,571	1,409	0,372
	SG	0,727	1,809	0,434	3,730	1,349	0,357
SVM - radial	Bruto	0,483	2,490	0,028	4,888	1,030	0,272
	Abs	0,614	2,152	0,032	4,877	1,032	0,273
	SG	0,666	2,002	0,046	4,811	1,039	0,275
SVM - linear	Bruto	0,775	1,645	0,268	4,242	1,186	0,314
	Abs	0,770	1,662	-0,101	5,201	0,968	0,256
	SG	0,747	1,743	0,342	4,023	1,251	0,331
Cubist	Bruto	0,636	2,090	0,217	4,387	1,147	0,303
	Abs	0,713	1,857	0,427	3,755	1,340	0,354
	SG	0,627	2,115	0,215	4,392	1,146	0,303
Magnésio (cmol _e /kg) (DP = 1,950)							
PLSR	Bruto	0,679	2,395	0,505	1,351	1,443	0,740
	Abs	0,646	2,515	0,359	1,538	1,268	0,650
	SG	0,603	2,663	0,458	1,414	1,379	0,707
SVM - radial	Bruto	0,236	3,696	0,293	1,615	1,207	0,619
	Abs	0,358	3,389	0,362	1,534	1,271	0,652
	SG	0,260	3,639	0,346	1,554	1,255	0,644
SVM - linear	Bruto	0,713	2,266	0,469	1,399	1,393	0,715
	Abs	0,775	2,005	0,028	1,894	1,029	0,528
	SG	0,720	2,237	0,481	1,384	1,409	0,723

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
Cubist	Bruto	0,897	1,359	-1,274	2,896	0,673	0,345
	Abs	0,914	1,238	-0,936	2,672	0,730	0,374
	SG	1,000	0,065	-1,264	2,890	0,675	0,346
Sódio (cmol _c /kg) (DP = 1,687)							
PLSR	Bruto	0,490	1,377	0,623	1,020	1,653	0,255
	Abs	0,493	1,373	0,521	1,150	1,467	0,227
	SG	0,431	1,455	0,608	1,040	1,621	0,250
SVM - radial	Bruto	0,312	1,599	0,186	1,499	1,125	0,174
	Abs	0,243	1,678	0,108	1,570	1,074	0,166
	SG	0,205	1,720	0,169	1,515	1,113	0,172
SVM - linear	Bruto	0,232	1,690	0,340	1,350	1,250	0,193
	Abs	0,329	1,580	0,530	1,139	1,481	0,229
	SG	0,194	1,731	0,264	1,425	1,183	0,183
Cubist	Bruto	1,000	0,037	0,510	1,163	1,450	0,224
	Abs	1,000	0,024	0,506	1,167	1,445	0,223
	SG	1,000	0,025	0,520	1,151	1,465	0,226
Alumínio trocável (cmol _c /kg) (DP = 0,665)							
PLSR	Bruto	0,136	0,757	0,313	0,543	1,224	1,492
	Abs	0,178	0,738	0,278	0,557	1,194	1,455
	SG	0,136	0,757	0,312	0,543	1,224	1,492
SVM - radial	Bruto	0,431	0,614	0,496	0,501	1,327	1,616
	Abs	0,465	0,596	0,495	0,465	1,429	1,740
	SG	0,420	0,620	0,498	0,464	1,432	1,745
SVM - linear	Bruto	0,532	0,557	-0,151	0,703	0,946	1,153
	Abs	0,550	0,546	-0,647	0,840	0,791	0,964
	SG	0,452	0,603	0,020	0,648	1,026	1,250
Cubist	Bruto	0,516	0,566	0,355	0,526	1,264	1,541
	Abs	0,559	0,541	0,273	0,558	1,191	1,451
	SG	0,397	0,632	0,329	0,537	1,239	1,510
Soma de bases (cmol _c /kg) (DP = 7,502)							
PLSR	Bruto	0,599	4,833	0,569	4,850	1,547	0,551
	Abs	0,445	5,686	0,328	6,059	1,238	0,441
	SG	0,601	4,823	0,601	4,669	1,607	0,572
SVM - radial	Bruto	0,596	4,855	0,174	6,717	1,117	0,398
	Abs	0,653	4,496	0,183	6,682	1,123	0,400
	SG	0,659	4,458	0,160	6,774	1,107	0,395
SVM - linear	Bruto	0,670	4,387	0,347	5,973	1,256	0,447
	Abs	0,750	3,819	-9,458	23,900	0,314	0,112
	SG	0,641	4,571	0,424	5,610	1,337	0,476

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
Cubist	Bruto	0,723	4,019	0,590	4,730	1,586	0,565
	Abs	0,999	0,241	0,602	4,661	1,610	0,573
	SG	0,999	0,290	0,609	4,625	1,622	0,578
Capacidade de troca catiônica (cmol _c /kg) (DP = 7,494)							
PLSR	Bruto	0,599	4,954	0,590	4,725	1,586	0,399
	Abs	0,608	4,895	0,505	5,196	1,442	0,363
	SG	0,668	4,504	0,269	6,313	1,187	0,299
SVM - radial	Bruto	0,422	5,948	0,213	6,552	1,144	0,288
	Abs	0,472	5,685	0,166	6,744	1,111	0,280
	SG	0,818	3,332	0,087	7,055	1,062	0,267
SVM - linear	Bruto	0,710	4,208	0,512	5,158	1,453	0,365
	Abs	0,799	3,506	-3,167	15,070	0,497	0,125
	SG	0,674	4,462	0,483	5,308	1,412	0,355
Cubist	Bruto	0,999	0,193	0,521	5,107	1,467	0,369
	Abs	1,000	0,171	0,552	4,944	1,516	0,381
	SG	0,998	0,320	0,446	5,493	1,364	0,343
Saturação por bases (%) (DP = 27,743)							
PLSR	Bruto	0,845	10,344	0,335	22,284	1,245	2,266
	Abs	0,833	10,730	0,331	22,363	1,241	2,258
	SG	0,817	11,252	0,357	21,919	1,266	2,304
SVM - radial	Bruto	0,724	13,788	0,414	20,919	1,326	2,414
	Abs	0,698	14,443	0,432	20,598	1,347	2,452
	SG	0,709	14,163	0,406	21,067	1,317	2,397
SVM - linear	Bruto	0,871	9,427	0,387	21,408	1,296	2,359
	Abs	0,881	9,077	0,313	22,655	1,225	2,229
	SG	0,801	11,717	0,408	21,022	1,320	2,402
Cubist	Bruto	1,000	0,439	0,623	16,786	1,653	3,009
	Abs	0,706	14,235	0,488	19,558	1,419	2,582
	SG	1,000	0,479	0,699	14,995	1,850	3,368
pH em água (DP = 0,875)							
PLSR	Bruto	0,457	0,653	0,410	0,662	1,322	1,586
	Abs	0,572	0,601	0,137	0,801	1,093	1,311
	SG	0,397	0,703	0,411	0,662	1,322	1,587
SVM - radial	Bruto	0,292	0,756	0,250	0,747	1,172	1,406
	Abs	0,259	0,766	0,276	0,733	1,193	1,432
	SG	0,255	0,792	0,256	0,744	1,177	1,412
SVM - linear	Bruto	0,532	0,625	0,125	0,806	1,085	1,302
	Abs	0,527	0,578	0,206	0,768	1,139	1,367
	SG	0,446	0,654	0,355	0,692	1,264	1,517
Cubist	Bruto	0,367	0,711	0,122	0,808	1,083	1,300

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
	Abs	0,516	0,641	0,193	0,775	1,130	1,356
	SG	0,384	0,703	0,486	0,618	1,416	1,700
Percentagem de saturação por sódio (%)(DP = 16,142)							
PLSR	Bruto	0,901	3,775	0,058	15,437	1,046	0,384
	Abs	0,705	6,498	0,084	15,221	1,060	0,389
	SG	0,869	4,326	0,067	15,358	1,051	0,386
SVM - radial	Bruto	0,475	8,673	0,211	14,126	1,143	0,419
	Abs	0,458	8,809	0,136	14,784	1,092	0,401
	SG	0,441	8,890	0,215	14,090	1,145	0,420
SVM - linear	Bruto	0,640	7,183	0,012	15,804	1,021	0,375
	Abs	0,755	5,926	0,010	15,823	1,020	0,374
	SG	0,555	7,988	0,056	15,453	1,045	0,383
Cubist	Bruto	1,000	0,166	0,504	11,203	1,441	0,529
	Abs	0,674	6,836	0,610	9,931	1,626	0,597
	SG	1,000	0,241	0,673	9,095	1,775	0,651
Condutividade elétrica (dS/m) (DP = 0,466)							
PLSR	Bruto	0,549	1,311	0,719	0,243	1,913	0,606
	Abs	0,086	1,865	0,326	0,377	1,236	0,392
	SG	0,496	1,384	0,734	0,237	1,968	0,623
SVM - radial	Bruto	0,241	1,699	0,609	0,287	1,623	0,514
	Abs	0,116	1,835	0,282	0,389	1,198	0,380
	SG	0,240	1,700	0,620	0,283	1,646	0,521
SVM - linear	Bruto	0,368	1,551	0,399	0,356	1,309	0,415
	Abs	0,413	1,495	0,560	0,304	1,531	0,485
	SG	0,337	1,588	-1,152	0,673	0,692	0,219
Cubist	Bruto	0,997	0,111	0,168	0,418	1,113	0,353
	Abs	0,998	0,083	0,160	0,421	1,107	0,351
	SG	0,998	0,093	-0,528	0,567	0,821	0,260

Conclusão

**APÊNDICE E - RESULTADO DA CALIBRAÇÃO E VALIDAÇÃO DOS MODELOS
PREDITIVOS PARA OS ATRIBUTOS FÍSICOS COM ESPECTRO MIR**

Algoritmo	Tratamento - dados espectrais	R ² calib.	RMSE calib.	R ² valid.	RMSE valid.	RPD	RPIQ
Areia (g/kg) (DP =161,953)							
PLSR	Bruto	0,928	55,922	0,838	64,181	2,523	4,137
	Abs	0,959	42,095	0,514	111,188	1,457	2,388
	SG	0,931	54,718	0,818	68,028	2,381	3,903
SVM - radial	Bruto	0,984	26,745	0,883	54,538	2,970	4,868
	Abs	0,984	26,017	0,867	58,181	2,784	4,563
	SG	0,982	28,100	0,883	54,533	2,970	4,869
SVM - linear	Bruto	0,985	25,348	0,858	60,215	2,690	4,409
	Abs	0,986	24,874	0,517	110,849	1,461	2,395
	SG	0,985	25,770	0,845	62,783	2,580	4,229
Cubist	Bruto	0,998	10,436	0,893	52,321	3,095	5,074
	Abs	0,931	54,886	0,832	65,314	2,480	4,065
	SG	0,912	61,775	0,872	57,062	2,838	4,653
Silte (g/kg) (DP = 127,192)							
PLSR	Bruto	0,987	13,612	0,830	51,656	2,462	2,817
	Abs	0,814	51,087	0,755	61,969	2,053	2,348
	SG	0,789	54,366	0,830	51,669	2,462	2,816
SVM - radial	Bruto	0,967	21,593	0,542	84,815	1,500	1,715
	Abs	0,985	14,671	0,596	79,645	1,597	1,827
	SG	0,961	23,349	0,559	83,258	1,528	1,748
SVM - linear	Bruto	0,991	11,342	0,776	59,259	2,146	2,455
	Abs	0,990	11,916	0,717	66,684	1,907	2,182
	SG	0,991	11,454	0,739	64,064	1,985	2,271
Cubist	Bruto	0,981	16,258	0,716	66,726	1,906	2,181
	Abs	1,000	1,452	0,729	65,207	1,951	2,231
	SG	0,993	9,803	0,768	60,423	2,105	2,408
Argila (g/kg) (DP =112,820)							
PLSR	Bruto	0,840	45,731	0,835	45,146	2,499	3,234
	Abs	0,901	36,011	0,815	47,750	2,363	3,058
	SG	0,961	22,515	0,855	42,364	2,663	3,446
SVM - radial	Bruto	0,938	28,534	0,864	40,958	2,755	3,565
	Abs	0,920	32,317	0,850	43,041	2,621	3,392
	SG	0,987	13,264	0,879	38,614	2,922	3,781
SVM - linear	Bruto	0,990	11,218	0,868	40,460	2,788	3,608
	Abs	0,990	11,420	0,685	62,333	1,810	2,342
	SG	0,990	11,503	0,783	51,826	2,177	2,817
Cubist	Bruto	0,998	4,599	0,856	42,244	2,671	3,456
	Abs	0,918	32,808	0,822	46,834	2,409	3,117
	SG	0,999	2,954	0,812	48,136	2,344	3,033

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE claib.	R ² valid.	RMSE valid.	RPD	RPIQ
	SG	0,573	8,843	0,040	21,821	1,036	0,335
Potássio (cmol _c /kg) (DP = 0,078)							
PLSR	Bruto	0,972	0,012	0,580	0,050	1,566	1,580
	Abs	0,576	0,047	0,644	0,046	1,700	1,716
	SG	0,882	0,025	0,604	0,048	1,624	1,639
SVM - radial	Bruto	0,822	0,030	0,434	0,058	1,349	1,361
	Abs	0,893	0,024	0,550	0,052	1,514	1,528
	SG	0,897	0,023	0,494	0,055	1,428	1,441
SVM - linear	Bruto	0,990	0,007	0,464	0,056	1,387	1,400
	Abs	0,990	0,007	0,566	0,051	1,540	1,555
	SG	0,990	0,007	0,395	0,060	1,305	1,317
Cubist	Bruto	0,999	0,002	0,495	0,055	1,428	1,441
	Abs	1,000	0,001	0,585	0,050	1,576	1,590
	SG	0,999	0,003	0,477	0,056	1,404	1,402
Cálcio (cmol _c /kg) (DP = 5,032)							
PLSR	Bruto	0,440	2,592	0,182	4,483	1,123	0,297
	Abs	0,595	2,204	0,281	4,205	1,197	0,316
	SG	0,691	1,925	0,245	4,308	1,168	0,309
SVM - radial	Bruto	0,800	1,550	0,309	4,123	1,221	0,323
	Abs	0,801	1,546	0,338	4,035	1,247	0,330
	SG	0,749	1,734	0,288	4,182	1,203	0,318
SVM - linear	Bruto	0,976	0,532	-0,341	5,740	0,877	0,232
	Abs	0,977	0,526	0,290	4,178	1,205	0,318
	SG	0,979	0,504	0,321	4,086	1,231	0,325
Cubist	Bruto	0,999	0,091	0,332	4,052	1,242	0,328
	Abs	1,000	0,022	0,327	4,066	1,238	0,327
	SG	0,999	0,091	0,295	4,162	1,209	0,320
Magnésio (cmol _c /kg) (DP = 1,950)							
PLSR	Bruto	0,963	0,812	0,530	1,317	1,480	0,759
	Abs	0,828	1,755	0,499	1,360	1,434	0,735
	SG	0,765	2,052	0,569	1,261	1,547	0,793
SVM - radial	Bruto	0,395	2,817	0,634	1,162	1,679	0,861
	Abs	0,588	2,715	0,605	1,207	1,615	0,828
	SG	0,997	0,244	0,638	1,156	1,686	0,865
SVM - linear	Bruto	0,996	0,264	0,568	1,262	1,545	0,792
	Abs	0,996	0,253	0,469	1,400	1,392	0,714
	SG	0,996	0,265	0,570	1,260	1,548	0,794
Cubist	Bruto	1,000	0,029	0,103	1,819	1,072	0,550
	Abs	1,000	0,029	0,547	1,296	1,509	0,774
	SG	1,000	0,050	0,286	1,623	1,201	0,616

Algoritmo	Tratamento – dados espectrais	R ² calib.	RMSE claib.	R ² valid.	RMSE valid.	RPD	RPIQ
PLSR	Bruto	0,856	2,966	0,543	4,989	1,502	0,378
	Abs	0,774	3,722	0,473	5,361	1,398	0,352
	SG	0,847	3,061	0,569	4,849	1,545	0,389
SVM - radial	Bruto	0,949	1,766	0,490	5,273	1,421	0,357
	Abs	0,861	2,916	0,464	5,405	1,387	0,349
	SG	0,956	1,642	0,490	5,273	1,421	0,357
SVM - linear	Bruto	0,988	0,848	0,427	5,588	1,341	0,337
	Abs	0,987	0,906	0,356	5,924	1,265	0,318
	SG	0,978	0,888	0,616	4,578	1,637	0,412
Cubist	Bruto	1,000	0,071	0,463	5,409	1,385	0,348
	Abs	1,000	0,032	0,486	5,294	1,415	0,356
	SG	1,000	0,081	0,489	5,276	1,420	0,357
Saturação por bases (%) (DP = 27,743)							
PLSR	Bruto	0,683	14,795	0,422	20,776	1,335	2,431
	Abs	0,620	16,183	0,584	17,635	1,573	2,864
	SG	0,694	14,541	0,425	20,732	1,338	2,436
SVM - radial	Bruto	0,922	7,343	0,540	18,545	1,496	2,723
	Abs	0,971	4,473	0,541	18,515	1,498	2,727
	SG	0,779	12,349	0,522	18,895	1,468	2,673
SVM - linear	Bruto	0,989	2,797	0,070	26,365	1,052	1,915
	Abs	0,989	2,768	0,046	26,702	1,039	1,891
	SG	0,989	2,765	0,290	23,025	1,205	2,193
Cubist	Bruto	0,887	8,833	0,658	15,977	1,736	3,161
	Abs	0,888	8,803	0,600	17,303	1,603	2,919
	SG	0,913	7,742	0,568	17,963	1,545	2,811
pH em água (DP = 0,875)							
PLSR	Bruto	0,777	0,431	0,510	0,603	1,451	1,741
	Abs	0,744	0,460	0,553	0,576	1,518	1,822
	SG	0,714	0,441	0,417	0,658	1,329	1,595
SVM - radial	Bruto	0,593	0,533	0,545	0,581	1,505	1,806
	Abs	0,577	0,562	0,497	0,611	1,431	1,718
	SG	0,603	0,547	0,491	0,615	1,423	1,708
SVM - linear	Bruto	0,761	0,419	0,521	0,597	1,466	1,759
	Abs	0,698	0,496	0,540	0,585	1,497	1,796
	SG	0,568	0,614	0,410	0,662	1,321	1,585
Cubist	Bruto	0,727	0,453	0,466	0,630	1,389	1,667
	Abs	0,624	0,515	0,451	0,639	1,370	1,644
	SG	0,707	0,454	0,535	0,588	1,488	1,786
Percentagem de saturação por sódio (%) (DP = 16,142)							
PLSR	Bruto	0,663	6,948	0,366	12,664	1,275	0,542
	Abs	0,961	2,378	0,319	13,122	1,230	0,458

