



**UNIVERSIDADE FEDERAL DO VALE DO SÃO FRANCISCO**  
**PÓS-GRADUAÇÃO EM AGRONOMIA – PRODUÇÃO VEGETAL**

**PATRÍCIA DE ARAUJO SOUZA**

**ESPECTROSCOPIA VIS-NIR-SWIR NO MAPEAMENTO DOS**  
**ATRIBUTOS DO SOLO E QUANTIFICAÇÃO DE NUTRIENTES**  
**FOLIARES DA MANGUEIRA NO SEMIÁRIDO BRASILEIRO**

**PETROLINA – PE**

**2022**

**PATRÍCIA DE ARAUJO SOUZA**

**ESPECTROSCOPIA VIS-NIR-SWIR NO MAPEAMENTO DOS  
ATRIBUTOS DO SOLO E QUANTIFICAÇÃO DE NUTRIENTES  
FOLIARES DA MANGUEIRA NO SEMIÁRIDO BRASILEIRO**

Dissertação apresentada ao curso de Pós-Graduação em Agronomia – Produção Vegetal da Universidade Federal do Vale do São Francisco – UNIVASF, *Campus* Ciências Agrárias, como parte dos requisitos para obtenção do título de Mestre em Agronomia – Produção Vegetal.

Orientador: Prof. Dr. Marcos Sales Rodrigues

Coorientador: Prof. Dr. Daniel dos Santos Costa

**PETROLINA – PE**

**2022**

S729e Souza, Patrícia de Araujo  
Espectroscopia Vis-NIR-SWIR no mapeamento dos atributos do solo e  
quantificação de nutrientes foliares da mangueira no semiárido brasileiro /  
Patrícia de Araujo Souza. – Petrolina-PE, 2022.  
xvi, 94 f.: il.; 29 cm.

Dissertação (Pós-Graduação em Agronomia – Produção Vegetal) -  
Universidade Federal do Vale do São Francisco, Campus Ciências Agrárias,  
Petrolina-PE, 2022.

Orientador: Prof.º Dr.º Marcos Sales Rodrigues.

Inclui referências.

1. Agricultura e tecnologias correlatas. 2. Agricultura de precisão. 3.  
Nutrição vegetal. 4. Mapeamento do solo. 5. Cultura da mangueira. I. Título.  
II. Rodrigues, Marcos Sales. III. Universidade Federal do Vale do São  
Francisco.

CDD 630

**UNIVERSIDADE FEDERAL DO VALE DO SÃO FRANCISCO**  
**PÓS-GRADUAÇÃO EM AGRONOMIA – PRODUÇÃO VEGETAL**

**FOLHA DE APROVAÇÃO**


Patrícia de Araujo Souza

**ESPECTROSCOPIA VIS-NIR-SWIR NO MAPEAMENTO DOS ATRIBUTOS DO SOLO E QUANTIFICAÇÃO DE NUTRIENTES FOLIARES DA MANGUEIRA NO SEMIÁRIDO BRASILEIRO**


Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Agronomia – Produção Vegetal, pela Universidade Federal do Vale do São Francisco.

Aprovada em: 22 de agosto de 2022.


**Banca Examinadora**

Documento assinado digitalmente  
 **MARCOS SALES RODRIGUES**  
Data: 20/09/2022 16:04:41-0300  
Verifique em <https://verificador.itl.br>


Prof. Dr. Marcos Sales Rodrigues (UNIVASF)  
(Orientador)

Documento assinado digitalmente  
 **DANIEL DOS SANTOS COSTA**  
Data: 22/09/2022 10:17:45-0300  
Verifique em <https://verificador.itl.br>

Prof. Dr. Daniel dos Santos Costa (UNIVASF)  
(Coorientador)

Documento assinado digitalmente  
 **AUGUSTO MIGUEL NASCIMENTO LIMA**  
Data: 22/09/2022 13:47:46-0300  
Verifique em <https://verificador.itl.br>

Prof. Dr. Augusto Miguel Nascimento Lima (UNIVASF)  
(Membro Interno)

Documento assinado digitalmente  
 **JOSE EDUARDO CORA**  
Data: 20/09/2022 17:25:09-0300  
Verifique em <https://verificador.itl.br>

Prof. Dr. José Eduardo Corá (UNESP)  
(Membro Externo)

## **AGRADECIMENTOS**

A Deus, por ter tornado tudo isso possível, por sempre abençoar e guiar os meus passos, por ser meu refúgio nas horas de desespero, por me fortalecer e me sustentar em todos os momentos ao longo desta jornada.

À Universidade Federal do Vale do São Francisco (UNIVASF), pela oportunidade de cursar o mestrado em Agronomia – Produção Vegetal.

À coordenação do programa de Pós-Graduação em Agronomia – Produção Vegetal, pelo cuidado e atenção com o corpo discente.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos.

À minha família, por ser meu alicerce e por estar sempre presente. Aos meus pais Sonia Maria de Araujo Souza e Adalberto Dias de Souza pelos conselhos sábios, por todo apoio, pela contribuição na minha educação, por estarem sempre ao meu lado e por me incentivarem a superar os obstáculos e alcançar os meus objetivos.

À minha irmã, Vitória de Araujo Souza, por todo companheirismo, cumplicidade e palavras encorajadoras.

Aos meus tios e primos, em especial à Nivan Souza, Rhaisa Micaelly, Beto Clebson, Erinei Dias, Tamires Andrade, Maria Helena e Ana Beatriz, por toda a amizade e por acreditarem em mim.

Ao meu orientador, prof. Dr. Marcos Sales Rodrigues, pela excelente orientação, por todos os conselhos, ensinamentos, direcionamentos e oportunidades oferecidas. Ainda por todo suporte, motivação, paciência, disponibilidade, preocupação, dedicação e por toda confiança em mim depositada, desde a graduação até o término de mais esta etapa.

Ao meu coorientador, prof. Dr. Daniel dos Santos Costa, pelo auxílio nas análises de estatística multivariada, pelas contribuições e sugestões dadas a este trabalho, pelos conhecimentos compartilhados e oportunidades oferecidas, por toda solicitude, atenção, dedicação e prontidão em ajudar.

Aos responsáveis pelas Fazendas Barreiro de Santa Fé (Sr. Moisés), Mandacaru (Srs. Reginaldo e Geraldo) e Sempre Verde (Srta. Larissa e Sr. Makoto), pela concessão das áreas para realização do experimento.

Aos revisores da dissertação, Dra. Alessandra Monteiro Salviano e Dr. Sérgio Tonetto de Freitas, por aceitarem o convite e pelas correções e sugestões pertinentes que ajudaram a enriquecer o trabalho.

Aos membros da banca examinadora, por aceitarem o convite, pelas correções e contribuições para o aprimoramento deste trabalho.

Aos professores da Pós-Graduação, por todos os conhecimentos transmitidos com qualidade, seriedade e compromisso, indispensáveis ao meu crescimento pessoal e profissional.

Ao Laboratório de Análises de Planta e Solo (LAPS) e ao Laboratório de Energia na Agricultura (LENA), por toda a estrutura necessária para as análises dos materiais coletados.

Aos amigos que tive a oportunidade de fazer durante a graduação e que se mantiveram no mestrado, em especial Ycaro Yuri, Ana Géssica, Bruna Parente e Maria Poliana, pelo companheirismo, pelas demonstrações de carinho, ajudando-me a superar os desafios no decorrer das disciplinas, por todos os momentos de descontração e por cada “vai dar certo”, mesmo à distância.

A todos que, de forma direta ou indireta, contribuíram com a realização deste trabalho e com a minha formação.

**Meus sinceros agradecimentos!**

Tudo posso Naquele que me fortalece.

(Filipenses 4:13)

## RESUMO

O conhecimento dos atributos físicos e químicos do solo, da sua variação e distribuição no espaço, assim como das informações acerca do estado nutricional da planta são importantes para um manejo agrícola adequado em sistemas produtivos. Entretanto, a morosidade e o alto custo das análises de solo e de folha pelos métodos padrão podem dificultar a rapidez na tomada de decisão e reduzir a eficiência das práticas de fertilização. Neste sentido, a espectroscopia vis-NIR-SWIR (visível - infravermelho - infravermelho de ondas curtas) surge como um método de análise alternativo com menor custo, maior rapidez e menores impactos ambientais. Portanto, objetivou-se com este trabalho utilizar a espectroscopia vis-NIR-SWIR para I) mapear os atributos físicos e químicos do solo em diferentes classes de solo e II) quantificar os nutrientes foliares em mangueiras cv. 'Tommy Atkins' cultivadas sob irrigação no semiárido brasileiro. Foram utilizadas 318 amostras de solo e 159 amostras de folhas de mangueira cv. 'Tommy Atkins' de três áreas comerciais distintas. Para essas amostras obteve-se os espectros de refletância para uma faixa espectral de 350 a 2500 nm e determinou-se pelos métodos de análises padrão os valores de pH, CE (condutividade elétrica),  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ ,  $\text{K}^+$ ,  $\text{Na}^+$ ,  $\text{Al}^{3+}$ , P, H+Al, COT (carbono orgânico total), areia e argila nas amostras de solo e os teores de N, P, K, Ca, Mg, B, Zn, Fe, Mn e Cu nas amostras de tecido foliar. Os dados espectrais foram submetidos a diferentes técnicas de pré-processamento. Foram desenvolvidos modelos de regressão multivariada PLSR (Regressão dos Mínimos Quadrados Parciais) e MLR (Regressão Linear Múltipla). Para os atributos do solo cujos modelos preditivos apresentaram  $R^2$  acima de 0,50, construíram-se os semivariogramas determinados pelos métodos de referência e por espectroscopia Vis-NIR-SWIR e, em seguida, foram confeccionados os mapas dos atributos do solo utilizando o interpolador Krigagem ordinária. Os modelos preditivos tiveram desempenho de previsão forte ( $R^2 > 0,70$ ) para areia, argila e COT do solo e para P e Ca foliar e moderado ( $0,50 < R^2 < 0,70$ ) para  $\text{Na}^+$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$  do solo e N e Zn foliar. Os mapas dos atributos do solo determinados pelo método convencional e método espectroscopia Vis-NIR-SWIR mostraram a existência de correlação espacial entre si. Portanto, a espectroscopia Vis-NIR-SWIR é uma ferramenta em potencial para avaliação e mapeamento dos atributos do solo em áreas de fruticultura na região semiárida brasileira e para a quantificação dos nutrientes foliares de mangueira cv. 'Tommy Atkins', constituindo uma alternativa para complementar as análises convencionais de solo e folha.

**Palavras-chave:** Fruticultura; Geoestatística; Macronutrientes; *Mangifera indica* L.; Micronutrientes; Sensoriamento proximal.



## ABSTRACT

The knowledge of the physical and chemical attributes of the soil, its variation and distribution in space, as well as information about the nutritional status of the plant are important for adequate agricultural management in production systems. However, the sluggishness and high cost of soil and leaf analysis by standard methods can hamper quick decision-making and reduce the efficiency of fertilization practices. In this sense, vis-NIR-SWIR spectroscopy (visible - near infrared - short-wave infrared) emerges as an alternative analysis method with lower cost, greater speed, and lower environmental impacts. Therefore, the objective of this work was to use vis-NIR-SWIR spectroscopy to I) map the physical and chemical attributes of the soil in different soil classes and II) quantify leaf nutrients in mango cv. 'Tommy Atkins' cultivated under irrigation in the Brazilian semiarid region. A total of 318 soil samples and 159 samples of cv. 'Tommy Atkins' mango leaves from three different commercial areas were used. For these samples, reflectance spectra were obtained for a spectral range from 350 to 2500 nm and determined by standard analysis methods the values of pH, EC (electrical conductivity),  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ ,  $\text{K}^+$ ,  $\text{Na}^+$ ,  $\text{Al}^{3+}$ , P, H+Al, TOC (total organic carbon), sand and clay in the soil samples and the contents of N, P, K, Ca, Mg, B, Zn, Fe, Mn and Cu in the leaf tissue samples. The spectral data were submitted to different pre-processing techniques. Multivariate regression models PLSR (Partial Least Squares Regression) and MLR (Multiple Linear Regression) were developed. For soil attributes whose predictive models showed  $R^2$  above 0.50, semivariograms determined by reference methods and by Vis-NIR-SWIR spectroscopy were constructed and then maps of soil attributes were made using the Ordinary Kriging interpolator. The predictive models had strong prediction performance ( $R^2 > 0.70$ ) for sand, clay and soil TOC and for foliar P and Ca and moderate ( $0.50 < R^2 < 0.70$ ) for  $\text{Na}^+$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$  of soil and foliar N and Zn. The maps of soil attributes determined by the conventional method and the Vis-NIR-SWIR spectroscopy method showed the existence of spatial correlation between them. Therefore, Vis-NIR-SWIR spectroscopy is a potential tool for the evaluation and mapping of soil attributes in fruit growing areas in the Brazilian semi-arid region and for the quantification of foliar nutrients of cv. 'Tommy Atkins' mango, constituting an alternative to complement the conventional soil and leaf analysis.

**Keywords:** Fruit growing; Geostatistics; Macronutrients; Micronutrients; *Mangifera indica* L; Proximal sensing.

## LISTA DE FIGURAS

### CAPÍTULO 2

- Figura 2.1.** Localização e distribuição dos pontos amostrais nas áreas cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira. 56 pontos amostrais na área Barreiro de Santa Fé, 50 pontos amostrais na área Mandacaru e 53 pontos amostrais na área Sempre Verde.....48
- Figura 2.2.** Espectros de refletância média das amostras de solo nas camadas de 0,00-0,20 e 0,20-0,40 m de profundidade em três áreas produtivas de mangueira irrigada cultivar 'Tommy Atkins' na região semiárida brasileira.....56
- Figura 2.3.** Mapas interpolados da área 1 da camada de 0,00-0,20 m de profundidade dos atributos (A)  $\text{Ca}^{2+}$  de referência; (B)  $\text{Ca}^{2+}$  Vis-NIR-SWIR; (C)  $\text{Mg}^{2+}$  de referência; (D)  $\text{Mg}^{2+}$  Vis-NIR-SWIR; (E) areia de referência; (F) areia Vis-NIR-SWIR; (G) argila de referência; (H) argila Vis-NIR-SWIR; (I) COT de referência; e (J) COT Vis-NIR-SWIR.....65
- Figura 2.4.** Mapas interpolados da área 1 da camada de 0,20-0,40 m de profundidade dos atributos (A)  $\text{Ca}^{2+}$  de referência; (B)  $\text{Ca}^{2+}$  Vis-NIR-SWIR; (C) areia de referência; (D) areia Vis-NIR-SWIR; (E) argila de referência; (F) argila Vis-NIR-SWIR; (G) COT de referência; e (H) COT Vis-NIR-SWIR.....66
- Figura 2.5.** Mapas interpolados da área 2 da camada de 0,00-0,20 m de profundidade dos atributos (A)  $\text{Na}^+$  de referência; (B)  $\text{Na}^+$  Vis-NIR-SWIR; (C)  $\text{Ca}^{2+}$  de referência; (D)  $\text{Ca}^{2+}$  Vis-NIR-SWIR; (E)  $\text{Mg}^{2+}$  de referência; (F)  $\text{Mg}^{2+}$  Vis-NIR-SWIR; (G) areia de referência; (H) areia Vis-NIR-SWIR; (I) argila de referência; (J) argila Vis-NIR-SWIR; (K) COT de referência; e (L) COT Vis-NIR-SWIR..... 67
- Figura 2.6.** Mapas interpolados da área 2 da camada de 0,20-0,40 m de profundidade dos atributos (A)  $\text{Ca}^{2+}$  de referência; (B)  $\text{Ca}^{2+}$  Vis-NIR-SWIR; (C)  $\text{Mg}^{2+}$  de referência; (D)  $\text{Mg}^{2+}$  Vis-NIR-SWIR; (E) areia de referência; (F) areia Vis-NIR-SWIR; (G) COT de referência; e (H) COT Vis-NIR-SWIR.....68
- Figura 2.7.** Mapas interpolados da área 3 da camada de 0,00-0,20 m de profundidade dos atributos (A)  $\text{Na}^+$  de referência; (B)  $\text{Na}^+$  Vis-NIR-SWIR; (C)  $\text{Ca}^{2+}$  de referência; (D)  $\text{Ca}^{2+}$  Vis-NIR-SWIR; (E)  $\text{Mg}^{2+}$  de referência; (F)  $\text{Mg}^{2+}$  Vis-NIR-SWIR; (G) areia de referência; (H) areia Vis-NIR-SWIR; (I) argila de referência; (J) argila Vis-NIR-SWIR; (K) COT de referência; e (L) COT Vis-NIR-SWIR.....69

**Figura 2.8.** Mapas interpolados da área 3 da camada de 0,20-0,40 m de profundidade dos atributos (A) Na<sup>+</sup> de referência; (B) Na<sup>+</sup> Vis-NIR-SWIR; (C) Ca<sup>2+</sup> de referência; (D) Ca<sup>2+</sup> Vis-NIR-SWIR; (E) Mg<sup>2+</sup> de referência; (F) Mg<sup>2+</sup> Vis-NIR-SWIR; (G) areia de referência; (H) areia Vis-NIR-SWIR; (I) argila de referência; (J) argila Vis-NIR-SWIR; (K) COT de referência; e (L) COT Vis-NIR-SWIR.....70

### **CAPÍTULO 3**

**Figura 3.1.** Espectros de refletância média das amostras de folhas de mangueira irrigada cultivar 'Tommy Atkins' em três áreas produtivas na região semiárida brasileira.....94

## LISTA DE TABELAS

### CAPÍTULO 2

|  |    |
|--|----|
| <b>Tabela 2.1.</b> Localização, relevo, solo, área, idade e espaçamento da cultura, irrigação e adubação das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.....   | 47 |
| <b>Tabela 2.2.</b> Análise descritiva dos atributos físico-químicos do solo na camada 0,00-0,20 m de profundidade das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.....  | 54 |
| <b>Tabela 2.3.</b> Análise descritiva dos atributos físico-químicos do solo na camada 0,20-0,40 m de profundidade das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.....  | 55 |
| <b>Tabela 2.4.</b> Assinaturas espectrais dos atributos físico-químicos do solo em áreas cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.....  | 57 |
| <b>Tabela 2.5.</b> Parâmetros dos modelos de regressão que apresentaram o melhor desempenho preditivo para os atributos físico-químicos do solo cultivado com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.....  | 59 |
| <b>Tabela 2.6.</b> Parâmetros de ajuste dos semivariogramas para os atributos do solo determinados pelos métodos convencionais e por espectroscopia Vis-NIR-SWIR nas camadas de 0,00-0,20 e 0,20-0,40 m de profundidade em três áreas distintas cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira..... | 61 |

### CAPÍTULO 3

|  |    |
|--|----|
| <b>Tabela 3.1.</b> Localização, relevo, solo, área, idade e espaçamento da cultura, irrigação e adubação das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira..... | 88 |
| <b>Tabela 3.2.</b> Teores adequados de nutrientes foliares para a cultura da mangueira na fase de floração plena.....  | 89 |

|  |    |
|--|----|
| <b>Tabela 3.3.</b> Análise descritiva dos nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas na região semiárida brasileira..... | 93 |
| <b>Tabela 3.4.</b> Assinaturas espectrais dos nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.....   | 95 |
| <b>Tabela 3.5.</b> Parâmetros dos modelos de regressão que apresentaram o melhor desempenho preditivo para os nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira..... | 97 |

## LISTA DE ABREVIATURAS E SIGLAS

|                  |   |
|------------------|---|
| AP               | Agricultura de Precisão                 |
| Vis              | Visível                                 |
| NIR              | Infravermelho                           |
| SWIR             | Infravermelho de ondas curtas           |
| MOS              | Matéria orgânica do solo                |
| MSC              | Correção multiplicativa de espalhamento |
| SNV              | Variação normal padrão                  |
| OSC              | Correção de sinal ortogonal             |
| PLSR             | Regressão mínimos quadrados parciais    |
| MLR              | Regressão linear múltipla               |
| COT              | Carbono orgânico total                  |
| N                | Nitrogênio                              |
| P                | Fósforo                                 |
| K                | Potássio                                |
| Mg               | Magnésio                                |
| Ca               | Cálcio                                  |
| Na               | Sódio                                   |
| B                | Boro                                    |
| Zn               | Zinco                                   |
| Fe               | Ferro                                   |
| Cu               | Cobre                                   |
| Mn               | Manganês                                |
| K <sup>+</sup>   | Potássio trocável                       |
| Mg <sup>2+</sup> | Magnésio trocável                       |
| Ca <sup>2+</sup> | Cálcio trocável                         |
| Na <sup>+</sup>  | Sódio trocável                          |
| CTC              | Capacidade de troca de cátions          |
| CE               | Condutividade elétrica                  |
| H+Al             | Acidez potencial                        |
| Al <sup>3+</sup> | Alumínio trocável                       |
| TFSA             | Terra Fina Seca ao Ar                   |

|                   |  |
|-------------------|--|
| CV                | Coeficiente de variação                          |
| W                 | Teste de normalidade Shapiro-Wilk                |
| ns                | Não-significativo à 5% de probabilidade          |
| FMM               | Filtro da média móvel                            |
| ANOVA             | Análise de variância                             |
| R <sup>2</sup>    | Coeficiente de determinação                      |
| RMSEC             | Raiz quadrada média do erro de calibração        |
| SEC               | Erro padrão de calibração                        |
| RMSECV            | Raiz quadrada média do erro de validação cruzada |
| SECV              | Erro padrão de validação cruzada                 |
| RMSEP             | Raiz quadrada média do erro de predição          |
| SEP               | Erro padrão da predição                          |
| r                 | Coeficiente de correlação                        |
| EPP               | Efeito pepita puro                               |
| IDE               | Índice de dependência espacial                   |
| C <sub>0</sub>    | Efeito pepita                                    |
| C <sub>0</sub> +C | Patamar  |
| A <sub>0</sub>    | Alcance  |
| ESF               | Esférico   |
| EXP               | Exponencial                                      |
| GAU               | Gaussiano  |

## SUMÁRIO

|   |    |
|---|----|
| INTRODUÇÃO GERAL.....   | 17 |
| CAPÍTULO 1.....   | 19 |
| 1. REVISÃO DE LITERATURA .....  | 19 |
| 1.1. Importância econômica da cultura da mangueira .....  | 19 |
| 1.2. Variabilidade espacial dos atributos do solo.....  | 21 |
| 1.3. Espectroscopia Vis-NIR-SWIR.....   | 24 |
| 1.4. Espectroscopia Vis-NIR-SWIR em análises de solo.....   | 27 |
| 1.5. Espectroscopia Vis-NIR-SWIR em análises de nutrientes foliares .....   | 29 |
| 2. REFERÊNCIAS BIBLIOGRÁFICAS .....   | 32 |
| CAPÍTULO 2.....   | 44 |
| ESPECTROSCOPIA VIS-NIR-SWIR NO MAPEAMENTO DE ATRIBUTOS FÍSICO-QUÍMICOS DO SOLO EM ÁREAS CULTIVADAS COM MANGUEIRA IRRIGADA NO SEMIÁRIDO BRASILEIRO ..... | 44 |
| RESUMO.....   | 44 |
| ABSTRACT .....  | 45 |
| INTRODUÇÃO.....   | 45 |
| MATERIAL E MÉTODOS .....  | 47 |
| Descrição da área de estudo e coleta de solo .....  | 47 |
| Análises de referência e estatística descritiva .....   | 49 |
| Aquisição dos dados espectrais .....  | 49 |
| Análises quimiométricas.....  | 50 |
| Análises geoestatísticas.....   | 52 |
| RESULTADOS .....  | 53 |
| Análise exploratória dos atributos do solo e do espectro .....  | 53 |
| Desempenho dos modelos quimiométricos .....   | 56 |
| Desempenho dos modelos geoestatísticos .....  | 60 |
| DISCUSSÃO .....   | 71 |
| Análise exploratória dos atributos do solo e do espectro .....  | 71 |
| Modelos quimiométricos.....   | 72 |
| Modelos geoestatísticos.....  | 74 |
| Considerações práticas do uso da espectroscopia VIS-NIR-SWIR na agricultura de precisão .....   | 75 |
| CONCLUSÕES.....   | 77 |
| REFERÊNCIAS BIBLIOGRÁFICAS.....   | 77 |
| CAPÍTULO 3.....   | 85 |



|  |     |
|--|-----|
| ESPECTROSCOPIA VIS-NIR-SWIR NA AVALIAÇÃO DO ESTADO NUTRICIONAL DE MANGUEIRA IRRIGADA NO SEMIÁRIDO BRASILEIRO ..... | 85  |
| RESUMO .....   | 85  |
| ABSTRACT .....   | 85  |
| INTRODUÇÃO.....  | 86  |
| MATERIAL E MÉTODOS .....   | 87  |
| Descrição da área de estudo e coleta de dados.....   | 87  |
| Análises de referência e estatística descritiva .....  | 88  |
| Aquisição dos dados espectrais .....   | 89  |
| Análises quimiométricas.....   | 90  |
| RESULTADOS .....   | 92  |
| Análise exploratória dos nutrientes foliares e do espectro .....   | 92  |
| Desempenho dos modelos quimiométricos .....  | 95  |
| DISCUSSÃO .....  | 98  |
| Análise exploratória dos nutrientes foliares e do espectro .....   | 98  |
| Desempenho dos modelos quimiométricos .....  | 99  |
| CONCLUSÕES.....  | 104 |
| REFERÊNCIAS BIBLIOGRÁFICAS.....  | 104 |
| CONSIDERAÇÕES FINAIS .....   | 110 |

## INTRODUÇÃO GERAL

A mangueira (*Mangifera indica* L.) é cultivada em todos os estados do Nordeste brasileiro, especialmente nos perímetros irrigados da região semiárida do Vale do São Francisco, que possui excelentes condições para o desenvolvimento da cultura, permitindo uma elevada produção e alta qualidade da fruta (LOBO et al., 2019).

Diante da importância da fruticultura, torna-se relevante a realização de um manejo adequado dos fatores que interferem no processo produtivo. Nesse contexto, um conhecimento dos atributos do solo e do *status* nutricional da planta é fundamental para a tomada de decisão quanto ao gerenciamento das práticas agrícolas (GALLI et al., 2013; QUEZADA et al., 2014; LIMA et al., 2016).

O solo não é uniforme no espaço, entretanto na agricultura convencional os campos agrícolas são considerados unidades homogêneas, de modo que o manejo se baseia em uma estimativa das condições médias (HAGHVERDI et al., 2015; JAVADI et al., 2022). Esse sistema tradicional desconsidera a variabilidade espacial dos atributos do solo podendo levar a erros no manejo, seja da adubação ou da irrigação, o que interfere diretamente na produtividade das culturas e nos custos de produção (COLAÇO e MOLIN, 2016).

Em contrapartida, o sistema de Agricultura de Precisão (AP) reconhece a variação espacial existente nas áreas sob produção agrícola, visando uma aplicação de insumos nas quantidades e locais corretos (KHANAL et al., 2017; GARCÍA-BERNÁ et al., 2020). Nesse sentido, a geoestatística surge como uma ferramenta que auxilia na previsão de valores em locais não amostrados por associação geográfica entre pontos amostrados, reduzindo a variância do erro de avaliação (ADDIS et al., 2015). No entanto, a aquisição de informações na resolução espacial exigida pela AP utilizando amostras de solo e análises laboratoriais padrão pode ser demorada e onerosa, dependendo do volume de amostras requerido para gerar mapas de qualidade e da extensão da área a ser mapeada. Além disso, as análises químicas de solo necessárias para o processo de mapeamento têm potencial de gerar resíduos tóxicos que requerem um descarte adequado (BENEDETTO et al., 2013).

O monitoramento dos nutrientes foliares também exige uma série de análises químicas de rotina que são muitas vezes demoradas e/ou requerem produtos químicos que oneram o processo (REDDY e VEERANKI, 2013). Esses entraves

podem muitas vezes impossibilitar correções nutricionais das plantas durante o ciclo produtivo (RODRIGUES et al., 2020).

Assim, a espectroscopia vis-NIR-SWIR (*visible - near infrared - short-wave infrared*) é uma ferramenta complementar em potencial para análises de várias amostras de solo e de folha com menor custo do que as técnicas tradicionais de base química. Sendo de mais rápida execução, visto que após a calibração de um modelo preditivo para um determinado atributo do solo ou nutriente foliar, é possível quantificá-lo sem uma preparação trabalhosa das amostras antes da análise e sem o uso de reagentes químicos e, portanto, sem produzir poluentes (GALVEZ-SOLA et al., 2015; PADARIAN et al., 2018; SHI et al., 2018; BA et al., 2020).

Diante do exposto, objetivou-se com este trabalho utilizar a espectroscopia vis-NIR-SWIR para I) mapear os atributos físicos e químicos do solo e II) quantificar os nutrientes foliares em mangueiras cv. 'Tommy Atkins' cultivadas sob irrigação no semiárido brasileiro.

## CAPÍTULO 1

### 1. REVISÃO DE LITERATURA

#### 1.1. Importância econômica da cultura da mangueira

A fruticultura representa uma considerável parcela da agricultura brasileira, sendo um setor entre os principais responsáveis pela geração de renda e empregos, constituindo, portanto, um importante segmento de desenvolvimento econômico (VIECCELLI et al., 2016). A fruticultura tornou-se uma das atividades agrícolas de grande relevância na economia nacional devido à sua alta rentabilidade em pequenas áreas (OLDONI et al., 2019). A posição geográfica do país, assim como sua dimensão territorial, privilegia o cultivo de frutas tropicais ao longo de todo o ano, gerando condições favoráveis à competitividade no mercado nacional e internacional (ANDRADE et al., 2017).

A mangueira (*Mangifera indica L.*), pertencente à família Anacardiaceae da ordem Sapindales, é uma planta frutífera tropical originária do sudeste da Ásia, que é cultivada em diversas regiões de clima tropical e subtropical. Nas últimas décadas, o cultivo se espalhou para além do seu centro de origem e domesticação, se disseminando por muitos países (PÉREZ et al., 2016), de modo que mais de 1000 variedades de manga estão disponíveis em todo o mundo (JAHURUL et al., 2015).

Entretanto, em se tratando de exportações, as mangas cv. 'Tommy Atkins', 'Kent' e 'Keitt' são as variedades mais requeridas no comércio internacional, principalmente quando se destinam aos mercados consumidores da União Europeia e dos Estados Unidos, que preferem mangas bem coloridas (pele e polpa) e com uma relação açúcar/acidez equilibrada (MITRA, 2016).

A manga é uma das cinco espécies de frutas mais populares do mundo, juntamente com bananas, laranjas, uvas e maçãs (WELAY et al., 2021). É uma das frutas tropicais mais importantes devido ao seu sabor e aroma agradáveis e alto valor nutricional. Sua polpa é rica em água, açúcares, fibras, minerais, vitaminas e antioxidantes (IBARRA et al., 2015).

A manga é a segunda fruta tropical mais comercializada do mundo e a quinta na produção total. Seu cultivo está espalhado por 100 países que produzem mais de 42 milhões de toneladas de frutas anualmente em aproximadamente 3,7 milhões de hectares (JAHURUL et al., 2015). Os maiores produtores mundiais são Índia (16.337.400 t), China (4.351.593 t), Tailândia (2.550.600 t), Paquistão (1.784.300 t),

México (1.632.650 t), Indonésia (1.313.540 t), Brasil (1.188.910 t), Bangladesh (1.047.850 t) e Filipinas (823.576 t) (FAO, 2018).

O Brasil é o sétimo maior produtor e o terceiro maior exportador mundial de manga, exportando 272.500 toneladas da fruta (FAO, 2021). E dentre as frutas produzidas pelo país, a manga ocupa o primeiro lugar no *ranking* brasileiro de exportações (KIST et al., 2019).

O Nordeste se destaca como a principal região produtora de manga no Brasil, ressaltando-se a produção comercial dos polos irrigados de Petrolina – PE e Juazeiro – BA, situados no Vale do Submédio São Francisco, semiárido brasileiro, onde condições climáticas propícias e o apoio de pesquisas, geraram um ambiente oportuno à investimentos em grandes projetos de irrigação, evidenciando o potencial produtivo e competitivo da região (ARAÚJO et al., 2018).

No Vale do Submédio São Francisco, fatores como alta luminosidade, baixos índices pluviométricos anuais e baixa umidade relativa do ar, beneficiam aspectos fitossanitários resultando em baixa incidência de doenças, os quais associados a disponibilidade de água de boa qualidade para irrigação permitem uma produção de frutas de alto padrão (SILVA et al., 2017). Em virtude da alta qualidade da manga, a maior parte da produção é exportada para os exigentes mercados americano e europeu (SOUZA et al., 2016).

Diante da importância da cultura da mangueira, torna-se necessário realizar um manejo adequado dos fatores que interferem no processo produtivo. Entre os inúmeros fatores que afetam a produtividade das culturas, os atributos do solo desempenham um papel fundamental, pois influenciam em muitas propriedades químicas e biológicas que afetam o crescimento das plantas (SIDOROVA et al., 2012). Um crescimento ideal das plantas é alcançado quando os solos têm a capacidade de fornecer quantidades adequadas de água e nutrientes (DAVATGAR et al., 2012; TRIPATHI et al., 2015). Portanto, o *status* do solo tem uma grande influência na qualidade e na quantidade da produção agrícola, de modo que uma deficiência ou um excesso de água e/ou nutrientes pode limitar ou impedir a produtividade e a qualidade dos frutos (MUKHERJEE e LASKAR, 2019).

## 1.2. Variabilidade espacial dos atributos do solo

Os solos são naturalmente heterogêneos (CAMBARDELLA e KARLEN, 1999; KILIC et al., 2012), mesmo em pequenas áreas, as características dos solos não são uniformes (WANG et al., 2021). A existência de variação nos atributos do solo em função do espaço, se deve à fatores intrínsecos, que interferem nos processos de formação do solo, como material de origem e topografia e também é devida a fatores extrínsecos como tipo de manejo do solo adotado e práticas de cultivo (LAEKEMARIAM et al., 2018). Assim, para uma estimativa adequada dos atributos do solo, essa variabilidade contínua deve ser considerada (SHIT et al., 2016; REZA et al., 2017).

Apesar da variabilidade espacial dos atributos do solo, as práticas agrônômicas, como a aplicação de insumos por exemplo, têm sido realizadas tradicionalmente de maneira uniforme pelos produtores nas áreas agrícolas (BEHERA et al., 2018). O manejo convencional do solo consiste na coleta de uma amostra composta, que é formada pela junção de amostras simples coletadas aleatoriamente no campo, sobre a qual se procedem as análises de solo tradicionais, determinando-se um valor representativo para cada um dos atributos de interesse (KODAIRA e SHIBUSAWA, 2013).

Essa metodologia resulta na aquisição de um valor médio dos atributos do solo, mas devido a presença de heterogeneidade, a média pode não ser um parâmetro apropriado de avaliação, uma vez que o valor médio de uma parcela não representa toda a parcela (BASSO et al., 2016). Isso pode resultar em excesso de aplicação de fertilizantes em áreas com altos níveis de nutrientes e sub-aplicação em áreas com baixos níveis de nutrientes, resultando em maior variação na produção e na qualidade dos frutos e menor rentabilidade para os agricultores (OLDONI et al., 2019; MOLIN e TAVARES, 2019), tendo em vista que o custo dos fertilizantes químicos é responsável por uma alta proporção do custo total de insumos agrícolas (BAI et al. 2019).

Um estudo da variabilidade espacial dos atributos do solo também é importante para a definição da lâmina de irrigação. Dentre os atributos do solo, a textura afeta consideravelmente a retenção e o movimento da água no solo, além de governar a água do solo prontamente disponível para as plantas (HAGHVERDI et al., 2019). Em vista disso, Quebrajo et al. (2018) observaram que um fornecimento uniforme de água em um campo agrícola com forte variabilidade da textura do solo causou diferenças significativas na umidade do solo entre uma zona mais arenosa e uma zona mais

argilosa, o que levou a uma variação no crescimento das plantas cultivadas na área com texturas distintas.

Isso ainda assume uma importância adicional para as culturas às quais é dado o estresse hídrico, como é o caso da mangueira. O manejo da mangueira nas regiões semiáridas, como no Vale do São Francisco, envolve uma redução da lâmina de irrigação antes da floração, pois o déficit hídrico atua como um indutor floral da mangueira (FARIA et al., 2016; HELALY et al., 2017). O estresse hídrico leva a um aumento nos níveis de etileno endógeno nas plantas (BANDURSKA et al., 2013) e a concentração do etileno por sua vez tem uma relação diretamente proporcional com o florescimento da mangueira (SUDHA et al., 2012; MALOBA et al., 2017; KUNDU et al., 2019). Desse modo, torna-se relevante considerar a variabilidade da textura do solo a fim de se realizar um manejo mais homogêneo. Vale ressaltar ainda que em áreas agrícolas irrigadas, é interessante que esta avaliação espacial da textura do solo ocorra antes da instalação dos sistemas de irrigação.

Geralmente amostras de solo mais próximas umas das outras têm propriedades semelhantes em comparação com amostras mais distantes. Isso indica que a variabilidade dos atributos do solo normalmente não é aleatória, mas dependente do espaço. Em virtude disso, a estatística clássica, que exige que os dados sejam independentes para ser utilizada, não é capaz analisar adequadamente essas variáveis (FU et al., 2013; TRIPATHY et al., 2015). Assim, a Geoestatística é uma ferramenta em potencial para o estudo da variabilidade dos atributos do solo, dado que, considera tanto o valor como a localização das amostras (SEYEDMOHAMMADI et al., 2016).

A principal vantagem da Geoestatística em relação aos parâmetros estatísticos tradicionais como média e coeficiente de variação, é sua capacidade de representar a continuidade espacial, o que é essencial para definir precisamente os limites entre as áreas mapeadas (MARQUES JÚNIOR et al., 2014). A Geoestatística, por meio da técnica de interpolação krigagem, permite prever o valor de uma variável de interesse do solo em locais não amostrados dentro de uma área a partir dos pontos amostrados, possibilitando a construção dos mapas dos atributos do solo (BOGUNOVIC et al., 2014; WADOUX et al., 2018).

Assim, os mapas dos atributos do solo são importantes instrumentos que auxiliam no gerenciamento de propriedades agrícolas, uma vez que um mapa é uma representação gráfica que exhibe informações sobre a distribuição espacial dos

atributos do solo (MINASNY e MCBRATNEY, 2016; BIER e SOUZA, 2017). O mapeamento dos atributos do solo propicia a adoção de sistemas de Agricultura de Precisão (AP) que consistem em tecnologias que aplicam insumos agrícolas de forma localizada (BETZEK et al., 2017), de modo que o objetivo da AP é otimizar o uso do solo, recursos hídricos e insumos químicos com base nos padrões espaciais das propriedades do solo (CASTRIGNANÒ et al., 2015).

De acordo com Alameen et al. (2019), uma aplicação de fertilizantes à taxa variável pode aumentar a eficácia do uso dos insumos para uma melhor produção agrícola e eficiência econômica e segundo Haghverdi et al. (2015), uma adoção de irrigação a taxa variável melhora o uso eficiente da água, reduz as perdas e aumenta o armazenamento da água no solo conferindo maior sustentabilidade aos sistemas agrícolas irrigados. Esse sistema de aplicação de insumos a taxa variável tem sido mais utilizado no cultivo de grãos, mas possui potencial para ser empregado em outros tipos de culturas, como nas frutíferas (COLAÇO e MOLIN, 2016).

Um mapa de qualidade, que consiga descrever bem a distribuição espacial dos atributos do solo de uma área, precisa de uma quantidade considerável de pontos amostrais (GUO et al., 2018; WANG et al., 2021). No entanto, a coleta de um grande número de amostras é irrealista, pois implica em grandes quantidades de recursos trabalhistas, materiais e financeiros (YE et al., 2017).

Em um relevante trabalho comparando a aplicação de fertilizantes pelo sistema convencional – que considera as áreas agrícolas como homogêneas – com o sistema de AP, Demattê et al. (2014) observaram que no método de AP houve uma maior produção para a cultura de cana-de-açúcar em relação ao método convencional, entretanto, os custos finais do sistema de AP foram maiores que os do método convencional, pois foi verificado que quanto maior o número de amostras, melhor a qualidade dos mapas e menor a quantidade de corretivos e fertilizantes utilizados, porém maior foi o número de análises de solo necessário.

O mapeamento dos atributos do solo a partir de análises químicas também pode gerar consideráveis impactos ambientais. Neste sentido, Demattê et al. (2019) estimam que atualmente, o Brasil utiliza técnicas de AP em aproximadamente 10% de suas terras agrícolas, o que envolve entre 100 e 200 mil análises de solo por ano, e levando em consideração que normalmente a amostragem é feita em duas profundidades (0,00-0,20 e de 0,20-0,40 m), esse número pode chegar a 400 mil análises de solo anuais. Considerando-se apenas a análise de matéria orgânica do



solo (MOS) por exemplo, os mesmos autores ainda apontam que o método tradicional de determinação faz uso de 0,196 g de dicromato ( $\text{Cr}_2\text{O}_7^{2-}$ ), 1,20 g hexahidrato de sulfato ferroso de amônio ( $\text{Fe}(\text{NH}_4)_2(\text{SO}_4)2.6\text{H}_2\text{O}$ ) e 5 ml de ácido sulfúrico ( $\text{H}_2\text{SO}_4$ ) para apenas uma amostra. Assim, tendo em vista apenas a análise de MOS, são utilizados 1,396 g de dicromato e amônio e 5 mL de ácido sulfúrico por amostra, atingindo-se um número preocupante de 559 kg e 2000 L desses compostos químicos tóxicos por ano, respectivamente.

Portanto, como o mapeamento detalhado dos atributos do solo envolve a coleta de um grande número de amostras, o que é demorado e implica em um alto custo econômico e na geração de resíduos perigosos oriundos dos reagentes utilizados nas análises químicas (CEZAR et al., 2019), o uso de sensores na agricultura surge como uma alternativa complementar mais rápida, de menor custo e mais limpa para tentar contornar essas dificuldades e viabilizar a adoção de AP.

### **1.3. Espectroscopia Vis-NIR-SWIR**

O sensoriamento baseia-se no princípio de interação entre a energia (radiação eletromagnética) e o objeto (MULLA, 2013). O sensoriamento remoto consiste na aquisição de informações sobre um objeto ou fenômeno à distância, de modo que os dados são adquiridos por sensores em plataformas aéreas como satélites, aeronaves, drones ou sondas (WEISS et al., 2020). Diferentemente, no sensoriamento proximal a obtenção dos dados se dá com o detector do sensor operando muito próximo (dentro de 2 m) ou em contato com o objeto (VISCARRA ROSSEL et al., 2011; CASTRIGNANÒ et al., 2015).

Nesse contexto, a espectroscopia é uma das principais técnicas do sensoriamento proximal, podendo ser definida como a ciência que estuda os espectros produzidos quando os materiais interagem ou emitem radiação eletromagnética. Essas informações espectrais resultantes são usadas para caracterizar quimicamente materiais e classifica-los de acordo com características de absorção diagnósticas, que resultam de processos vibracionais moleculares e eletrônicos (MEER, 2018).

Diante do exposto, a espectroscopia vis-NIR-SWIR tem sido utilizada no estudo das características de diversos materiais, tendo aplicabilidade na agricultura e em outros campos devido a sua alta eficiência, não destrutividade e baixo custo (YAO et

al., 2018). A espectroscopia vis-NIR-SWIR refere-se às faixas do espectro eletromagnético do visível (vis – *visible*: 350-700 nm), do infravermelho próximo (NIR – *near infrared*: 701-1100 nm) e do infravermelho de ondas curtas (SWIR – *short-wave infrared*: 1101-2500 nm) (VISCARRA ROSSEL e BEHRENS, 2010).

Quando a radiação eletromagnética interage com um material, parte da energia emitida é absorvida pelo objeto causando alterações nos seus constituintes. Essas modificações podem ser no nível atômico (eletrônico) ou molecular a depender da região espectral utilizada (VISCARRA ROSSEL e LARK, 2009).

As regiões espectrais do vis e do NIR, causam mudanças no nível energético dos elétrons provocando excitação eletrônica e rearranjo dos elétrons de valência, enquanto a região do SWIR, que é menos energética que as anteriores, é absorvida por determinadas ligações covalentes, como os grupos O–H, C–H, N–H e C–O, ocasionando sobreposição e combinações das vibrações moleculares fundamentais (SORIANO-DISLA et al., 2014; RECENA et al., 2019).

Da radiação eletromagnética emitida pela fonte de energia, uma parte é absorvida pelo objeto e o restante é refletida e/ou transmitida sendo então medida por detectores, de modo que a informação espectral computada é específica do material permitindo, portanto, a caracterização de propriedades importantes (GOBRECHT et al., 2015; WIGHT et al., 2016). Assim, a espectroscopia vis-NIR-SWIR tem seu princípio fundamental baseado nas diferenças das características eletrônicas e moleculares, de forma que a assinatura espectral de diferentes materiais é categorizada com base em seus espectros de refletância, transmitância ou absorvância (CORTI et al., 2018; COBLINSKI et al., 2020).

Apesar da espectroscopia vis-NIR-SWIR incorporar informações importantes acerca de um material, o espectro vis-NIR-SWIR possui uma baixa relação sinal-ruído e alta sobreposição de combinações de bandas e sobretons, o que causa uma convolução das curvas espectrais. Em virtude disso, métodos quimiométricos precisam ser aplicados após a obtenção dos espectros a fim de extrair informações sobre determinados constituintes do material avaliado (WANG et al., 2015).

A quimiometria é uma ferramenta que auxilia no aprimoramento e desenvolvimento de métodos instrumentais de origem química por meio da aplicação de técnicas estatísticas e matemáticas (BRERETON et al., 2017). A quimiometria se divide em duas partes principais, pré-processamentos e métodos de regressão.

O pré-processamento é uma etapa muito importante a ser realizada antes do desenvolvimento de modelos de calibração, uma vez que converte os dados brutos em um novo conjunto de dados com uma menor quantidade de variações indesejáveis, pois frequentemente existem muitos fatores que causam informações irrelevantes nos espectros, incluindo ruído de fundo, dispersão de luz e diferenças nas geometrias da amostra (ZAHIR et al., 2022).

De acordo com Rinnan et al. (2009), as técnicas de pré-processamento mais utilizadas em espectroscopia vis-NIR-SWIR podem ser divididas em métodos de suavização, derivadas espectrais e correção de dispersão do sinal. A suavização é aplicada ao espectro para reduzir o problema da relação sinal-ruído, as derivadas são aplicadas para remover os efeitos de deslocamento e inclinação da linha de base dos dados, enquanto a correção de sinal é aplicada para reduzir os efeitos de dispersão que ocorrem dentro das amostras.

Os métodos de suavização incluem o filtro da média móvel (WANG et al., 2015), enquanto os métodos de derivativos espectrais incluem a filtragem de Savitzky-Golay (GORRY, 1990; SAVITZKY e GOLAY, 1964) e os métodos de correção de dispersão incluem a correção multiplicativa de espalhamento (MSC) (ISAKSSON e NAES, 1988) e a variação normal padrão (SNV) (BARNES et al., 1989). Ademais, a correção de sinal ortogonal (OSC) é um pré-processamento que exclui variações ortogonais não relacionadas do conjunto de dados e que tem baixa correlação com a variável de interesse (WOLD et al., 1998).

A existência de correlação entre os dados espectrais de um material e propriedades específicas de seus constituintes (determinadas por métodos de referência, como análise química por exemplo), permite o uso de técnicas de regressão multivariada para a construção de um modelo matemático preditivo que, quando aplicado aos espectros de amostras desconhecidas, fornece uma estimativa do valor analítico de interesse (RECENA et al., 2019).

Apesar de diferentes métodos de calibração multivariada poderem ser usados, dentre as principais técnicas empregadas em espectroscopia vis-NIR-SWIR estão inclusas a regressão dos mínimos quadrados parciais (PLSR) e a regressão linear múltipla (MLR). Esses métodos permitem estimar relações lineares entre o espectro e as propriedades do material (LUCÀ et al., 2017).

O PLSR é uma técnica de redução dimensional que maximiza a covariância entre as variáveis independentes  $X$  (dados espectrais) e a variável dependente  $Y$

(variável resposta). Este método utiliza fatores, também chamados de variáveis latentes, que são calculados a partir da combinação das características mais relevantes da variável de interesse, presentes em vários comprimentos de onda (ADELINE et al., 2017), de modo que as informações mais úteis de uma variável de interesse estão contidas nos primeiros fatores, enquanto os fatores menos importantes podem incluir efeitos de fundo (KAWAMURA et al., 2017). Em outras palavras, as informações significativas existentes na assinatura espectral estão concentradas em poucas variáveis latentes, que são otimizadas para produzir a melhor correlação com as propriedades de interesse (CURCIO et al., 2013).

O MLR é um método simples e de fácil interpretação, mas para ser utilizado é necessário que o número de variáveis espectrais de entrada seja inferior ao número de amostras, e além disso, é uma técnica muito afetada pela colinearidade entre as variáveis, de forma que o coeficiente de colinearidade tem que ser baixo (NAES e MEVIK, 2001; WU et al., 2010). Tendo em vista que a espectroscopia vis-NIR-SWIR fornece uma quantidade elevada de variáveis preditoras e que estas são, em geral, fortemente colineares, o uso do MLR requer uma redução da dimensionalidade por meio de uma seleção de variáveis espectrais (VOHLAND et al., 2014; LI et al., 2019 b).

A espectroscopia vis-NIR-SWIR tem aplicações em diversas áreas, dentre elas na agricultura (IZNAGA et al., 2014; JAMSHIDI et al., 2016; COSTA et al., 2019; WANG et al., 2019; ZHANG et al., 2020). O uso desta tecnologia pode melhorar os métodos convencionais utilizados para obter recomendações agronômicas, visto que em comparação com a abordagem tradicional, os sensores fornecem medições mais rápidas e de menor custo (ROSSEL e BOUMA, 2016), permitindo ainda que vários constituintes sejam avaliados ao mesmo tempo (LI et al., 2013 a).

#### **1.4. Espectroscopia Vis-NIR-SWIR em análises de solo**

A espectroscopia vis-NIR-SWIR começou a ser utilizada na Ciência do Solo desde meados dos anos 90, a partir dos trabalhos pioneiros desenvolvidos por Bowers e Hanks (1965) e Stoner e Baumgardner (1981), que mostraram a existência de uma relação entre os atributos do solo e a refletância espectral. Os espectros vis-NIR-SWIR carregam informações sobre materiais orgânicos e inorgânicos do solo, empregando

medidas de energia de fótons na faixa de comprimento de onda de 350-2500 nm (NG et al., 2019).

Os atributos do solo interferem no comportamento das bandas espectrais, permitindo, dessa forma, a existência de padrões espectrais do solo. A matéria orgânica do solo (MOS) absorve energia ao longo do espectro vis-NIR-SWIR, principalmente devido aos seus grupos funcionais constituintes (C–O, O–H, C=O, C–H e N–H, ligações presentes em compostos orgânicos como proteínas, amido, celulose e lignina) (STEVENS et al., 2013; KNADEL et al., 2015), de modo que um aumento no conteúdo de MOS, normalmente leva a uma diminuição da intensidade de refletância em toda a faixa espectral (HONG et al., 2018).

Os componentes texturais bem como o tamanho das partículas são sensíveis a espectroscopia vis-NIR-SWIR, podendo ser detectados por esta tecnologia (PENG et al. 2020). A argila absorve grande quantidade de energia, sendo essa absorção devida principalmente a OH, H<sub>2</sub>O e CO<sub>3</sub>. Os minerais de argila podem apresentar absorção devido às ligações metal-OH e devido ao grupo OH de água residual do solo (mesmo quando seco) (LACERDA et al., 2016; SANTANA et al., 2018).

A areia, por sua vez, também tem efeitos importantes e distintos nas respostas espectrais do solo, assinaturas e comportamentos ao longo da faixa vis-NIR-SWIR (SAWUT et al., 2014). A areia absorve menos energia do que as partículas de argila, pois o quartzo, principal constituinte da areia, não exibe absorção exclusiva na faixa vis-NIR-SWIR apesar de aumentar o brilho geral (MOHAMED et al., 2018; BAHRAMI et al., 2022).

Assim, solos mais argilosos possuem espectros de refletância menos intensos e com uma forma horizontal, enquanto solos arenosos apresentam espectros de maior intensidade de refletância e com forma ascendente, pois refletem mais energia em toda a faixa vis-NIR-SWIR (DEMATTÊ e TERRA, 2014).

O carbono orgânico total do solo (COT), principal constituinte da MOS, e o teor de argila possuem resposta espectral vis-NIR-SWIR direta, ao passo que atributos do solo como pH, fósforo (P), potássio (K<sup>+</sup>), magnésio (Mg<sup>2+</sup>), cálcio (Ca<sup>2+</sup>) e sódio (Na<sup>+</sup>) têm resposta espectral indireta a partir de uma possível correlação com os atributos espectralmente ativos do solo (MUNNAF et al., 2019).

Portanto, intercorrelações entre atributos do solo como MOS e composição granulométrica, que são espectralmente ativos na faixa vis-NIR-SWIR, com atributos

como pH e P, que não apresentam características espectrais fortes, permitem uma estimativa destes últimos atributos de maneira indireta (LU et al., 2013).

Os atributos  $K^+$ ,  $Ca^{+2}$  e  $Mg^{+2}$ , por não possuírem as ligações C–H, O–H e N–H, não são medidos diretamente pela espectroscopia vis-NIR-SWIR, no entanto, geralmente apresentam padrões semelhantes aos de outros atributos aos quais estão correlacionados, especialmente teor de MOS e argila, o que sugere que possam ser avaliados a partir de dados de refletância de ambos os atributos (BILGLI et al., 2010). A MOS gera sítios de cargas negativas que podem ser ocupados por cátions como  $K^+$ ,  $Mg^{2+}$  e  $Ca^{2+}$ , de modo que as respostas espectrais desses elementos trocáveis estão correlacionadas a MOS. Esses elementos também estão associados a mineralogia do solo no que se refere a CTC (Capacidade de troca de cátions) (DEMATTÊ et al., 2017).

A espectroscopia vis-NIR-SWIR pode estimar quantitativamente atributos do solo de forma mais econômica e rápida em comparação com a análise laboratorial tradicional (ADELINE et al., 2017; QI et al., 2018), podendo ser considerada como uma técnica complementar aos métodos de análises químicas convencionais (MORELLOS et al., 2016)

### **1.5. Espectroscopia Vis-NIR-SWIR em análises de nutrientes foliares**

A fertilização é uma prática essencial para o desenvolvimento das culturas agrícolas, sobretudo para as espécies frutíferas, devido as suas características de crescimento e desenvolvimento (LI et al., 2020). A cultura da mangueira por exemplo, requer altos níveis nutricionais durante seus estágios de crescimento e maturidade, pois é uma cultura que exporta grande quantidade de nutrientes, uma vez que cada planta produz um elevado número de frutos (LIU et al., 2021). Nesse sentido, Mellado-Vázquez et al. (2012) estimam para a manga cv. 'Tommy Atkins' uma exportação total de macronutrientes de 4,28 kg (N: 1,11; P: 0,24; K: 1,88; Ca: 0,21; Mg: 0,15; S: 0,28 kg t<sup>-1</sup>) e de micronutrientes de 14,1 g (Fe: 3,52; Cu: 1,02; Mn: 3,22; Zn: 2,06; B: 1,66 g t<sup>-1</sup>) por tonelada de fruta fresca.

Nessa perspectiva, a fertilização é o principal método para fornecer os nutrientes necessários para as plantas (KUMARI et al., 2020), visando repor os elementos removidos pelas culturas (SILBER et al., 2021). Sarker e Rahim (2012) afirmam que dentre os fatores que influenciam a produção agrícola, os fertilizantes estão entre os mais importantes.

Para um manejo adequado da adubação, além do conhecimento do estado da fertilidade do solo, a informação sobre o *status* nutricional da planta é um pré-requisito básico para se alcançar uma alta produtividade (LI et al., 2015). Assim, o uso da espectroscopia vis-NIR-SWIR pode beneficiar o processo produtivo por ser um método rápido e econômico que permite a obtenção de informações acerca de componentes foliares (ZHANG et al., 2013), em detrimento dos métodos de análise padrão utilizados para determinação de nutrientes foliares, por serem morosos, de alto custo e com potencial para produzir resíduos químicos (ROTBART et al., 2013).

As características espectrais foliares são determinadas pela composição química e física da folha. Cada região do espectro vis-NIR-SWIR contém informações de diferentes propriedades foliares. A região do visível do espectro eletromagnético está associada aos pigmentos fotossintetizantes, principalmente à absorção de energia pelas clorofilas e carotenoides (SIEDLISKA et al., 2021).

A região do NIR está relacionada à estrutura celular da folha. A reflexão foliar ocorre pela dispersão da luz devido as descontinuidades celulares, de modo que a disposição das células determina o número de interfaces de ar/água/parede e, portanto, determinam o número de pontos de dispersão nas folhas (NEUWIRTHOVÁ et al., 2021). Dessa maneira, a região do NIR dá indicativos sobre a espessura da camada de cutícula, densidade estomatal e compactação dos parênquimas paliçádico e esponjoso do mesofilo (LI e HE, 2008). Os comprimentos de onda na região do SWIR por sua vez, estão associados principalmente à absorção de luz por grupos funcionais relacionados a proteínas, celulose, amido e açúcares foliares (KNOX et al., 2012).

Os nutrientes minerais não podem ser detectados diretamente por espectroscopia vis-NIR-SWIR. Entretanto, esses elementos geralmente participam de ligações covalentes de compostos orgânicos foliares que absorvem a energia vis-NIR-SWIR, o que permite sua quantificação de forma indireta (PRANANTO et al., 2021).

Nas folhas vegetais por exemplo, o N existe em várias formas, incluindo proteínas, aminoácidos livres e dentro de moléculas de clorofila. As proteínas e aminoácidos livres contêm ligações N–H que absorvem na região do SWIR, enquanto as clorofilas absorvem no visível. O mesmo vale para o Mg que faz parte da estrutura do anel das moléculas de clorofila, o P que constitui os fosfolipídeos e o Fe que está associado com citocromo envolvido na transferência eletrônica da fotossíntese. Essas relações permitem o estabelecimento de correlações entre os espectros vis-NIR-SWIR e os nutrientes foliares (PANDEY et al., 2017).

A análise foliar complementa a análise de solo e neste sentido, Lima de Deus et al. (2018) observaram para a cultura da bananeira que o uso conjunto da análise foliar, análise de solo e produtividade esperada permitiu recomendações de adubação mais adequadas em relação ao uso apenas da análise do solo.

Na atualidade, a análise mineral vegetal é normalmente usada para confirmar ou refutar a suspeita de problemas relacionados à deficiência, toxidez, desbalanço nutricional e para fazer ajustes no programa de adubação de nutrientes. A análise foliar auxilia na tomada de decisão de adubar ou não, contudo, ainda não é uma ferramenta utilizada com frequência em muitos pomares comerciais, mas à medida que os custos diminuïrem, o uso da análise mineral vegetal de rotina na produção das culturas tende a aumentar (MAARSCHALKERWEERD e HUSTED, 2015).



## 2. REFERÊNCIAS BIBLIOGRÁFICAS

- ADDIS, H. K.; KLIK, A.; STROHMEIER, S. Spatial variability of selected soil attributes under agricultural land use system in a Mountainous Watershed, Ethiopia. **International Journal of Geosciences**, v. 6, p. 605-613, 2015.
- ADELIN, K. R. M.; GOMEZ, C.; GORRETTA, N.; ROGER, J. M. Predictive ability of soil properties to spectral degradation from laboratory Vis-NIR spectroscopy data. **Geoderma**, v. 288, p. 143-153, 2017.
- ALAMEEN, A. A.; AL-GAADIA, K. A.; ELKAMIL TOLA, E. Development and performance evaluation of a control system for variable rate granular fertilizer application. **Computers and Electronics in Agriculture**, v. 160, p. 31-39, 2019.
- ANDRADE, J. E. E. S.; COSTA, P. G.; LEITE, A. A. M. Análise da estratégia de operações na produção de manga para exportação. **Revista em Agronegócio e Meio Ambiente**, v. 10, n. e, p. 115-136, 2017.
- ARAÚJO, W. B. C.; CAMPOS, R. T.; CAMPOS, K. C. Análise da cadeia produtiva da manga em Petrolina. **Revista de Política Agrícola**, n. 4, p. 122-133, 2018.
- BA, Y.; LIU, J.; HAN, J.; ZHANG, X. Application of Vis-NIR spectroscopy for determination the content of organic matter in saline-alkali soils. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 229, p. 1-5, 2020.
- BAHRAMI, A.; DANESH, M.; BAHRAMI, M. Studying sand component of soil texture using the spectroscopic method. **Infrared Physics and Technology**, v. 122, p. 1-15, 2022.
- BAI, X. G.; WANG, Y. N.; HUO, X. X.; SALIM, R.; BLOCH, H.; ZHANG, H. Assessing fertilizer use efficiency and its determinants for apple production in China. **Ecological Indicators**, v. 104, p. 268-278, 2019.
- BANDURSKA, H.; NIEDZIELA, J.; CHADZINIKOLAU, T. Separate and combined responses to water deficit and UV-B radiation. **Plant Science**, v. 213, p. 98-105, 2013.
- BARNES, R. J.; DHANOA, M. S.; LISTER, S. J. Standard normal variate transformation and detrending of near-infrared diffuse reflectance spectra, **Applied Spectroscopy**, v. 43, n. 5, p. 772-777, 1989.
- BASSO, B.; DUMONT, B.; CAMMARANO, D.; PEZZUOLO, A.; MARINELLO, F.; SARTORI, L. Environmental and economic benefits of variable rate nitrogen fertilization in a nitrate vulnerable zone. **Science of the Total Environment**, v. 545-546, p. 227-235, 2016.
- BEHERA, S. K.; MATHUR, R. K.; SHUKLA, A. K.; SURESH, K.; PRAKASH. C. Spatial variability of soil properties and delineation of soil management zones of oil palm plantations grown in a hot and humid tropical region of southern India. **Catena**, v. 165, p. 251-259, 2018.

BENEDETTO, D. D.; CASTRIGNANO, A.; DIACONO, M.; RINALDI, M.; RUGGIERI, S.; TAMBORRINO, R. Field partition by proximal and remote sensing data fusion. **Biosystems Engineering**, v. 114, p. 372-383, 2013.

BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; SOBJAK, R.; BIER, V. A.; MERCANTE, E. Interpolation methods for thematic maps of soybean yield and soil chemical attributes. **Semina: Ciências Agrárias**, v. 38, n. 2, p. 1059-1070, 2017.

BIER, V. A.; SOUZA, E. G. Interpolation selection index for delineation of thematic maps. **Computers and Electronics in Agriculture**, v. 136, p. 202-209, 2017.

BOGUNOVIC, I.; MESIC, M.; ZGORELEC, Z.; JURISIC, A.; BILANDZIJA, D. Spatial variation of soil nutrients on sandy-loam soil. **Soil & Tillage Research**, v. 144, p. 174-183, 2014.

BRERETON, R. G.; JANSEN, J.; LOPES, J.; MARINI, F.; POMERANTSEV, A.; RODIONOVA, O.; ROGER, J. M.; WALCZAK, B.; TAULER, R. Chemometrics in analytical chemistry—part I: history, experimental design and data analysis tools. **Analytical and Bioanalytical Chemistry**, v. 409, n. 25, p. 5891-5899, 2017.

BOWERS, S. A.; HANKS, R. J. Reflection of radiant energy from soils. **Soil Science**, v. 100, n. 2, p. 130-138, 1965.

CAMBARDELLA, C. A.; KARLEN, D. L. Spatial analysis of soil fertility parameters. **Precision Agriculture**, v. 1, n. 1, p. 5-14, 1999.

CASTRIGNANÒ, A.; LANDRUM, C.; DE BENEDETTO, D. Delineation of management zones in precision agriculture by integration of proximal sensing with multivariate Geostatistics. Examples of sensor data fusion. **Agriculturae Conspectus Scientificus**, v. 80, n. 1, p. 39-45, 2015.

CEZAR, E.; NANNI, M. F.; GUERRERO, C.; SILVA JUNIOR, C. A.; CRUCIOL, L. G. T.; CHICATIA, M. L.; SILVA, G. F. C. Organic matter and sand estimates by spectroradiometry: Strategies for the development of models with applicability at a local scale. **Geoderma**, v. 340, p. 224-233, 2019.

COBLINSKI, J. A.; GIASSON, E.; 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**, v. 189, p. 1-12, 2020.

COLAÇO, A. F.; MOLIN, J. P. Variable rate fertilization in citrus: a long term study. **Precision Agriculture**, v. 18, n. 2, p. 169-191, 2016.

CORTI, M.; CAVALLI, D.; CABASSI, G.; GALLINA, P. M.; BECHINI, L. Does remote and proximal optical sensing successfully estimate maize variables? A review. **European Journal of Agronomy**, v. 99, p. 37-50, 2018.

COSTA, D. S.; MESA, N. F. O.; FREIRE, M. S.; RAMOS, R. P.; MEDEROS, B. J. T. Development of predictive models for quality and maturation stage attributes of wine grapes using vis-nir reflectance spectroscopy. **Postharvest Biology and Technology**, v. 150, p. 166-178, 2019.

CURCIO, D.; CIRAULO, G.; D'ASARO, F.; MINACAPILLI, M. Prediction of soil texture distributions using VNIR-SWIR reflectance spectroscopy. **Procedia Environmental Sciences**, v. 19, p. 494-503, 2013.

DAVATGAR, N.; NEISHABOURI, M. R.; SEPASKHAH, A. R. Delineation of site specific nutrient management zones for a paddy cultivated área based on soil fertility using fuzzy clustering. **Geoderma**, v. 173-174, p. 111-118, 2012.

DEMATTE, J. A. M.; TERRA, F. S. Spectral pedology: A new perspective on evaluation of soils along pedogenetic alterations. **Geoderma**, v. 217-218 p. 190-200, 2014.

DEMATTE, J. A. M.; DEMATTE, J. L. L.; ALVES, E. R.; NEGRÃO, R.; MORELLI, J. L. Precision agriculture for sugarcane management: a strategy applied for brazilian conditions. **Acta Scientiarum Agronomy**, v. 36, n. 1, p. 111-117, 2014.

DEMATTE, J. A. M.; DOTTO, A. C.; BEDIN, L. C.; SAYÃO, V. M.; SOUZA, A. B. Soil analytical quality control by traditional and spectroscopy techniques: Constructing the future of a hybrid laboratory for low environmental impact. **Geoderma**, v. 337, p. 111-121 2019.

FAO – FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **Statistics**, Rome, Italy, 2018. Disponível em <http://faostat.fao.org/>. Acesso em 22 nov. 2021.

FAO – FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **Major tropical fruits - Preliminary market results**, 2019. Rome, 2020. 24p.

FARIA, L. N.; SOARES, A. A.; DONATO, S. L. R.; SANTOS, M. R.; CASTRO, L. G. The effects of irrigation management on floral induction of 'Tommy Atkins' mango in Bahia semiarid. **Engenharia Agrícola**, v. 36, n. 3, p. 387-398, 2016.

FU, W.; ZHAO, K.; TUNNEY, H.; ZHANG, C. Using GIS and geostatistics to optimize soil phosphorus and magnesium sampling in temperate grassland. **Soil Science**, v. 178, n. 5, p. 240-247, 2013.

GALLI, J. A.; PALHARINI, M. C. A.; FISCHER, I. H.; MICHELOTTO, M. D.; MARTINS, A. L. M. Produção e qualidade de frutos de diferentes cultivares de mangueira adubadas com boro. **Revista Brasileira de Ciências Agrárias**, v. 8, n. 3, p. 358-363, 2013.

GALVEZ-SOLA, L.; GARCÍA-SÁNCHEZ, F.; PÉREZ-PÉREZ, J. G.; GIMENO, V.; NAVARRO, J. M.; MORAL, R.; MARTÍNEZ-NICOLÁS, J. J.; NIEVES, M. Rapid estimation of nutritional elements on citrus leaves by near infrared reflectance spectroscopy. **Frontiers in Plant Science**, v. 6, p. 1-8, 2015.

GARCÍA-BERNÁ, J. A.; OUHBI, S.; BENMOUNA, B.; GARCÍA-MATEOS, G.; FERNÁNDEZ-ALEMÁN, J. L.; MOLINA-MARTÍNEZ, J. M. Systematic mapping study on remote sensing in agriculture. **Applied Sciences**, v. 10, n. 10, 2020.

GOBRECHT, A.; BENDOULA, R.; ROGER, J. M.; BELLON-MAUREL, V. Combining linear polarization spectroscopy and the Representative Layer Theory to measure the

Beer–Lambert law absorbance of highly scattering materials. **Analytica Chimica Acta**, v. 853, p. 486-494, 2015.

GORRY, P. A. General least-square smoothing and differentiation by the convolution (Savitzky-Golay) method. **Analytical Chemistry**, v. 62, n. 6, p. 570-573, 1990.

GUO, L.; LINDERMAN, M.; SHI, T.; CHEN, Y.; DUAN, L.; ZHANG, H. Exploring the sensitivity of sampling density in digital mapping of soil organic carbon and its application in soil sampling. **Remote Sensing**, v. 10, n. 6, p. 1-27, 2018.

HAGHVERDI, A.; LEIB, B. G.; WASHINGTON-ALLEN, R. A.; AYERS, P. D.; BUSCHERMOHLE, M. J. Perspectives on delineating management zones for variable rate irrigation. **Computers and Electronics in Agriculture**, v. 117, p. 154-167, 2015.

HAGHVERDI, A.; LEIB, B.; WASHINGTON-ALLEN, R.; WRIGHT, W. C.; GHODSI, S.; GRANT, T.; ZHENG, M.; VANCHIASONG, P. Studying crop yield response to supplemental irrigation and the spatial heterogeneity of soil physical attributes in a humid region. **Agriculture**, v. 9, n. 43, p. 1-21, 2019.

HELALY, M. N.; EL-HOSEINY, H.; EL-SHEERY, N. I.; RASTOGI, A.; KALAJI, H. M. Regulation and physiological role of silicon in alleviating drought stress of mango. **Plant Physiology and Biochemistry**, v. 118, p. 31-44, 2017.

HONG, Y.; YU, L.; CHEN, Y.; LIU, Y.; LIU, Y.; LIU, Y.; CHENG, H. Prediction of soil organic matter by vis–NIR spectroscopy using normalized soil moisture index as a proxy of soil moisture. **Remote Sensing**, v. 10, n. 28, p. 1-17, 2018.

IBARRA, I.; RAMOS, P.; HERNÁNDEZ, C.; JACOBO, D. Effects of postharvest ripening on the nutraceutical and physicochemical properties of mango (*Mangifera indica* L. cv Keitt). **Postharvest Biology and Technology**, v. 103, n. 0, p. 45-54, 2015.

ISAKSSON, T.; NAES, T. The effect of multiplicative scatter correction (MSC) and linearity improvement in NIR spectroscopy. **Applied Spectroscopy**, v. 42, n. 7, p. 1273-1284, 1998.

IZNAGA, A. C.; OROZCO, M. R.; ALCANTARA, E. A.; PAIROL, M. C.; SICILIA, Y. E. D.; BAERDEMAEKER, J.; SAEYS, W. Vis/NIR spectroscopic measurement of selected soil fertility parameters of Cuban agricultural Cambisols. **Biosystems Engineering**, v. 125, 2014, p. 105-121, 2014.

JAHURUL, M. H. A.; Z Aidul, I. S. M.; GHAFoor, K.; AL-JUHAIMI, F. Y.; NYAM, K.; NORULAINI, N. A. N.; SAHENA, F.; OMAR, A. K. M. Mango (*Mangifera indica* L.) by-products and their valuable components: A review. **Food Chemistry**, v. 183, p. 173-180, 2015.

JAMSHIDI, B.; MOHAJERANI, E.; JAMSHIDI, J. Developing a Vis/NIR spectroscopic system for fast and non-destructive pesticide residue monitoring in agricultural product. **Measurement**, v. 89, p. 1-6, 2016.

JAVADI, S. H.; GUERRERO, A.; MOUAZEN, A. M. Clustering and smoothing pipeline for management zone delineation using proximal and remote sensing. **Sensors**, v. 22, n. 2, p. 1-20, 2022.

KAWAMURA, K.; TSUJIMOTO, Y.; RABENARIVO, M.; ASAI, H.; ANDRIAMANANJARA, A.; RAKOTOSON, T. Vis-NIR Spectroscopy and PLS Regression with Waveband Selection for Estimating the Total C and N of Paddy Soils in Madagascar. **Remote Sensing**, v. 9, n. 10, p. 1-13, 2017.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p. 22-32, 2017.

KILIC, K.; KILIC, S.; KOCYIGIT, R. Assessment of spatial variability of soil properties in areas under different land use. **Bulgarian Journal of Agricultural Science**, v. 18, n. 5, p. 722-732, 2012.

KIST, B. B.; SANTOS, C. E.; CARVALHO, C.; BELING, R. R. Anuário brasileiro da fruticultura 2018. Santa Cruz do Sul: **Gazeta Santa Cruz**, 2019. 96 p.

KNADEL, M.; THOMSEN, A.; SCHELDE, K.; GREVE, M. H. Soil organic carbon and particle sizes mapping using vis-NIR, EC and temperature mobile sensor platform. **Computers and Electronics in Agriculture**, v. 114, p. 134-144, 2015.

KNOX, N. M.; SKIDMORE, A. K.; PRINS, H. H. T.; HEITKÖNIG, I. M. A.; SLOTOW, R.; WAAL, C.; BOER, W. F. Remote sensing of forage nutrients: Combining ecological and spectral absorption feature data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 72, p. 27-35, 2012.

KODAIRA, M.; SHIBUSAWA, S. Using a mobile real-time soil visible-near infrared sensor for high resolution soil property mapping. **Geoderma**, v. 199, p. 64-79, 2013.

KUMARI, R.; KUNDU, M.; DAS, A.; RAKSHIT, R.; SAHAY, S.; SENGUPTA, S.; AHMAD, M. F. Long-term integrated nutrient management improves carbon stock and fruit yield in a subtropical mango (*Mangifera indica* L.) orchard. **Journal of Soil Science and Plant Nutrition**, v. 20, n. 1, p. 725-737, 2020.

KUNDU, S.; MISHRA, J.; NANDI, P.; SEKHAR, R. S.; ADHIKARY, T. Induction of flowering in mango cv. Himsagar. **Journal of Crop and Weed**, v. 15, n. 1, p. 29-34, 2019.

LACERDA, M. P. C.; DEMATTÊ, J. A. M.; SATO, M. V.; FONGARO, C. T.; GALLO, B. C.; SOUZA, A. B. Tropical texture determination by proximal sensing using a regional spectral library and its relationship with soil classification. **Remote Sensing**, v. 8, n. 701, p. 1-20, 2016.

LAEKEMARIAM, F.; KIBRET, K.; MAMO, T.; SHIFERAW, H. Accounting spatial variability of soil properties and mapping fertilizer types using geostatistics in Southern Ethiopia. **Communications in Soil Science and Plant Analysis**, v. 49, n. 1, p. 124-137, 2018.

LI, X.; HE, Y. Discriminating varieties of tea plant based on Vis/NIR spectral characteristics and using artificial neural networks. **Biosystems Engineering**, v. 99, p. 313-321, 2008.

LI, J.; HUANG, W.; ZHAO, C.; ZHANG, B. A comparative study for the quantitative determination of soluble solids content, pH and firmness of pears by Vis/NIR spectroscopy. **Journal of Food Engineering**, v. 116, p. 324-332, 2013 a.

LI, X.; ZENG, R.; LIAO, H. Improving crop nutrient efficiency through root architecture modifications. **Journal of Integrative Plant Biology**, v. 58, n. 3, p. 193-202, 2015.

LI, J.; ZHANG, H.; ZHAN, B.; WANG, Z.; JIANG, Y. Determination of SSC in pears by establishing the multi-cultivar models based on visible-NIR spectroscopy. **Infrared Physics and Technology**, v. 102, p. 1-10, 2019 b.

LI, W.; YANG, M.; WANG, J.; WANG, Z.; FAN, Z.; KANG, F.; WANG, Y.; LUO, Y.; KUANG, D.; CHEN, Z.; GUO, C.; LI, Y.; HE, X.; CHEN, X.; SHI, X.; ZHANG, Y. Agronomic responses of major fruit crops to fertilization in China: A meta-analysis. **Agronomy**, v. 10, n. 1, p. 1-18, 2020.

LIMA, J. S. S.; ALVES, D. I.; COELHO, R. I.; STURIAÑO, W. P.; SILVA, S. A. Spatial variability in the diagnosis of nutritional status in the papaya. **Revista Ciência Agronômica**, v. 47, n. 2, p. 264-274, 2016.

LIMA DE DEUS, J. A.; NEVES, J. C. L.; SOARES, I.; ALVAREZ V., V. H.; ALBUQUERQUE, F. M. R.; SANTOS, L. L.; NATALE, W. Modeling in the adjustment of fertilization recommendation through leaf analysis in fertigated 'Prata' banana. **Revista Brasileira de Ciência do Solo**, v. 42, p. 1-19, 2018.

LOBO, J. T.; SOUSA, K. S. M.; PAIVA NETO, V. B.; PEREIRA, R. N.; SILVA, L. S.; CAVALCANTE, I. H. L. Biostimulants on fruit yield and quality of mango cv. Kent grown in semiarid. **Journal of the American Pomological Society**, n. 73, v. 3, p. 152-160, 2019.

LIU, X.; PENG, Y.; YANG, Q.; WANG, X.; CUI, N. Determining optimal deficit irrigation and fertilization to increase mango yield, quality, and WUE in a dry hot environment based on TOPSIS. **Agricultural Water Management**, v. 245, p. 1-13, 2021.

LUCÀ, L.; CONFORTI, M.; CASTRIGNANÒ, A.; MATTEUCCI, G.; BUTTAFUOCO, G. Effect of calibration set size on prediction at local scale of soil carbon by Vis-NIR spectroscopy. **Geoderma**, v. 288, p. 175-183, 2017.

MAARSCHALKERWEERD, M.; HUSTED, S. Recent developments in fast spectroscopy for plant mineral analysis. **Frontiers in Plant Science**, v. 6, n. 169, p. 1-14, 2015.

MALOBA, S.; AMBUKO, J.; HUTCHINSON, M.; OWINO, W. Off-season flower induction in mango fruits using ethephon and potassium nitrate. **Journal of Agricultural Science**, v. 9, n. 9; p. 158-167, 2017.

MARQUES JÚNIOR, J.; SIQUEIRA, D. S.; CAMARGO, L. A.; TEIXEIRA, D. D. B.; BARRÓN, V.; TORRENT, J. Magnetic susceptibility and diffuse reflectance spectroscopy to characterize the spatial variability of soil properties in a Brazilian Haplustalf. **Geoderma**, v. 219-220, p. 63-71, 2014.

MEER, F. Near-infrared laboratory spectroscopy of mineral chemistry: A review. **International Journal of Applied Earth Observation**, v. 65, p. 71-78, 2018.

MELLADO-VÁZQUEZ, A.; SALAZAR-GARCÍA, S.; FUENTE, C. A. T.; GONZÁLEZ-DURÁN, I. J. L.; JIMÉNEZ, L. A. Fruit nutrient composition and removal by 'Haden' and 'Tommy Atkins' mangos fruits under forced production. **Revista Mexicana de Ciencias Agrícolas**, v. 3, n. 5, p. 925-941, 2012.

MINASNY, B.; MCBRATNEY, A. B. Digital soil mapping: A brief history and some lessons. **Geoderma**, v. 264, p. 301-311, 2016.

MITRA, S. K. Mango production in the world – present situation and future prospect. **Acta Horticulturae**, v. 1111, p. 287-296, 2016.

MOHAMED, E. S.; SALEH, A. M.; BELAL, A. B.; GAD, A. Application of near-infrared reflectance for quantitative assessment of soil properties. **Journal Remote Sensing Spatial Sciences**, v. 21, p. 1-14, 2018.

MOLIN, J. P.; TAVARES, T. R.; Sensor systems for mapping soil fertility attributes: challenges, advances, and perspectives in Brazilian tropical soils. **Engenharia Agrícola**, v.39, p.126-147, 2019.

MORELLOS, A.; PANTAZI, X.; MOSHOU, D.; ALEXANDRIDIS, T.; WHETTON, R.; TZIOTZIOS, G.; WIEBENSOHN, J.; BILL, R.; M. MOUAZEN, A. M. Machine learning based prediction of soil total nitrogen, organic carbon and moisture content by using VIS-NIR spectroscopy. **Biosystems Engineering**, v. 152, p. 104-116, 2016.

MUKHERJEE, S.; LASKAR, S. Vis–NIR-based optical sensor system for estimation of primary nutrients in soil. **Journal of Optics**, v. 48, n. 1, p. 87-103, 2019.

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, p. 358-371, 2013.

MUNNAF, M. A.; NAWAR, S.; MOUAZEN, A. M. Estimation of secondary soil properties by fusion of laboratory and on-line measured vis–NIR spectra. **Remote Sensing**, v. 11, n. 23, p. 1-21, 2019.

NAES, T.; MEVIK, B. H. Understanding the collinearity problem in regression and discriminant analysis. **Journal of Chemometrics**, v. 15, n. 4, p. 413-426, 2001.

NEUWIRTHOVÁ, E.; LHOTÁKOVÁ, Z.; LUKEŠ, P.; ALBRECHTOVÁ, J. Leaf surface reflectance does not affect biophysical traits modelling from vis-NIR spectra in plants with sparsely distributed trichomes. **Remote Sensing**, v. 13, n. 20, p. 2-21, 2021.

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**, v. 352, p. 251-267, 2019.

OLDONI, H.; TERRA, V. S. S.; TIMM, L. C.; REISSER JÚNIOR, C.; MONTEIRO, A. B. Delineation of management zones in a peach orchard using multivariate and geostatistical analyses. **Soil & Tillage Research**, v. 191, p. 1-10, 2019.

PADARIAN, J.; MINASNY, B.; MCBRATNEY, A. B. Using deep learning to predict soil properties from regional spectral data. **Geoderma Regional**, v. 15, p. 1-9, 2018.

PANDEY, P.; GE, Y.; STOERGER, V.; SCHNABLE, J. C. High Throughput In vivo Analysis of Plant Leaf Chemical Properties Using Hyperspectral Imaging. **Frontiers in Plant Science**, v. 8, p. 1-12, 2017.

PENG, L.; CHENG, H.; WANG, L.; ZHU, D. Comparisons of the prediction results of soil properties based on *fuzzy c-means* clustering and expert knowledge from laboratory Visible – Near-Infrared reflectance spectroscopy data. **Canadian Journal of Soil Science**, v. 101, p. 33-44, 2020.

PÉREZ, V.; HERRERO, M.; HORMAZAA, J. I. Self-fertility and preferential cross-fertilization in mango (*Mangifera indica*). **Scientia Horticulturae**, v. 213, p. 373-378, 2016.

PRANANTO, J. A.; MINASNY, B.; WEAVER, T. Rapid and cost-effective nutrient content analysis of cotton leaves using near-infrared spectroscopy (NIRS). **PeerJ**, v. 9, p. 1-25, 2021.

QI, H.; PAZ-KAGAN, T.; KARNIELI, A.; JIN, X.; LI, S. Evaluating calibration methods for predicting soil available nutrients using hyperspectral VNIR data. **Soil & Tillage Research**, v. 175, p. 267-275, 2018.

QUEBRAJO, L.; PEREZ-RUIZ, M.; PÉREZ-URRESTARAZU, L.; MARTÍEZ, G.; EGEEA, G. Linking thermal imaging and soil remote sensing to enhance irrigation management of sugar beet. **Biosystems Engineering**, v. 165, p. 77-87, 2018.

QUEZADA, C.; SORIANO, M. A.; DÍAZ, J.; MERINO, R.; CHANDÍA, A.; CAMPOS, J.; MARCO SANDOVAL, M. Influence of soil physical properties on grapevine yield and maturity components in an Ultic Palexeralf soils, Central-Southern, Chile. **Open Journal of Soil Science**, v. 4, p. 127-135, 2014.

RECENA, R.; FERNÁNDEZ-CABANÁS, V. M.; DELGADO, A. Soil fertility assessment by Vis-NIR spectroscopy: Predicting soil functioning rather than availability indices. **Geoderma**, v. 337, p. 368-374, 2019.

REDDY, D. D.; VEERANKI, K. Simple and inexpensive water extraction method for assaying potassium concentration in tobacco plant tissue. **Communications in Soil Science and Plant Analysis**, v. 44, n. 5, p. 962-970, 2013.

REZA, S. K.; NAYAK, D. C.; MUKHOPADHYAY, S.; CHATTOPADHYAY, T.; SINGH, S. K. Characterizing spatial variability of soil properties in alluvial soils of India using geostatistics and geographical information system. **Archives of Agronomy and Soil Science**, v. 63, n. 11, p. 1489-1498, 2017.



RINNAN, A.; BERG, F. V. D.; ENGELSEN, S. B. Review of the most common pre-processing techniques for near-infrared spectra. **Trends in Analytical Chemistry**, v. 28, n. 10, p. 1201-1222, 2009.

RODRIGUES, M.; NANNI, M. R.; CEZAR, E.; SANTOS, G. L. A. A.; REIS, A. S.; OLIVEIRA, K. M.; OLIVEIRA, R. B. Vis–NIR spectroscopy: from leaf dry mass production estimate to the prediction of macro- and micronutrients in soybean crops. **Journal of Applied Remote Sensing**, v. 14, n. 4, p. 1-20, 2020.

ROSSEL, R. A. V.; BOUMA, J. Soil sensing: A new paradigm for agriculture. **Agricultural Systems**, v. 148, p. 71-74, 2016.

ROTBART, N.; SCHMILOVITCH, Z.; COHEN, Y.; ALCHANATIS, V.; EREL, R.; IGNAT, T.; SHENDEREY, C.; DAG, A.; YERMIYAHU, U.; Estimating olive leaf nitrogen concentration using visible and near-infrared spectral reflectance. **Biosystems Engineering**, v. 114, p. 426-434, 2013.

SANTANA, F. B.; SOUZA, A. M.; POPPI, R. J. Visible and near infrared spectroscopy coupled to random forest to quantify some soil quality parameters. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 191, p. 454-462, 2018.

SARKER, B. C.; RAHIM, M. A. Effects of doses and splits of fertilizer application on harvesting time, yield and quality of mango cv. Amrapali. **Bangladesh Journal Agricultural Research**, v. 37, n. 2, p. 279-293, 2012.

SAVITZKY, A.; GOLAY, M. J. E.; Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SAWUT, M.; GHULAM, A.; TIYIP, T.; ZHANG, Y.; DING, J.; ZHANG, F.; MAIMAITIYIMING, M. Estimating soil sand content using thermal infrared spectra in arid lands. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, p. 203-210, 2014.

SEYEDMOHAMMADI, J.; ESMAEELNEJAD, L.; SHABANPOUR, M. Spatial variation modeling of groundwater electrical conductivity using geostatistics and GIS. **Modeling Earth Systems and Environment**, v. 2: n. 4, p. 1-10, 2016.

SHI, T.; GUO, L.; CHEN, Y.; WANG, W.; SHI, Z.; LI, Q.; WU, G. Proximal and remote sensing techniques for mapping of soil contamination with heavy metals. **Applied Spectroscopy Reviews**, v. 53, n. 10, p. 783-805, 2018.

SHIT, P. K.; BHUNIA, G. S.; MAITI, R. Spatial analysis of soil properties using GIS based geostatistics models. **Modeling Earth Systems and Environment**, n. 2, v. 2, p. 1-6, 2016.

SIDOROVA, V. A.; ZHUKOVSKII, E. E.; LEKOMTSEV, P. V.; YAKUSHEV, V. V. Geostatistical analysis of the soil and crop parameters in a field experiment on precision agriculture. **Eurasian Soil Science**, v. 45, n. 8, p. 783-792, 2012.

SIEDLISKA, A.; BARANOWSKI, P.; PASTUSZKA-WOŹNIAK, J.; ZUBIK, M.; KRZYSZCZAK, J. Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance. **BMC Plant Biology**, v. 21, n. 28, 2021.

SILBER, A.; GOLDBERG, T.; SHAPIRA, O.; HOCHBERG, U. Nitrogen uptake and macronutrients distribution in mango trees (cv. Keitt) under three N fertigation treatments. **BioRxiv**, v. 1, n. 1, p. 1-20, 2021.

SILVA, J. S.; FERREIRA, M. O.; LIMA, R. F. Eficiência técnica dos produtores de manga do Vale do São Francisco. **Revista de Economia e Agronegócio**, v. 15, n. 1, p. 27-49, 2017.

SORIANO-DISLA, J. M.; JANIK, L. J.; ROSSEL, R. 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**, v. 49, p. 139-186, 2014.

SOUZA, S. F.; SILVA, J. L. M.; GUEDES, J. P. M.; LIMA, J. R. F. Competitividade e parcela de mercado das exportações brasileiras de manga: uma análise do modelo Constant Market Share. **Revista Econômica do Nordeste**, v. 47, n. 1, p. 39-48, 2016.

STEVENS, A.; NOCITA, M.; TÓTH, G.; MONTANARELLA, L.; WESEMAEL, B. Prediction of soil organic carbon at the european scale by visible and near infrared reflectance spectroscopy. **PLoS ONE**, v. 8, n. 6, p. 1-13, 2013.

STONER, E. R.; BAUMGARDNER, M. F. Characteristic variations in reflectance of surface soils, **Soil Science Society of America Journal**, v. 45, p. 1161-1165, 1981.

SUDHA, R.; BALAMOCHAN, T. N.; SOORIANATHASUNDARAM, K. Effect of foliar spray of nitrogenous chemicals on flowering, fruit set and yield in mango (*Mangifera indica* L.) cv. Alphonso. **Journal of Horticultural Science and Biotechnology**, v. 7, n. 2, p. 190-193, 2012.

TRIPATHI, R.; NAYAK, A. K.; SHAHID, M.; LAL, B.; GAUTAM, P.; RAJA, R.; MOHANTY, S.; KUMAR, A.; PANDA, B. B.; SAHOO, R. N. Delineation of soil management zones for a rice cultivated area in eastern India using fuzzy clustering. **Catena**, n. 133, p. 128-136, 2015.

VIECCELLI, J. C.; SIQUEIRA, D. L.; BISPO, W. M. S.; LEMOS, L. M. C. Caracterização de folhas e frutos da manga (*Mangifera indica* L.) cv. Imbu. **Revista Brasileira de Fruticultura**, v. 38, n. 3, p. 1-7, 2016.

VISCARRA ROSSEL, R. A.; LARK, R. M. Improved analysis and modelling of soil diffuse reflectance spectra using wavelets. **European Journal of Soil Science**, v. 60, p. 453-464, 2009.

VISCARRA ROSSEL, R. A.; BEHRENS, T. Using data mining to model and interpret soil diffuse reflectance spectra. **Geoderma**, v. 158, p. 46-54, 2010.

VISCARRA ROSSEL, R. A.; ADAMCHUK, V. I.; SUDDUTH, K. A., MCKENZIE, N. J., LOBSEY, C. Proximal soil sensing: An effective approach for soil measurements in space and time. In: SPARKS, D. L. **Advances in Agronomy**. 113. ed. Newark: Academic Press, 2011. p. 243-291.

VOHLAND, M.; LUDWIG, M.; THIELE-BRUHN, S.; LUDWIG, B. Determination of soil properties with visible to near- and mid-infrared spectroscopy: Effects of spectral variable selection. **Geoderma**, v. 223–225, p. 88-96, 2014.

WADOUX, A. M. J. C.; BRUS, D. J.; HEUVELINK, G. B. M. Accounting for non-stationary variance in geostatistical mapping of soil properties. **Geoderma**, v. 324, p. 138-147, 2018.

WANG, H.; PENG, J.; XIE, C.; BAO, Y.; HE, Y. Fruit quality evaluation using spectroscopy technology: A review. **Sensors**, v. 15, n. 5, p. 11889-11927, 2015.

WANG, C.; LI, X.; WANG, L.; YANG, C.; CHEN, X.; LI, M.; MA, S. Prediction of N, P, and K contents in sugarcane leaves by VIS-NIR spectroscopy and modeling of NPK interaction effects. **Transactions of the ASABE**, v. 62, n. 6, p. 1427-1433, 2019.

WANG, W.; CAI, L.; PENG, P.; GONG, Y.; YANG, X. Soil sampling spacing based on precision agriculture variable rate fertilization of pomegranate orchard. **Communications in Soil Science and Plant Analysis**, v. 52, n. 20, p. 2445-2461, 2021.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, p. 1-19, 2020.

WELAY, P.; GEBREYESUS, B. T.; MULUGETA, B.; JOHAN, M. Effectiveness of water-saving techniques on growth performance of Mango (*Mangifera indica* L.) seedlings in Mihitsab-Azmati Watershed, Rama Area, Northern Ethiopia. **Agricultural Water Management**, v. 243, n. 1, p. 1-10, 2021.

WIGHT, J. P.; ASHWORTH, A. J.; ALLEN, F. L. Organic substrate, clay type, texture, and water influence on NIR carbon measurements. **Geoderma**, v. 261, p. 36-43, 2016.

WOLD, S.; RUHE, A.; WOLD, H. The collinearity problem in linear regression. The partial least square (PLS) approach to generalized inverses. **SIAM Journal on Scientific Computing**, v. 5, n. 3, p. 735-743, 1984.

WU, D.; HE, Y.; NIE, P.; CAO, F.; BAO, Y. Hybrid variable selection in visible and near-infrared spectral analysis for non-invasive quality determination of grape juice. **Analytica Chimica Acta**, v. 659, p. 229-237, 2010.

YAO, X.; YANG, W.; LI, M.; ZHOU, P.; CHEN, Y.; HAO, Z.; LIU, Z. Prediction of total nitrogen in soil based on random frog leaping wavelet neural network. **IFAC PapersOnLine**, v. 51, n. 17, p. 660-665, 2018.

YE, H.; HUANG, W.; HUANG, S.; HUANG, Y.; ZHANG, S.; DONG, Y.; PENGFEI CHEN, P. Effects of different sampling densities on geographically weighted regression kriging for predicting soil organic carbon. **Spatial Statistics**, v. 20, p. 76-91, 2017.

ZAHIR, S. A. D. M.; OMAR, A. F.; JAMLOS, M. F.; AZMI, M. A. M.; MUNCAN, J. A review of visible and near-infrared (Vis-NIR) spectroscopy application in plant stress detection. **Sensors and Actuators: A. Physical**, v. 338, p. 1-15, 2022.

ZHANG, X.; LIU, F.; HE, Y.; GONG, X. Detecting macronutrients content and distribution in oilseed rape leaves based on hyperspectral imaging. **Biosystems Engineering**, v. 115, p. 56-65, 2013.

ZHANG, T.; FAN, S.; XIANG, Y.; ZHANG, S.; WANG, J.; SUN, Q. Non-destructive analysis of germination percentage, germination energy and simple vigour index on wheat seeds during storage by Vis/NIR and SWIR hyperspectral imaging. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 239, p.1-11, 2020.

## CAPÍTULO 2

### ESPECTROSCOPIA VIS-NIR-SWIR NO MAPEAMENTO DE ATRIBUTOS FÍSICO-QUÍMICOS DO SOLO EM ÁREAS CULTIVADAS COM MANGUEIRA IRRIGADA NO SEMIÁRIDO BRASILEIRO<sup>1</sup>

#### RESUMO

Para a adoção de um manejo específico local do solo em áreas agrícolas, torna-se necessário a obtenção dos resultados de muitas análises de solo, o que é demorado e de alto custo. Neste sentido a espectroscopia Vis-NIR-SWIR (visível - infravermelho - infravermelho de ondas curtas) surge como uma alternativa para determinar os atributos do solo de forma rápida, com menor custo e poucos impactos ambientais. Assim, o objetivo do presente trabalho foi mapear os atributos físicos e químicos do solo em áreas cultivadas com mangueira irrigada em diferentes classes de solo no semiárido brasileiro com uso da espectroscopia Vis-NIR-SWIR. Foram utilizadas 318 amostras de solo provenientes de três áreas distintas cultivadas com mangueira cv. 'Tommy Atkins'. Para essas amostras obteve-se os espectros de refletância para uma faixa espectral de 350 a 2500 nm e determinou-se os valores de pH, CE (condutividade elétrica),  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ ,  $\text{K}^+$ ,  $\text{Na}^+$ ,  $\text{Al}^{3+}$ , P, H+Al, COT (carbono orgânico total), areia e argila pelos métodos analíticos padrão. Os dados espectrais foram inicialmente submetidos a técnicas de pré-processamento de suavização, derivação e correção. Em seguida, foram desenvolvidos modelos de Regressão dos Mínimos Quadrados Parciais (PLSR), utilizando o espectro completo (350-2500 nm) e regiões espectrais específicas no Vis (350-700 nm), NIR (701-1100 nm) e SWIR (1101-2500 nm). Também foram desenvolvidos modelos de Regressão Linear Múltipla (MLR) a partir de uma seleção de variáveis espectrais. Para todos os modelos calibrados realizou-se a validação cruzada e para os modelos com melhor desempenho, realizou-se uma validação externa. Para os modelos preditivos que tiveram  $R^2$  acima de 0,50 na validação externa, construiu-se os semivariogramas dos atributos do solo determinados pelos métodos de referência e por espectroscopia Vis-NIR-SWIR, e em seguida, confeccionou-se os mapas dos atributos do solo utilizando o interpolador Krigagem ordinária. A construção dos modelos de regressão PLSR e MLR forneceu previsões fortes para areia, argila e COT ( $R^2 > 0,85$ ), moderadas para  $\text{Na}^+$ ,  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  ( $0,65 < R^2 < 0,70$ ), fracas para pH, CE,  $\text{K}^+$  e  $\text{Al}^{3+}$  ( $0,30 < R^2 < 0,50$ ) e muito fracas para H+Al e P ( $R^2 < 0,30$ ). Os mapas dos atributos do solo determinados pelo método convencional e método espectroscopia Vis-NIR-SWIR mostraram a existência de correlação espacial entre si. Portanto, a espectroscopia de refletância Vis-NIR-SWIR é uma ferramenta em potencial para avaliação do solo e mapeamento de áreas de fruticultura constituindo uma alternativa para complementar as análises de solo convencionais.

**Palavras-chave:** Fruticultura; Geoestatística; *Mangifera indica* L.; Sensoriamento proximal.

---

<sup>1</sup> Artigo a ser submetido para publicação.

## VIS-NIR-SWIR SPECTROSCOPY IN MAPPING OF SOIL PHYSICAL-CHEMICAL ATTRIBUTES IN AREAS CULTIVATED WITH IRRIGATED MANGO IN THE BRAZILIAN SEMI-ARID REGION

### ABSTRACT

For the adoption of a specific local soil management in agricultural areas, it is necessary to obtain the results of many soil analyses, which is time-consuming and costly. In this context, Vis-NIR-SWIR spectroscopy (visible - near infrared - short-wave infrared) emerges as an alternative to determine soil attributes quickly, with lower cost and few environmental impacts. Thus, the objective of this study was to map the physical-chemical attributes of the soil in areas cultivated with irrigated mango in different soil classes in the Brazilian semi-arid region using Vis-NIR-SWIR spectroscopy. In total, 318 soil samples from three different areas cultivated with mango cv. 'Tommy Atkins' were used. For these samples, the reflectance spectra were obtained for a spectral range from 350 to 2500 nm and the values of pH, EC (electrical conductivity),  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ ,  $\text{K}^+$ ,  $\text{Na}^+$ ,  $\text{Al}^{3+}$ , P, H+Al, TOC (total organic carbon), sand and clay were determined by standard analytical methods. Spectral data were initially subjected to smoothing, derivation and correction preprocessing techniques. Then, Partial Least Square Regression (PLSR) models were developed using the complete spectrum (350-2500 nm) and specific spectral regions in Vis (350-700 nm), NIR (701-1100 nm) and SWIR (1101-2500 nm). Multiple Linear Regression (MLR) models were developed from a selection of spectral variables. Cross-validation was performed for all calibrated models, and external validation was performed for the models with better performance. For the predictive models that had  $R^2$  above 0.5 in the external validation, the semivariograms of the soil attributes determined by the reference methods and by Vis-NIR-SWIR spectroscopy were constructed, and then the maps of the soil attributes were created using the ordinary Kriging interpolator. The construction of the PLSR and MLR regression models provided strong predictions for sand, clay and TOC ( $R^2 > 0.85$ ), moderate predictions for  $\text{Na}^+$ ,  $\text{Ca}^{2+}$  and  $\text{Mg}^{2+}$  ( $0.65 < R^2 < 0.70$ ), weak predictions for pH, CE,  $\text{K}^+$  and  $\text{Al}^{3+}$  ( $0.30 < R^2 < 0.50$ ) and very weak for H+Al and P ( $R^2 < 0.30$ ). The maps of soil attributes determined by the conventional method and Vis-NIR-SWIR spectroscopy method showed the existence of spatial correlation with each other. Therefore, the Vis-NIR-SWIR reflectance spectroscopy is a potential tool for evaluation of soil and mapping of fruit growing areas, constituting an alternative to complement conventional soil analyses.

**Keywords:** Fruit growing. Geostatistics. *Mangifera indica* L. Proximal sensing.

### INTRODUÇÃO

O Brasil é o sétimo maior produtor de manga do mundo (FAO, 2020). Nesse contexto, a região do Vale do Submédio São Francisco no semiárido brasileiro, é a maior produtora nacional, sendo responsável por 87% das exportações anuais da fruta no país (KIST et al., 2021).

Um manejo adequado da adubação e da irrigação é essencial para alcançar alta produtividade e qualidade dos frutos de manga (FARIA et al., 2016 a; FARIA et al., 2016 b), sendo necessário para isso ter conhecimento acerca dos atributos físico-químicos do solo. Contudo, a região do Vale do Submédio São Francisco é caracterizada pela alta variabilidade espacial dos atributos físico-químicos do solo, mesmo em áreas pequenas (menores que 10 ha) (RODRIGUES et al., 2015; RODRIGUES et al., 2018; SILVA et al., 2020). Isso dificulta o mapeamento dos atributos físico-químicos do solo, pois é necessário maior densidade amostral, acarretando maior custo e tempo de análise (LU et al., 2013; SILVA et al., 2020), além da geração de resíduos (CEZAR et al., 2019; LIMA et al., 2019) que podem prejudicar o meio ambiente.

Assim, o sensoriamento proximal do solo, com uso da espectroscopia Vis-NIR-SWIR (Visible - near infrared - short-wave infrared), surge como uma alternativa para diminuir a quantidade de análises laboratoriais e aumentar a densidade amostral, melhorando o desempenho do mapeamento e reduzindo custos (RODRIGUES et al., 2019), proporcionando a delimitação de zonas de manejo (SOUZA et al., 2021). O comportamento espectral é influenciado pelos constituintes do solo, possibilitando a correlação entre os espectros e os atributos físicos e químicos dos solos, permitindo a predição dos seus atributos (DEMATTÊ et al., 2017).

Estudos têm demonstrado resultados promissores com o uso da espectroscopia Vis-NIR-SWIR para a predição de alguns atributos físico-químicos do solo, como carbono orgânico (KODAIRA e SHIBUSAWA, 2013; NOCITA et al., 2013; KNADEL et al., 2015; LU et al., 2013), condutividade elétrica (KODAIRA e SHIBUSAWA, 2013), textura do solo (KNADEL et al., 2015), pH e P (KODAIRA e SHIBUSAWA, 2013; LU et al., 2013), N, P, K (MUKHERJEE e LASKAR, 2019), Ca e Mg (VAŠÁT et al., 2014). Entretanto, são inexistentes estudos em solos do semiárido brasileiro cultivados com frutíferas irrigadas, diferenciando dos demais locais de produção agrícola do Brasil devido as características das classes de solos, as condições edafoclimáticas, assim como das práticas de manejo (irrigação) das frutíferas cultivadas nesta região.

A hipótese deste estudo é que os atributos físico-químicos do solo apresentam correlação com os espectros do sensor Vis-NIR-SWIR, permitindo o mapeamento de solos em áreas de produção de mangueiras com menor custo, e, portanto, viabilizando o manejo específico por meio de técnicas de agricultura de precisão.

Portanto, o objetivo desse trabalho foi mapear os atributos físico-químicos do solo em áreas cultivadas com mangueira irrigada cv. 'Tommy Atkins' em diferentes classes de solo no semiárido brasileiro com uso da espectroscopia Vis-NIR-SWIR.

## MATERIAL E MÉTODOS

### Descrição da área de estudo e coleta de solo

As amostras de solo foram provenientes de três áreas comerciais cultivadas com mangueira irrigada cv. 'Tommy Atkins', localizadas nos municípios de Petrolina-PE e Juazeiro-BA, na região do Vale do Submédio São Francisco, semiárido brasileiro (Tabela 2.1). O clima da região, segundo classificação de Köppen e Geiger, é do tipo BSh – semiárido quente (ALVARES et al., 2013). A temperatura média é 32,7 °C com máxima de 36,7 °C e mínima 18,4 °C, a umidade relativa média é de 56,7%, a precipitação média anual é de 373,3 mm distribuídos em quatro a cinco meses durante o ano (INMPE, 2019).

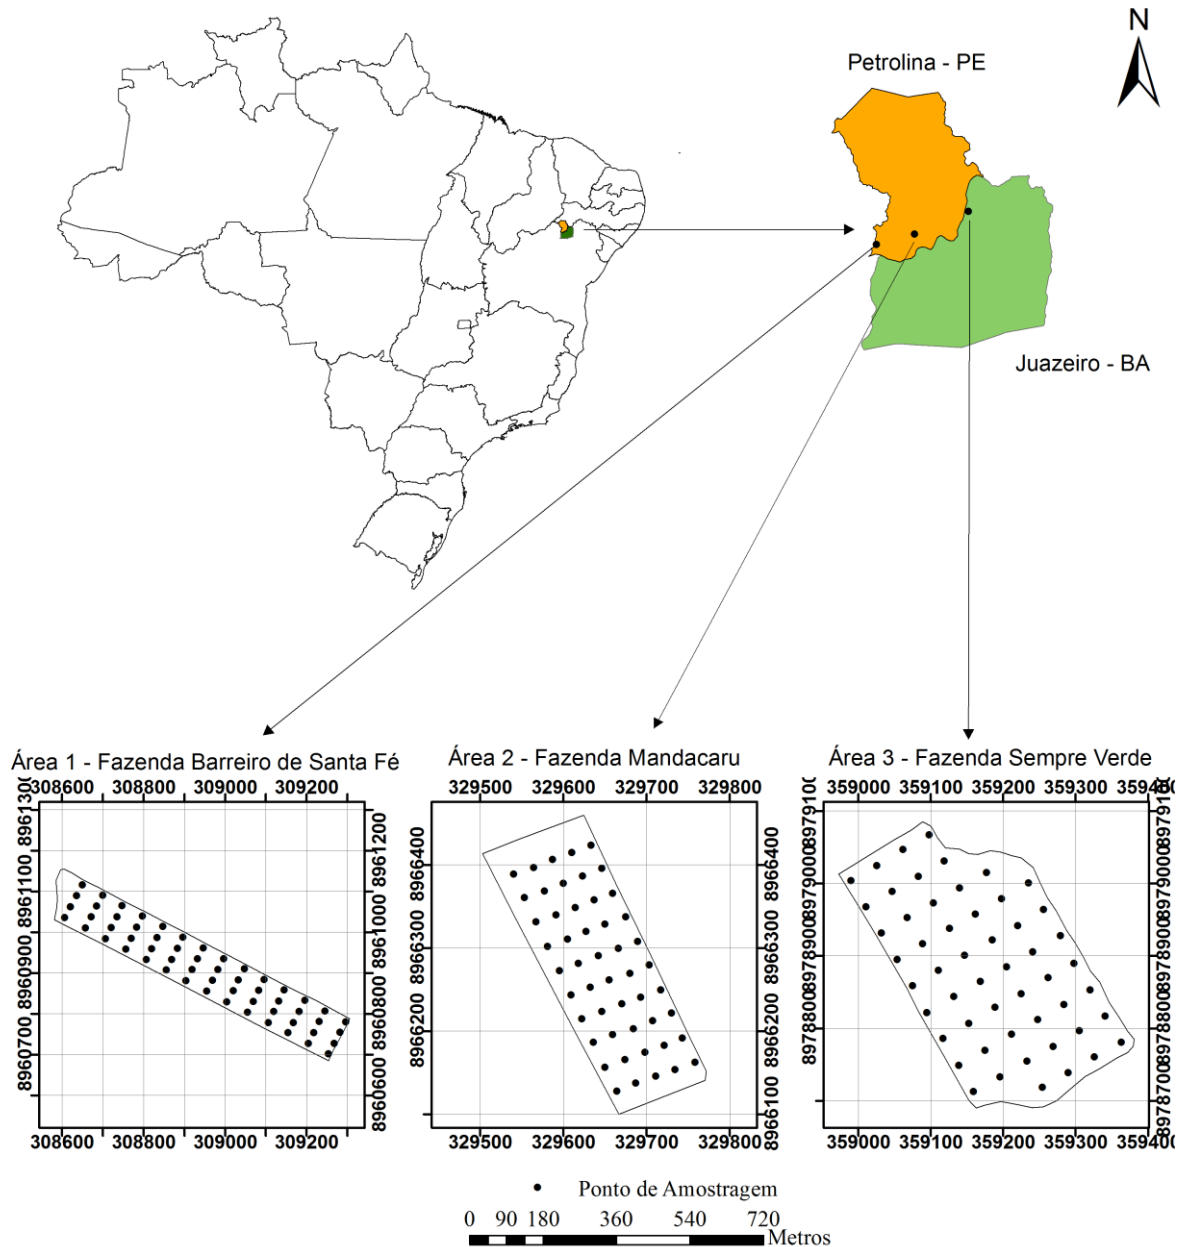
**Tabela 2.1.** Localização, relevo, solo, área, idade e espaçamento da cultura, irrigação e adubação das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

|                        | Área 1  | Área 2   | Área 3   |
|------------------------|---|--|--|
| Localização            | Fazenda Barreiro de Santa Fé, Petrolina, Pernambuco<br>(9°23'39,37" S e 40°44'32,91" W) | Fazenda Mandacaru, Petrolina, Pernambuco<br>(9°20'50,58" S e 40°33'04,51" W) | Fazenda Sempre Verde, Juazeiro, Bahia<br>(9°14'59,38" S e 40°16'5840" W) |
| Relevo                 | Plano   | Plano  | Plano  |
| Solo                   | Latossolo   | Argissolo  | Argissolo  |
| Área                   | 9 ha (797 x 114 m)  | 4,5 ha (353 x 125 m)   | 9,5 ha (411 x 232 m)   |
| Idade da cultura       | 25 anos   | 26 anos  | 25 anos  |
| Espaçamento da cultura | 8 x 5 m   | 8 x 5 m  | 7 x 5 m  |
| Irrigação              | Localizada por microaspersão (2 microaspersores/planta)                                 | Localizada por microaspersão (2 microaspersores/planta)                      | Localizada por microaspersão (2 microaspersores/planta)                  |
| Adubação               | Via fertirrigação para N, P e K e aplicação manual para Ca e Mg                         | Via fertirrigação para N, P e K e aplicação manual para Ca e Mg              | Via fertirrigação para N, P e K e aplicação manual para Ca e Mg          |

As amostras de solo foram coletadas na região da projeção da copa das plantas após a colheita (antes da aplicação de insumos) nas camadas de 0,00-0,20 e 0,20-0,40 m de profundidade, seguindo uma malha amostral regular contendo 56 pontos (com espaçamento de 56 m entre linhas e 30 m entre plantas), 50 pontos (com espaçamento de 32 m entre linhas e 25 m entre plantas) e 53 pontos (com



espaçamento de 42 m entre linhas e 35 m entre plantas) georreferenciados nas áreas das fazendas Barreiro de Santa Fé, Mandacaru e Sempre Verde respectivamente, totalizando 318 amostras (Figura 2.1).



**Figura 2.1.** Localização e distribuição dos pontos amostrais nas áreas cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira. 56 pontos amostrais na área Barreiro de Santa Fé, 50 pontos amostrais na área Mandacaru e 53 pontos amostrais na área Sempre Verde.

O número de amostras foi determinado de acordo com dois critérios: 1) a obtenção de no mínimo 30 pares de pontos para o cálculo das semivariâncias para que o semivariograma seja considerado representativo (ARÉTOUYAP et al., 2016) e 2) a forma geométrica de cada área.

### **Análises de referência e estatística descritiva**

As amostras de solo foram secas ao ar e passadas em peneira de 2,0 mm para obtenção da Terra Fina Seca ao Ar (TFSA). Nestas amostras foi determinado o carbono orgânico total (COT) pela digestão úmida com solução ácida de dicromato de potássio, posterior aquecimento e titulação do excesso de dicromato de potássio com solução de sulfato ferroso amoniacal, conforme Yeomans e Bremner (1988). Adicionalmente, determinou-se a condutividade elétrica (CE) em meio aquoso segundo Souza et al. (2013), a granulometria (método da pipeta), pH (mistura solo/água 1:2), teores de  $\text{Ca}^{2+}$  (solução extratora:  $\text{KCl } 1,0 \text{ mol L}^{-1}$ ),  $\text{Mg}^{2+}$  (solução extratora:  $\text{KCl } 1,0 \text{ mol L}^{-1}$ ),  $\text{Na}^+$  (solução extratora: Mehlich-1),  $\text{K}^+$  (solução extratora: Mehlich-1),  $\text{Al}^{3+}$  (solução extratora:  $\text{KCl } 1,0 \text{ mol L}^{-1}$ ), P (solução extratora: Mehlich-1) e acidez potencial (H+Al) (solução extratora alcalina de acetato de cálcio), conforme Teixeira et al. (2017).

Os dados de referência foram submetidos à análise descritiva (médias, valores máximos, mínimos, desvio padrão e coeficiente de variação (CV)) e suas distribuições foram testadas quanto à normalidade por meio o teste Shapiro-Wilk a 5% de probabilidade. O CV foi classificado segundo Warrick e Nielsen (1980) em baixa variabilidade ( $\text{CV} < 12\%$ ), média variabilidade ( $12\% \leq \text{CV} \leq 60\%$ ) e alta variabilidade ( $\text{CV} > 60\%$ ).

### **Aquisição dos dados espectrais**

Para a obtenção dos dados espectrais, foram utilizados 10  $\text{cm}^3$  das amostras de solo secas ao ar e passadas em peneira de 2,0 mm (VISCARRA ROSSEL et al., 2016). Os espectros de refletância das amostras foram adquiridos por: (1) um espectrorradiômetro FieldSpec 3 (*Analytical Spectral Devices*, Boulder, Colorado, USA) que possui sensor óptico com campo de visão  $8^\circ$ , faixa espectral de 350 a 2500 nm, resolução de 8 nm, e precisão de  $\pm 1 \text{ nm}$ ; (2) fonte de luz halogêneo-tungstênio-quartzo com 50 W; (3) câmara escura com dimensões 100 x 50 x 50 cm; e (4) computador com *software* RS3 (*Analytical Spectral Devices*, Boulder, Colorado, EUA). O sensor de fibra óptica foi posicionado perpendicularmente ao plano de medição, com altura de 7,0 cm, e as amostras de solo foram colocadas no centro do referido plano.

Utilizou-se como referência branca uma placa cerâmica Spectralon (*Labsphere Inc.*, North Sutton, NH, EUA), com a qual as operações de calibração foram realizadas antes da aquisição dos dados. Cada espectro de cada amostra de solo foi composto por uma média de 30 varreduras realizadas pelo equipamento. Obteve-se os valores de refletância, os quais foram utilizados para a construção das curvas espectrais médias das amostras de solo. Posteriormente, os valores de refletância foram transformados em medidas de absorbância ( $\log(1/R)$ ), onde R significa refletância, utilizando o *software* ViewSpec Pro (*Analytic Spectral Devices*, Boulder, Colorado, EUA). Os dados de absorbância foram usados para a construção dos modelos preditivos.

### **Análises quimiométricas**

Para a realização das análises quimiométricas, utilizou-se o *software* Unscrambler X 10.4 (CAMO ASA, Oslo, Noruega). Inicialmente, os dados espectrais foram submetidos a diferentes combinações de pré-processamentos. Aplicou-se aos dados espectrais suavização com filtro da média móvel (FMM) em vários tamanhos de segmento (7, 15, 25 e 35 pontos). Sobre os dados suavizados, foram aplicadas a primeira e segunda derivada de Savitzky-Golay (GORRY, 1990; SAVITZKY e GOLAY, 1964) com polinômio de segunda ordem e vários tamanhos de segmento (7, 15, 25 e 35 pontos). Sobre os dados suavizados e/ou derivadas, foram aplicadas a correção multiplicativa de espalhamento (MSC) (ISAKSSON e NAES, 1988), a transformação de variável normal padrão (SNV) (BARNES et al., 1989) e a correção ortogonal do sinal (OSC) (WOLD et al., 1984).

O desenvolvimento dos modelos preditivos para a determinação dos atributos físico-químicos do solo foi realizado com a regressão de mínimos quadrados parciais (PLSR). O conjunto de dados foi dividido utilizando o algoritmo Kennard-Stone (KENNARD e STONE, 1969), sendo 212 amostras para calibração e validação cruzada, e 106 amostras para validação externa. Foram utilizados os dados espectrais pré-processados, como variáveis preditoras (X), e os teores dos diferentes atributos físico-químicos, como variáveis resposta (Y). Também, os dados espectrais foram divididos por regiões, sendo modelados para região Vis (visível: 350-700 nm), região NIR (infravermelho próximo: 701-1100 nm), região SWIR (infravermelho de ondas

curtas: 1101-2500 nm), e região Vis-NIR-SWIR (350-2500 nm). Foi utilizado o algoritmo NIPALS (GELADI e KOWALSKI, 1986) com 100 iterações.

A fim de resolver os problemas de colinearidade da matriz de dados e permitir o desenvolvimento de modelos preditivos com a regressão linear múltipla (MLR), foi realizada uma seleção de variáveis dos comprimentos de onda a partir da análise gráfica dos pesos das variáveis espectrais dos atributos físico-químicos do solo nos modelos PLSR. Esses comprimentos de onda selecionados foram utilizados como variáveis preditoras para os modelos MLR. Após a construção dos modelos MLR, as variáveis selecionadas foram submetidas a uma análise de variância (ANOVA) e os modelos foram reconstruídos com as variáveis significativas ( $p$ -valor < 0,05).

O desempenho dos modelos foi avaliado a partir dos parâmetros estatísticos: coeficiente de determinação ( $R^2$ ); raiz quadrada média do erro de calibração (RMSEC); erro padrão de calibração (SEC); raiz quadrada média do erro de validação cruzada (RMSECV); erro padrão de validação cruzada (SECV); raiz quadrada média do erro de predição (RMSEP); erro padrão da predição (SEP); e viés. Esses parâmetros são definidos pelas seguintes equações:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})(y_i - \bar{y})}{(n-1)\sigma_r\sigma_p} \quad (\text{Equação 2.1})$$

$$RMSEC = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (\text{Equação 2.2})$$

$$SEC = \sqrt{\frac{n RMSEC^2}{n-1}} \quad (\text{Equação 2.3})$$

$$RMSECV = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_{i*})^2}{n}} \quad (\text{Equação 2.4})$$

$$SECV = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i - bias)^2}{n-1}} \quad (\text{Equação 2.5})$$

$$RMSEP = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{m}} \quad (\text{Equação 2.6})$$

$$SEP = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i - bias)^2}{m-1}} \quad (\text{Equação 2.7})$$

$$viés = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{m} \quad (\text{Equação 2.8})$$

Onde  $\hat{y}_i$  é o valor estimado pelo modelo de calibração;  $\hat{y}_{i*}$  é o valor estimado pelo modelo na etapa de validação cruzada;  $y_i$  é o valor de referência;  $\bar{y}$  é a média dos

valores de referência;  $\bar{y}$  é a média dos valores previstos;  $n$  é o número de amostras nas etapas de calibração ou validação;  $m$  é o número de amostras previstas;  $\sigma_r$  é o desvio padrão dos valores de referência;  $\sigma_p$  é o desvio padrão dos valores previstos; e  $S_r^2$  é a variação dos valores de referência.

Comparou-se o desempenho dos modelos PLSR e MLR e selecionou-se para a validação externa dos atributos físico-químicos do solo aqueles que apresentaram, simultaneamente, menores valores de erro padrão e maiores valores de coeficiente de determinação da validação cruzada (GÓMEZ et al., 2006). Para os modelos selecionados, realizou-se a validação externa. Por fim, utilizou-se a classificação proposta por Moore e Kirkland (2007) em termos de forte ( $R^2 > 0,70$ ), moderado ( $0,50 < R^2 < 0,70$ ), fraco ( $0,30 < R^2 < 0,50$ ) e muito fraco ( $R^2 < 0,30$ ).

### Análises geoestatísticas

Para os atributos que apresentaram desempenho forte e moderado, de acordo com a classificação proposta por Moore e Kirkland (2007), realizou-se a construção dos semivariogramas com o *software* GS+ 5.1 (Gamma Design, Plainwell, Michigan, EUA).

Para estimar a dependência espacial entre as amostras e identificar se as variações foram sistemáticas ou aleatórias, foram utilizados modelos de semivariogramas (OLIVER e WEBSTER, 2014). O semivariograma é uma ferramenta básica para quantificar a dependência espacial de uma variável regionalizada (HU et al., 2018), sendo calculado pela equação 2.9.

$$\gamma(h) = \frac{1}{2N(h)} \sum_{\alpha=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (\text{Equação 2.9})$$

onde  $N(h)$  é o número de pares experimentais de dados separados por uma distância  $h$ ,  $Z(x_i)$  é o valor determinado em cada ponto amostrado e  $Z(x_i + h)$  é o valor medido num ponto mais uma distância  $h$ .

Para as variáveis que apresentaram tendência, ou seja, quando o semivariograma cresceu indefinidamente, não ocorrendo a estabilização do patamar, a hipótese intrínseca não foi atendida e a remoção foi realizada pelo método de superfície de tendência proposto por Vieira et al. (2010). Este método consiste em ajustar uma superfície de tendência por mínimos quadrados e subtraí-la dos dados

originais gerando uma nova variável residual e o semivariograma é ajustado com os resíduos.

Os modelos esférico, exponencial e gaussiano foram testados para cada semivariograma (ZÚVALA et al., 2016). Para avaliar o grau de dependência espacial dos atributos físico-químicos do solo utilizou-se o índice de dependência espacial (IDE), proposto por Seidel e Oliveira (2016).

A partir dos semivariogramas ajustados, utilizou-se o interpolador krigagem ordinária para a confecção dos mapas (Oliver e Webster, 2014) utilizando a extensão ArcMap do *software* ArcGIS 10.2 (ESRI, Redlands, Califórnia, EUA, Licença trial). Em seguida, calculou-se a correlação linear de Pearson ( $r$ ) pixel a pixel entre os mapas dos atributos físico-químicos do solo determinados pelos métodos convencionais e os estimados pelo método de espectroscopia Vis-NIR-SWIR.

## RESULTADOS

### **Análise exploratória dos atributos do solo e do espectro**

Nas Tabelas 2.2 e 2.3, encontra-se a estatística descritiva dos atributos físico-químicos do solo das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde nas camadas de 0,00-0,20 m e 0,20-0,40 m de profundidade, respectivamente.

As maiores variabilidades dos atributos do solo nas três áreas e em ambas as profundidades, verificadas por meio dos valores de coeficiente de variação (CV) mais altos, ocorreram para P, enquanto as menores variabilidades (CVs mais baixos) ocorreram para pH e areia. Para a maioria dos atributos físico-químicos observou-se variabilidade intermediária. A presença de variação nos dados permite o desenvolvimento de modelos preditivos robustos.

A partir dos valores de máximo e mínimo, verifica-se a existência de uma amplitude considerável para vários atributos físico-químicos do solo. Ademais, o teste de Shapiro-Wilk indicou que alguns dos atributos do solo na camada superficial e subsuperficial não apresentaram distribuição normal.

**Tabela 2.2.** Análise descritiva dos atributos físico-químicos do solo na camada 0,00-0,20 m de profundidade das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| Atributos                             | pH                 | CE<br>dS m <sup>-1</sup> | Na <sup>+</sup> | K <sup>+</sup> | H + Al | Al <sup>3+</sup> | Ca <sup>2+</sup>   | Mg <sup>2+</sup>   | P<br>mg dm <sup>-3</sup> | Areia<br>-----%----- | Argila             | COT<br>dag Kg <sup>-1</sup> |
|---------------------------------------|--------------------|--------------------------|-----------------|----------------|--------|------------------|--------------------|--------------------|--------------------------|----------------------|--------------------|-----------------------------|
|                                       |                    |                          |                 |                |        |                  |                    |                    |                          |                      |                    |                             |
| 0,00-0,20 m                           |                    |                          |                 |                |        |                  |                    |                    |                          |                      |                    |                             |
| Área 1 – Fazenda Barreiro de Santa Fé |                    |                          |                 |                |        |                  |                    |                    |                          |                      |                    |                             |
| Média                                 | 7,09               | 0,09                     | 0,20            | 0,29           | 0,92   | 0,15             | 4,51               | 1,83               | 83,67                    | 83,24                | 8,28               | 2,03                        |
| Máximo                                | 7,76               | 0,13                     | 0,30            | 0,44           | 1,16   | 0,20             | 6,25               | 2,29               | 249,14                   | 89,65                | 14,50              | 3,48                        |
| Mínimo                                | 6,49               | 0,06                     | 0,09            | 0,15           | 0,66   | 0,10             | 3,15               | 1,47               | 10,45                    | 78,04                | 3,60               | 1,06                        |
| CV                                    | 4                  | 22                       | 32              | 25             | 15     | 35               | 16                 | 11                 | 76                       | 4                    | 33                 | 27                          |
| Classificação do CV                   | B                  | M                        | M               | M              | M      | M                | M                  | M                  | A                        | B                    | M                  | M                           |
| W                                     | 0,13 <sup>ns</sup> | 0,00*                    | 0,00*           | 0,00*          | 0,00*  | 0,00*            | 0,00*              | 0,00*              | 0,00*                    | 0,69 <sup>ns</sup>   | 0,43 <sup>ns</sup> | 0,13 <sup>ns</sup>          |
| Área 2 – Fazenda Mandacaru            |                    |                          |                 |                |        |                  |                    |                    |                          |                      |                    |                             |
| Média                                 | 6,81               | 0,06                     | 0,06            | 0,43           | 1,06   | 0,13             | 2,38               | 0,82               | 14,81                    | 90,50                | 4,04               | 1,70                        |
| Máximo                                | 7,74               | 0,22                     | 0,13            | 0,92           | 1,82   | 0,20             | 3,78               | 1,43               | 68,75                    | 92,50                | 6,70               | 3,94                        |
| Mínimo                                | 5,94               | 0,03                     | 0,04            | 0,21           | 0,33   | 0,10             | 1,54               | 0,50               | 3,27                     | 87,78                | 1,60               | 0,83                        |
| CV                                    | 7                  | 78                       | 41              | 42             | 37     | 36               | 22                 | 27                 | 86                       | 2                    | 35                 | 37                          |
| Classificação do CV                   | B                  | A                        | M               | M              | M      | M                | M                  | M                  | A                        | B                    | M                  | M                           |
| W                                     | 0,56 <sup>ns</sup> | 0,00*                    | 0,00*           | 0,00*          | 0,00*  | 0,00*            | 0,00*              | 0,00*              | 0,00*                    | 0,07 <sup>ns</sup>   | 0,13 <sup>ns</sup> | 0,00*                       |
| Área 3 – Fazenda Sempre Verde         |                    |                          |                 |                |        |                  |                    |                    |                          |                      |                    |                             |
| Média                                 | 6,51               | 0,12                     | 0,27            | 0,67           | 1,18   | 0,05             | 5,97               | 2,10               | 72,72                    | 68,85                | 16,87              | 0,94                        |
| Máximo                                | 6,97               | 0,31                     | 0,48            | 1,26           | 2,48   | 0,10             | 12,28              | 2,70               | 247,04                   | 87,37                | 24,10              | 1,60                        |
| Mínimo                                | 6,03               | 0,06                     | 0,13            | 0,31           | 0,33   | 0,05             | 1,45               | 1,31               | 2,05                     | 57,63                | 6,30               | 0,56                        |
| CV                                    | 3                  | 48                       | 31              | 34             | 48     | 27               | 36                 | 16                 | 60                       | 9                    | 23                 | 24                          |
| Classificação do CV                   | B                  | M                        | M               | M              | M      | M                | M                  | M                  | M                        | B                    | M                  | M                           |
| W                                     | 0,94 <sup>ns</sup> | 0,00*                    | 0,00*           | 0,00*          | 0,01*  | 0,00*            | 0,45 <sup>ns</sup> | 0,30 <sup>ns</sup> | 0,00*                    | 0,00*                | 0,65 <sup>ns</sup> | 0,19 <sup>ns</sup>          |

Legenda: Condutividade elétrica (CE); Acidez potencial (H+Al); Acidez trocável (Al<sup>3+</sup>); Carbono orgânico total (COT); Coeficiente de variação (CV); Classificação CV segundo Warrick e Nielsen (1980): baixa variabilidade (B) = CV < 12%, média variabilidade (M) = 12% ≤ CV ≤ 60 e alta variabilidade (A) = CV > 60%; Teste de normalidade de Shapiro-Wilk (W); não significativo a 5% de probabilidade, indicando normalidade dos dados (ns).

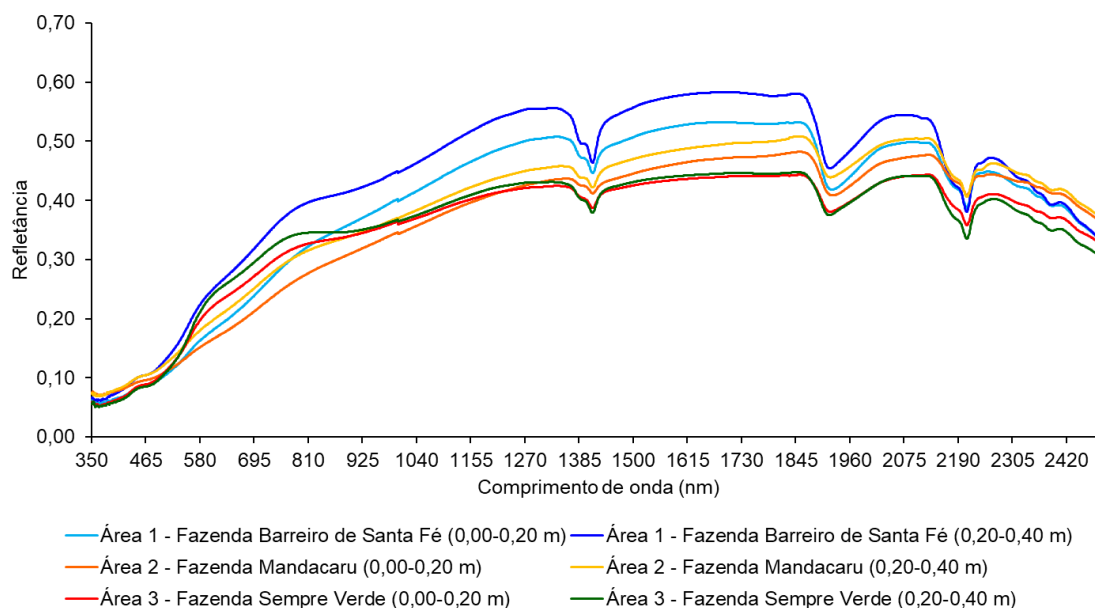
**Tabela 2.3.** Análise descritiva dos atributos físico-químicos do solo na camada 0,20-0,40 m de profundidade das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| Atributos                             | pH                 | CE<br>dS m <sup>-1</sup> | Na <sup>+</sup>    | K <sup>+</sup> | H + Al | Al <sup>3+</sup> | Ca <sup>+2</sup>   | Mg <sup>+2</sup>   | P<br>mg dm <sup>-3</sup> | Areia<br>-----%----- | Argila             | COT<br>dag Kg <sup>-1</sup> |
|---------------------------------------|--------------------|--------------------------|--------------------|----------------|--------|------------------|--------------------|--------------------|--------------------------|----------------------|--------------------|-----------------------------|
|                                       |                    |                          |                    |                |        |                  |                    |                    |                          |                      |                    |                             |
| 0,20-0,40 m                           |                    |                          |                    |                |        |                  |                    |                    |                          |                      |                    |                             |
| Área 1 – Fazenda Barreiro de Santa Fé |                    |                          |                    |                |        |                  |                    |                    |                          |                      |                    |                             |
| Média                                 | 6,79               | 0,06                     | 0,26               | 0,53           | 1,31   | 0,09             | 3,46               | 1,56               | 49,33                    | 80,21                | 13,13              | 1,04                        |
| Máximo                                | 7,37               | 0,16                     | 0,30               | 0,92           | 1,65   | 0,10             | 4,63               | 2,10               | 224,73                   | 88,36                | 20,50              | 2,11                        |
| Mínimo                                | 6,35               | 0,04                     | 0,22               | 0,26           | 1,16   | 0,05             | 2,36               | 1,08               | 11,59                    | 74,44                | 7,40               | 0,59                        |
| CV                                    | 4                  | 40                       | 14                 | 31             | 16     | 25               | 17                 | 13                 | 96                       | 5                    | 25                 | 26                          |
| Classificação do CV                   | B                  | M                        | M                  | M              | M      | M                | M                  | M                  | A                        | B                    | M                  | M                           |
| W                                     | 0,47 <sup>ns</sup> | 0,00*                    | 0,00*              | 0,00*          | 0,00*  | 0,00*            | 0,00*              | 0,00*              | 0,00*                    | 0,22 <sup>ns</sup>   | 0,14 <sup>ns</sup> | 0,00*                       |
| Área 2 – Fazenda Mandacaru            |                    |                          |                    |                |        |                  |                    |                    |                          |                      |                    |                             |
| Média                                 | 6,76               | 0,04                     | 0,05               | 0,33           | 0,72   | 0,19             | 1,19               | 0,65               | 14,81                    | 90,27                | 4,43               | 0,84                        |
| Máximo                                | 8,00               | 0,16                     | 0,09               | 0,62           | 1,32   | 0,30             | 1,93               | 0,87               | 68,75                    | 93,17                | 6,70               | 2,03                        |
| Mínimo                                | 5,87               | 0,02                     | 0,04               | 0,13           | 0,33   | 0,05             | 0,60               | 0,42               | 3,27                     | 86,07                | 1,70               | 0,46                        |
| CV                                    | 8                  | 68                       | 35                 | 38             | 42     | 38               | 27                 | 19                 | 86                       | 2                    | 29                 | 34                          |
| Classificação do CV                   | B                  | A                        | M                  | M              | M      | M                | M                  | M                  | A                        | B                    | M                  | M                           |
| W                                     | 0,38 <sup>ns</sup> | 0,00*                    | 0,00*              | 0,00*          | 0,02*  | 0,00*            | 0,00*              | 0,00*              | 0,00*                    | 0,00*                | 0,75 <sup>ns</sup> | 0,00*                       |
| Área 3 – Fazenda Sempre Verde         |                    |                          |                    |                |        |                  |                    |                    |                          |                      |                    |                             |
| Média                                 | 6,43               | 0,12                     | 0,30               | 0,76           | 1,11   | 0,06             | 5,78               | 1,85               | 39,60                    | 63,65                | 22,96              | 0,72                        |
| Máximo                                | 6,81               | 0,33                     | 0,52               | 2,28           | 2,15   | 0,15             | 10,61              | 2,87               | 127,68                   | 75,15                | 37,60              | 1,09                        |
| Mínimo                                | 5,74               | 0,04                     | 0,09               | 0,21           | 0,33   | 0,05             | 2,40               | 0,11               | 1,39                     | 49,50                | 13,80              | 0,49                        |
| CV                                    | 3                  | 53                       | 32                 | 57             | 42     | 39               | 36                 | 33                 | 74                       | 10                   | 27                 | 20                          |
| Classificação do CV                   | B                  | M                        | M                  | M              | M      | M                | M                  | M                  | A                        | B                    | M                  | M                           |
| W                                     | 0,03*              | 0,00*                    | 0,12 <sup>ns</sup> | 0,00*          | 0,04*  | 0,00*            | 0,43 <sup>ns</sup> | 0,13 <sup>ns</sup> | 0,00*                    | 0,40 <sup>ns</sup>   | 0,37 <sup>ns</sup> | 0,00*                       |

Legenda: Condutividade elétrica (CE); Acidez potencial (H+Al); Acidez trocável (Al<sup>+3</sup>); Carbono orgânico total (COT); Coeficiente de variação (CV); Classificação CV segundo Warrick e Nielsen (1980): baixa variabilidade (B) = CV < 12%, média variabilidade (M) = 12% ≤ CV ≤ 60 e alta variabilidade (A) = CV > 60%; Teste de normalidade de Shapiro-Wilk (W); não significativo a 5% de probabilidade, indicando normalidade dos dados (ns).



A Figura 2.2 apresenta as curvas espectrais médias das amostras de solo de cada área nas camadas de 0,00 a 0,20 e de 0,20 a 0,40 m de profundidade. Observa-se que nas regiões do Vis (visível; 350-700 nm) e do NIR (infravermelho próximo; 701-1100 nm) ocorre uma elevação da refletância à medida em que se aumentam os comprimentos de onda e na região do SWIR (infravermelho de ondas curtas; 1101-2500 nm) verifica-se a existência de picos de absorção em torno de 1400, 1950 e 2200 nm.



**Figura 2.2.** Espectros de refletância média das amostras de solo nas camadas de 0,00-0,20 e 0,20-0,40 m de profundidade em três áreas produtivas de mangueira irrigada cultivar ‘Tommy Atkins’ na região semiárida brasileira.

### Desempenho dos modelos quimiométricos

A Tabela 2.4 apresenta as assinaturas espectrais dos atributos físico-químicos do solo em áreas cultivadas com mangueira irrigada na região semiárida brasileira. Observa-se que a maioria dos atributos do solo possui assinaturas espectrais na região do SWIR, com exceção da areia e o carbono orgânico total (COT) apresentando duas assinaturas na região do Vis e três assinaturas na região do NIR, respectivamente.

**Tabela 2.4.** Assinaturas espectrais dos atributos físico-químicos do solo em áreas cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| <b>Atributos</b>                                       | <b>Comprimento de onda (nm)</b>   |
|--|---|
| pH   | 1896; 1998; 1911; 1990; 2196; 2212; e 2237.   |
| CE (dS m <sup>-1</sup> )                               | 1848; 1909; 1949; 1963; 1987; 2048; 2113; 2125; 2268; 2291; 2312; 2333; 2354; 2368; 2388; 2403; 2414; e 2476. |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | 2278; 2387; e 2405.   |
| K <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )   | 1390; 1404; 1414; e 1730.   |
| H+Al (cmol <sub>c</sub> dm <sup>-3</sup> )             | 1975; 1998; 2202; e 2266.   |
| Al <sup>3+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | 1347; 1383; 1400; 1413; 1440; 1733; e 1764.   |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | 1885; 1901; 2130; 2354; 2368; e 2459.   |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | 2133; 2242; 2261; 2282; e 2455.   |
| P (mg dm <sup>-3</sup> )                               | 1241; 1264; 1397; 1413; 1445; e 1683.   |
| Areia (dag Kg <sup>-1</sup> )                          | 519; 590; 1297; 1388; 1408; 1441; 2210; 2219; 2244; e 2349.   |
| Argila (dag Kg <sup>-1</sup> )                         | 1889; 1974; 2021; 2068; 2100; 2212; 2286; 2349; 2401; 2453; e 2461.   |
| COT (dag Kg <sup>-1</sup> )                            | 763; 781; 827; 1125; 1214; 1242; 1282; 1307; 1363; 1382; 1402; 1410; 1439; 1446; e 1660.                      |

Legenda: Condutividade elétrica (CE); Carbono orgânico total (COT).

A Tabela 2.5 apresenta os parâmetros de desempenho dos modelos preditivos para os atributos físico-químicos do solo, em áreas cultivadas com mangueira irrigada cv. 'Tommy Atkins', com uso da espectroscopia Vis-NIR-SWIR. O pré-processamento que proporcionou os melhores desempenhos foi a correção do sinal ortogonal (OSC).

Para pH, CE, Na<sup>+</sup>, H+Al, Al<sup>3+</sup>, Mg<sup>2+</sup> e P, o modelo PLSR proporcionou o melhor desempenho preditivo, sendo utilizada a região espectral do NIR para Al<sup>3+</sup> e P, e a região espectral do SWIR para pH, CE, Na<sup>+</sup>, H+Al e Mg<sup>2+</sup>. Para K<sup>+</sup>, Ca<sup>2+</sup>, areia, argila e COT, o modelo MLR proporcionou o melhor desempenho preditivo, sendo utilizado assinaturas espectrais.

Segundo a classificação de Moore e Kirkland (2007), considerando o resultado da validação externa, os modelos preditivos ajustados tiveram

desempenho forte para os atributos areia, argila e COT, moderado para  $\text{Na}^+$ ,  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$ , fraco para pH, CE,  $\text{K}^+$  e  $\text{Al}^{3+}$ , e muito fraco para H+Al e P. As regiões espectrais do NIR e SWIR possuem relação com os atributos físico-químicos do solo. Para todos os atributos, observou-se que a seleção de regiões específicas do espectro ou assinaturas espectrais proporcionou modelos com maior capacidade preditiva do que espectro completo.

**Tabela 2.5.** Parâmetros dos modelos de regressão que apresentaram o melhor desempenho preditivo para os atributos físico-químicos do solo cultivado com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| Atributos  | Modelos | Faixa espectral | Calibração     |       |       |      | Validação cruzada |        |       |      |         | Validação externa |       |       |       |
|--|---------|-----------------|----------------|-------|-------|------|-------------------|--------|-------|------|---------|-------------------|-------|-------|-------|
|  |         |                 | R <sup>2</sup> | RMSEC | SEC   | BIAS | R <sup>2</sup>    | RMSECV | SECV  | BIAS | FATORES | R <sup>2</sup>    | RMSEP | SEP   | BIAS  |
| pH   | PLSR    | SWIR            | 0,61           | 0,29  | 0,29  | 0,00 | 0,54              | 0,32   | 0,32  | 0,00 | 7       | 0,35              | 0,35  | 0,35  | 0,00  |
| CE (dS m <sup>-1</sup> )                               | PLSR    | SWIR            | 0,68           | 0,05  | 0,05  | 0,00 | 0,61              | 0,05   | 0,05  | 0,00 | 6       | 0,47              | 0,04  | 0,04  | 0,01  |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | PLSR    | SWIR            | 0,61           | 0,07  | 0,07  | 0,00 | 0,59              | 0,07   | 0,07  | 0,00 | 3       | 0,65              | 0,07  | 0,07  | 0,01  |
| K <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )   | MLR     | -               | 0,39           | 0,25  | 0,25  | 0,00 | 0,35              | 0,25   | 0,25  | 0,00 | -       | 0,32              | 0,21  | 0,21  | 0,01  |
| H+Al (cmol <sub>c</sub> dm <sup>-3</sup> )             | PLSR    | SWIR            | 0,38           | 0,36  | 0,36  | 0,00 | 0,27              | 0,39   | 0,39  | 0,00 | 6       | 0,11              | 0,41  | 0,41  | 0,06  |
| Al <sup>3+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | PLSR    | NIR             | 0,42           | 0,05  | 0,05  | 0,00 | 0,39              | 0,05   | 0,05  | 0,00 | 3       | 0,40              | 0,05  | 0,04  | 0,01  |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | MLR     | -               | 0,71           | 1,18  | 1,16  | 0,00 | 0,69              | 1,20   | 1,20  | 0,00 | -       | 0,66              | 1,27  | 1,24  | 0,30  |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | PLSR    | SWIR            | 0,79           | 0,30  | 0,30  | 0,00 | 0,77              | 0,31   | 0,31  | 0,00 | 5       | 0,70              | 0,32  | 0,32  | -0,01 |
| P (mg dm <sup>-3</sup> )                               | PLSR    | NIR             | 0,43           | 45,37 | 45,47 | 0,00 | 0,36              | 48,07  | 48,18 | 0,41 | 3       | 0,24              | 43,03 | 43,12 | 3,09  |
| Areia (dag Kg <sup>-1</sup> )                          | MLR     | -               | 0,91           | 3,39  | 3,31  | 0,00 | 0,91              | 3,45   | 3,45  | 0,00 | -       | 0,93              | 2,62  | 2,62  | -0,27 |
| Argila (dag Kg <sup>-1</sup> )                         | MLR     | -               | 0,90           | 2,55  | 2,49  | 0,00 | 0,89              | 2,65   | 2,65  | 0,00 | -       | 0,89              | 2,38  | 2,27  | 0,77  |
| COT (dag Kg <sup>-1</sup> )                            | MLR     | -               | 0,89           | 0,22  | 0,22  | 0,00 | 0,88              | 0,23   | 0,23  | 0,00 |         | 0,85              | 0,22  | 0,22  | 0,01  |

Legenda: Regressão dos mínimos quadrados parciais (PLSR); Regressão linear múltipla (MLR); Infravermelho (NIR); Infravermelho de ondas curtas (SWIR); Coeficiente de determinação (R<sup>2</sup>); Raiz Quadrada média do erro de calibração (RMSEC); Erro padrão de calibração (SEC); Raiz quadrada média do erro de validação cruzada (RMSECV); Erro padrão de validação cruzada (SECV); Raiz quadrada média do erro de predição (RMSEP); Erro padrão da predição (SEP); Carbono orgânico total (COT); Condutividade elétrica (CE).

### **Desempenho dos modelos geoestatísticos**

A Tabela 2.6 apresenta os parâmetros dos semivariogramas para os atributos físico-químicos do solo determinados por método convencional e por espectroscopia Vis-NIR-SWIR. Observa-se a ocorrência de efeito pepita puro (EPP), isto é, ausência de dependência espacial na distância amostral utilizada na área 1 para os atributos  $\text{Na}^+$  (nas duas profundidades avaliadas) e  $\text{Mg}^{2+}$  (na camada de 0,20-0,40 m de profundidade) e na área 2 para o atributo argila (na camada de 0,20-0,40 m de profundidade) determinados por métodos convencionais. Ademais, observa-se EPP na área 1 para o atributo  $\text{Mg}^{2+}$  (na camada de 0,20-0,40 m de profundidade), determinado por método de espectroscopia Vis-NIR-SWIR.

Em relação ao índice de dependência espacial (IDE), observa-se que os atributos físico-químicos do solo apresentaram IDE moderado e forte. Os atributos do solo determinados por método de espectroscopia Vis-NIR-SWIR apresentaram IDE semelhantes aos dos métodos convencionais, com exceção do  $\text{Ca}^{2+}$  na área 1, para o qual observou-se diminuição do IDE de forte para moderado nas duas profundidades.

**Tabela 2.6.** Parâmetros de ajuste dos semivariogramas para os atributos do solo determinados pelos métodos convencionais e por espectroscopia Vis-NIR-SWIR nas camadas de 0,00-0,20 e 0,20-0,40 m de profundidade em três áreas distintas cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| Atributos  | Métodos convencionais |                |                                 |                    |         |     | Método espectroscopia Vis-NIR-SWIR |                |                                 |                    |         |     |
|--|-----------------------|----------------|---------------------------------|--------------------|---------|-----|------------------------------------|----------------|---------------------------------|--------------------|---------|-----|
|  | Mod                   | C <sub>0</sub> | C <sub>0</sub> + C <sub>1</sub> | A <sub>0</sub> (m) | IDE (%) | IDE | Mod                                | C <sub>0</sub> | C <sub>0</sub> + C <sub>1</sub> | A <sub>0</sub> (m) | IDE (%) | IDE |
| Área 1 – Fazenda Barreiro de Santa Fé (0,00-0,20 m)    |                       |                |                                 |                    |         |     |                                    |                |                                 |                    |         |     |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | EPP                   | 0,00           | 0,00                            | -                  | -       | -   | EXP                                | 0,00           | 0,00                            | 63,00              | 7       | Mo  |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF                   | 0,12           | 0,49                            | 103,40             | 16      | Fo  | ESF                                | 0,33           | 0,58                            | 86,77              | 8       | Mo  |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | GAU                   | 0,01           | 0,04                            | 78,98              | 14      | Mo  | ESF                                | 0,02           | 0,05                            | 111,70             | 12      | Mo  |
| Areia (dag Kg <sup>-1</sup> )                          | ESF                   | 2,53           | 10,85                           | 249,10             | 39      | Fo  | ESF                                | 1,87           | 16,03                           | 255,40             | 46      | Fo  |
| Argila (dag Kg <sup>-1</sup> )                         | ESF                   | 3,50           | 11,08                           | 165,90             | 23      | Fo  | ESF                                | 2,05           | 7,29                            | 255,70             | 38      | Fo  |
| COT (dag Kg <sup>-1</sup> )                            | ESF                   | 0,05           | 0,28                            | 73,80              | 12      | Fo  | GAU                                | 0,02           | 0,21                            | 61,62              | 16      | Fo  |
| Área 1 – Fazenda Barreiro de Santa Fé (0,20-0,40 m)    |                       |                |                                 |                    |         |     |                                    |                |                                 |                    |         |     |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | EPP                   | 0,00           | 0,00                            | -                  | -       | -   | EXP                                | 0,00           | 0,00                            | 105,00             | 18      | Fo  |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF                   | 0,11           | 0,60                            | 138,10             | 23      | Fo  | ESF                                | 0,13           | 0,36                            | 96,70              | 12      | Mo  |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | EPP                   | 0,03           | 0,03                            | -                  | -       | -   | EPP                                | 0,04           | 0,04                            | -                  | -       | -   |
| Areia (dag Kg <sup>-1</sup> )                          | ESF                   | 0,45           | 18,89                           | 187,50             | 37      | Fo  | EXP                                | 0,00           | 15,67                           | 196,00             | 34      | Fo  |
| Argila (dag Kg <sup>-1</sup> )                         | GAU                   | 4,77           | 15,33                           | 182,39             | 34      | Fo  | ESF                                | 1,96           | 9,51                            | 181,80             | 29      | Fo  |
| COT (dag Kg <sup>-1</sup> )                            | EXP                   | 0,00           | 0,05                            | 61,80              | 12      | Mo  | GAU                                | 0,01           | 0,07                            | 72,53              | 18      | Mo  |
| Área 2 – Fazenda Mandacaru (0,00-0,20 m)               |                       |                |                                 |                    |         |     |                                    |                |                                 |                    |         |     |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | GAU                   | 0,06           | 0,27                            | 60,97              | 30      | Fo  | GAU                                | 0,00           | 0,00                            | 40,80              | 24      | Fo  |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF                   | 0,01           | 0,25                            | 45,15              | 21      | Fo  | ESF                                | 0,15           | 0,74                            | 54,45              | 21      | Fo  |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF                   | 0,00           | 0,05                            | 41,70              | 19      | Fo  | ESF                                | 0,02           | 0,06                            | 49,56              | 17      | Fo  |
| Areia (dag Kg <sup>-1</sup> )                          | GAU                   | 0,08           | 2,34                            | 51,79              | 32      | Fo  | GAU                                | 0,84           | 3,36                            | 46,21              | 22      | Fo  |
| Argila (dag Kg <sup>-1</sup> )                         | EXP                   | 0,06           | 1,73                            | 109,59             | 43      | Fo  | GAU                                | 0,00           | 2,97                            | 50,06              | 32      | Fo  |
| COT (dag Kg <sup>-1</sup> )                            | ESF                   | 0,02           | 0,24                            | 42,90              | 19      | Fo  | ESF                                | 0,03           | 0,16                            | 46,24              | 18      | Fo  |

Tabela 2.6 (continuação)

| Área 2 – Fazenda Mandacaru (0,20-0,40 m)               |     |       |       |        |    |    |     |      |       |        |    |    |
|--|-----|-------|-------|--------|----|----|-----|------|-------|--------|----|----|
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | EXP | 0,07  | 0,30  | 78,34  | 25 | Fo | EXP | 0,00 | 0,00  | 60,90  | 22 | Fo |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | GAU | 0,00  | 0,11  | 49,88  | 31 | Fo | GAU | 0,04 | 0,53  | 43,22  | 26 | Fo |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF | 0,00  | 0,02  | 42,30  | 19 | Fo | ESF | 0,00 | 0,01  | 46,55  | 21 | Fo |
| Areia (dag Kg <sup>-1</sup> )                          | GAU | 0,48  | 1,88  | 57,16  | 27 | Fo | ESF | 1,41 | 3,66  | 129,30 | 38 | Fo |
| Argila (dag Kg <sup>-1</sup> )                         | EPP | 2,18  | 2,18  | -      | -  | -  | ESF | 0,45 | 2,57  | 41,48  | 16 | Fo |
| COT (dag Kg <sup>-1</sup> )                            | GAU | 0,01  | 0,05  | 42,44  | 24 | Fo | ESF | 0,01 | 0,05  | 58,30  | 25 | Fo |
| Área 3 – Fazenda Sempre Verde (0,00-0,20 m)            |     |       |       |        |    |    |     |      |       |        |    |    |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | ESF | 0,01  | 0,03  | 155,80 | 32 | Fo | GAU | 0,00 | 0,00  | 70,51  | 26 | Fo |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF | 1,41  | 3,66  | 126,00 | 27 | Fo | ESF | 0,08 | 0,62  | 79,41  | 24 | Fo |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | EXP | 0,02  | 0,10  | 92,11  | 21 | Fo | ESF | 0,00 | 0,06  | 78,12  | 26 | Fo |
| Areia (dag Kg <sup>-1</sup> )                          | GAU | 8,06  | 26,39 | 86,26  | 28 | Fo | GAU | 0,79 | 18,71 | 93,70  | 42 | Fo |
| Argila (dag Kg <sup>-1</sup> )                         | GAU | 0,89  | 15,28 | 82,97  | 36 | Fo | GAU | 0,01 | 11,95 | 100,29 | 46 | Fo |
| COT (dag Kg <sup>-1</sup> )                            | ESF | 0,00  | 0,05  | 88,90  | 30 | Fo | GAU | 0,00 | 0,06  | 74,48  | 33 | Fo |
| Área 3 – Fazenda Sempre Verde (0,20-0,40 m)            |     |       |       |        |    |    |     |      |       |        |    |    |
| Na <sup>+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> )  | ESF | 0,00  | 0,03  | 138,30 | 45 | Fo | GAU | 0,00 | 0,00  | 71,76  | 31 | Fo |
| Ca <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | ESF | 2,06  | 4,04  | 113,40 | 19 | Fo | ESF | 0,06 | 0,92  | 112,90 | 36 | Fo |
| Mg <sup>2+</sup> (cmol <sub>c</sub> dm <sup>-3</sup> ) | EXP | 0,02  | 0,21  | 138,30 | 37 | Fo | GAU | 0,00 | 0,06  | 67,90  | 29 | Fo |
| Areia (dag Kg <sup>-1</sup> )                          | ESF | 10,90 | 45,49 | 142,80 | 37 | Fo | ESF | 2,90 | 34,53 | 142,10 | 45 | Fo |
| Argila (dag Kg <sup>-1</sup> )                         | ESF | 7,50  | 43,88 | 160,10 | 46 | Fo | GAU | 6,39 | 26,64 | 114,32 | 40 | Fo |
| COT (dag Kg <sup>-1</sup> )                            | ESF | 0,00  | 0,02  | 76,82  | 23 | Fo | GAU | 0,00 | 0,03  | 65,30  | 30 | Fo |

Legenda: Modelo (Mod); Efeito pepita (C<sub>0</sub>); Patamar (C<sub>0</sub> + C); Alcance (A<sub>0</sub>); Índice de dependência espacial (IDE); Esférico (ESF); Exponencial (EXP); Gaussiano (GAU); Efeito pepita puro (EPP); Carbono orgânico total (COT); Moderado (Mo); Forte (Fo).

Para os atributos  $\text{Ca}^{2+}$ , areia e argila na camada de 0,00-0,20 m de profundidade e  $\text{Ca}^{2+}$  na camada de 0,20-0,40 m da área 1,  $\text{Na}^+$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ , areia e COT na camada de 0,00-0,20 m de profundidade e  $\text{Na}^+$ ,  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  na camada de 0,20-0,40 m da área 2,  $\text{Ca}^{2+}$ , areia e argila na camada de 0,00-0,20 m de profundidade e  $\text{Ca}^{2+}$  e areia na camada de 0,20-0,40 m da área 3, os semivariogramas dos métodos convencionais e método espectroscopia Vis-NIR-SWIR foram ajustados pelos mesmos modelos. Em geral, o modelo esférico foi o mais adequado para expressar a dependência espacial dos atributos físico-químicos do solo.

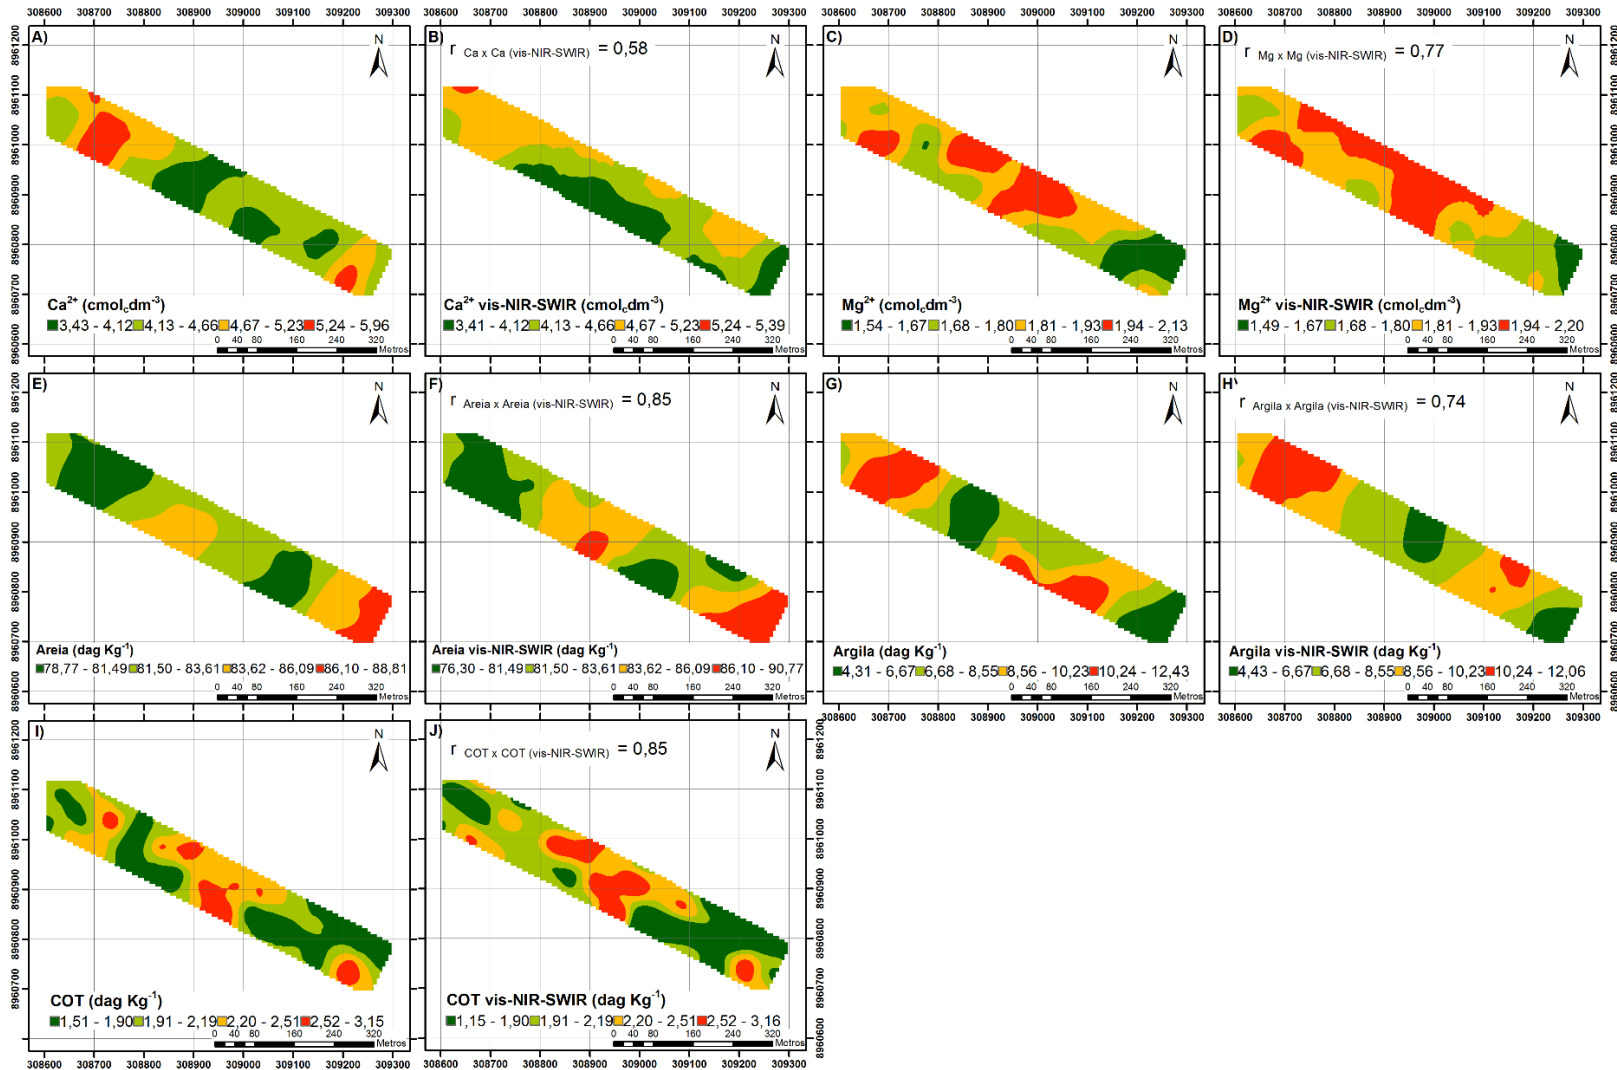
Os maiores valores de alcance para os atributos determinados pelos métodos convencionais foram verificados para areia na área 1 na camada de 0,00-0,20 m de profundidade, para argila na área 2 na camada de 0,00-0,20 m de profundidade e para argila na área 3 na camada de 0,20-0,40 m de profundidade. O alcance dos atributos determinados por espectroscopia Vis-NIR-SWIR apresentou variação em comparação com os valores de referência, sendo que a maior variação foi observada para argila na área 1 na camada de 0,00-0,20 m de profundidade (89,80 m) e a menor diferença foi verificada para  $\text{Ca}^{2+}$  na área 3 na camada de 0,20-0,40 m de profundidade (0,50 m).

Os mapas interpolados por Krigagem ordinária e os coeficientes de correlação entre eles são apresentados nas Figuras 2.3, 2.4, 2.5, 2.6, 2.7 e 2.8. Observa-se que a área 1 mostrou as melhores correlações entre os mapas dos teores de referência e os mapas dos teores determinados por espectroscopia Vis-NIR-SWIR para as duas profundidades avaliadas. Nas áreas 2 e 3, de modo geral, observou-se melhores correlações entre as interpolações na camada de 0,20-0,40 m de profundidade.

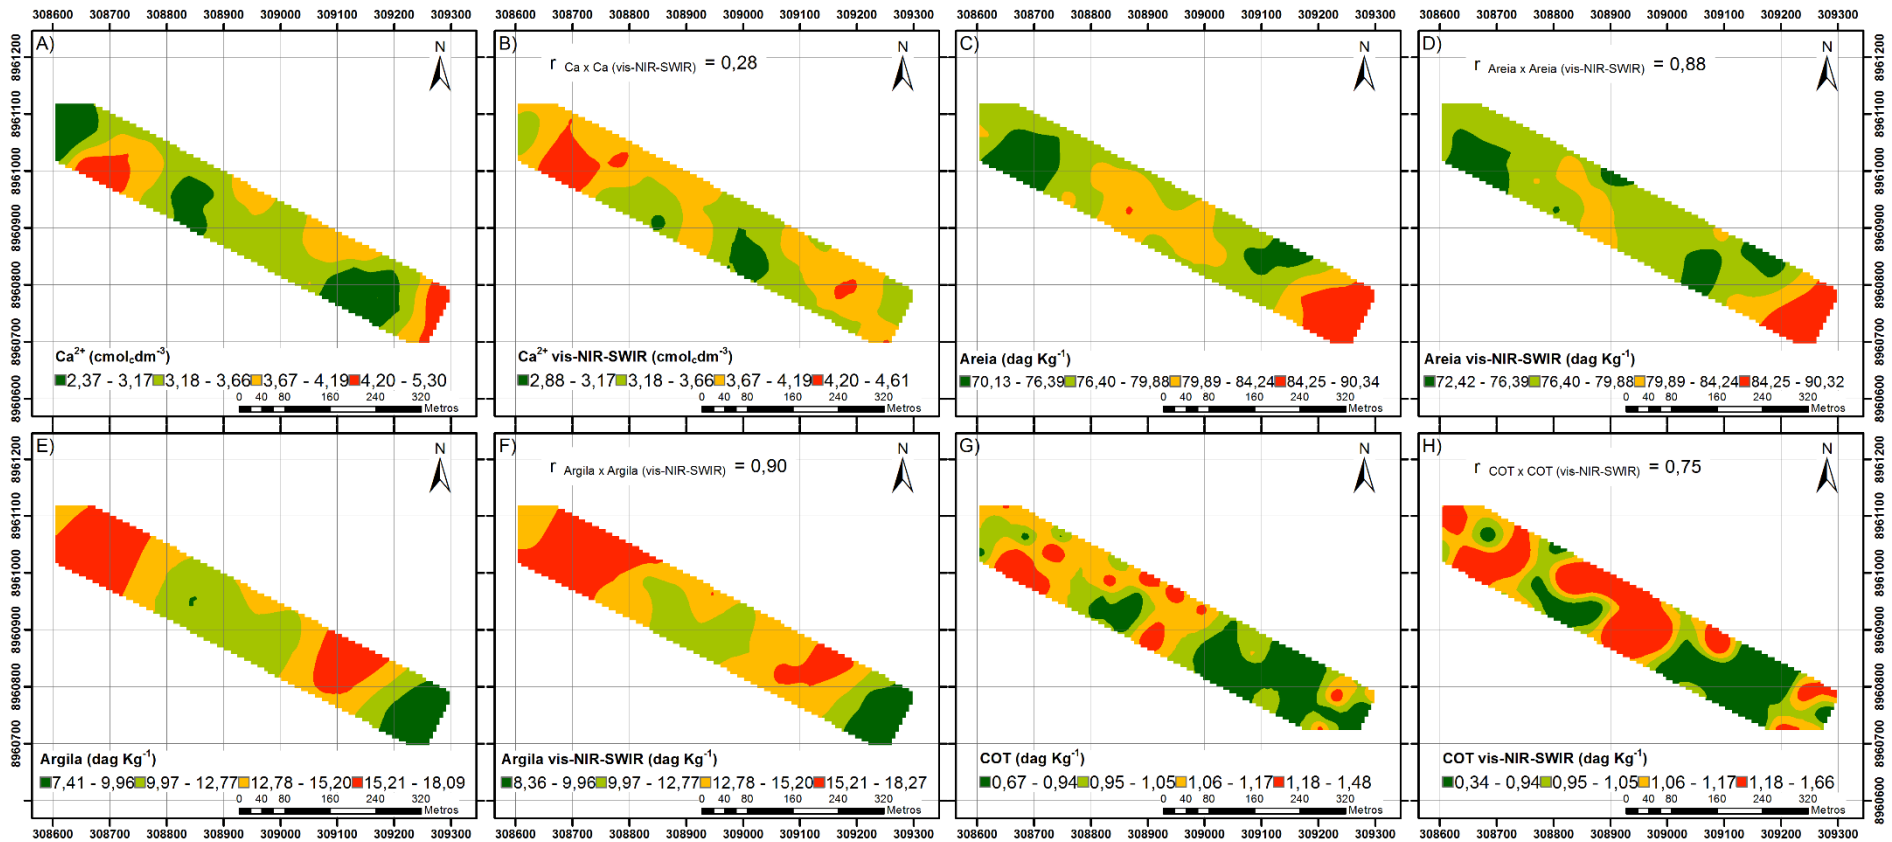
As melhores correlações espaciais ocorreram para textura e COT nas diferentes áreas de produção e profundidade, com exceção do COT na camada de 0,20-0,40 m de profundidade da área 3 (Figura 2.8L). Para esse atributo na área 3 na camada de 0,20-0,40 m de profundidade, observa-se que houve uma subestimação dos teores, uma vez que o mapa dos teores de referência (Figura 2.8K) apresentou predominância da classe de 0,65-0,73  $\text{dag kg}^{-1}$  (verde claro), enquanto o mapa dos teores estimados (Figura 2.8L) apresentou predominância da classe de 0,52-0,64  $\text{dag kg}^{-1}$  (verde escuro). Contudo, os teores de COT em ambos os mapas apresentaram um padrão de distribuição espacial semelhantes. Ademais, para os atributos  $\text{Na}^+$ ,  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$ , as correlações espaciais foram variadas sendo a maior correlação obtida para  $\text{Mg}^{2+}$  na área 1 na camada de 0,00-0,20 m de profundidade (Figura 2.3C) e a menor



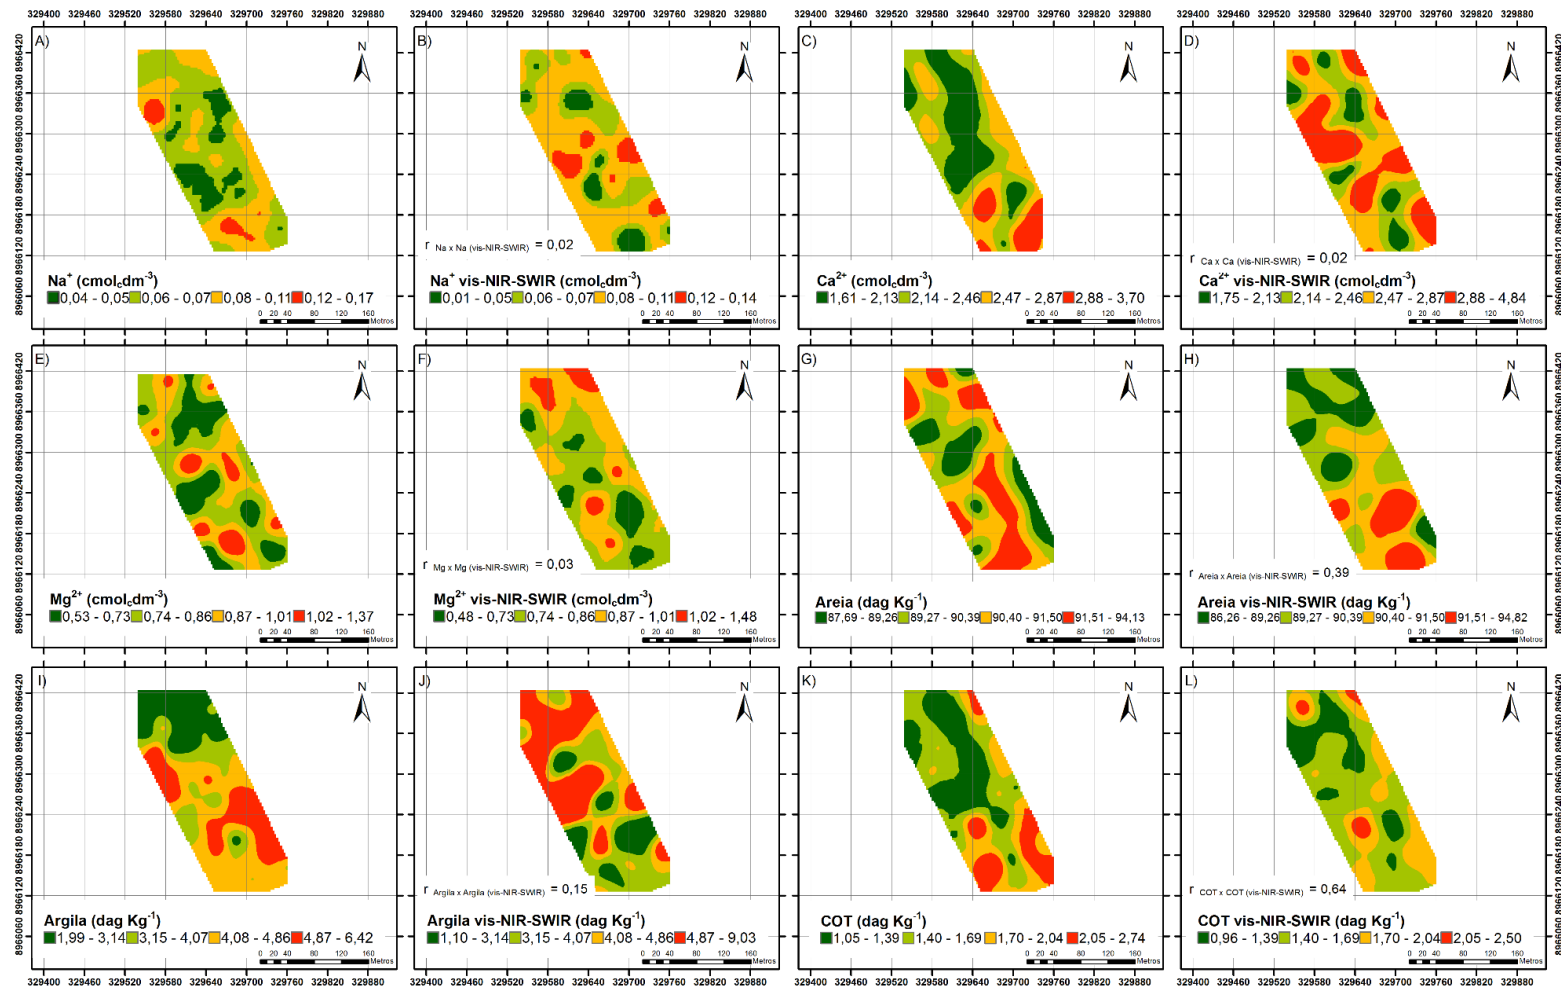
para  $\text{Ca}^{2+}$  na área 2 na camada de 0,20-0,40 m de profundidade (Figura 2.5D). Portanto, os resultados do presente trabalho indicam que a calibração de modelos preditivos para  $\text{Na}^+$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ , areia, argila e COT a partir de dados espectrais Vis-NIR-SWIR podem auxiliar no processo de mapeamento do solo.



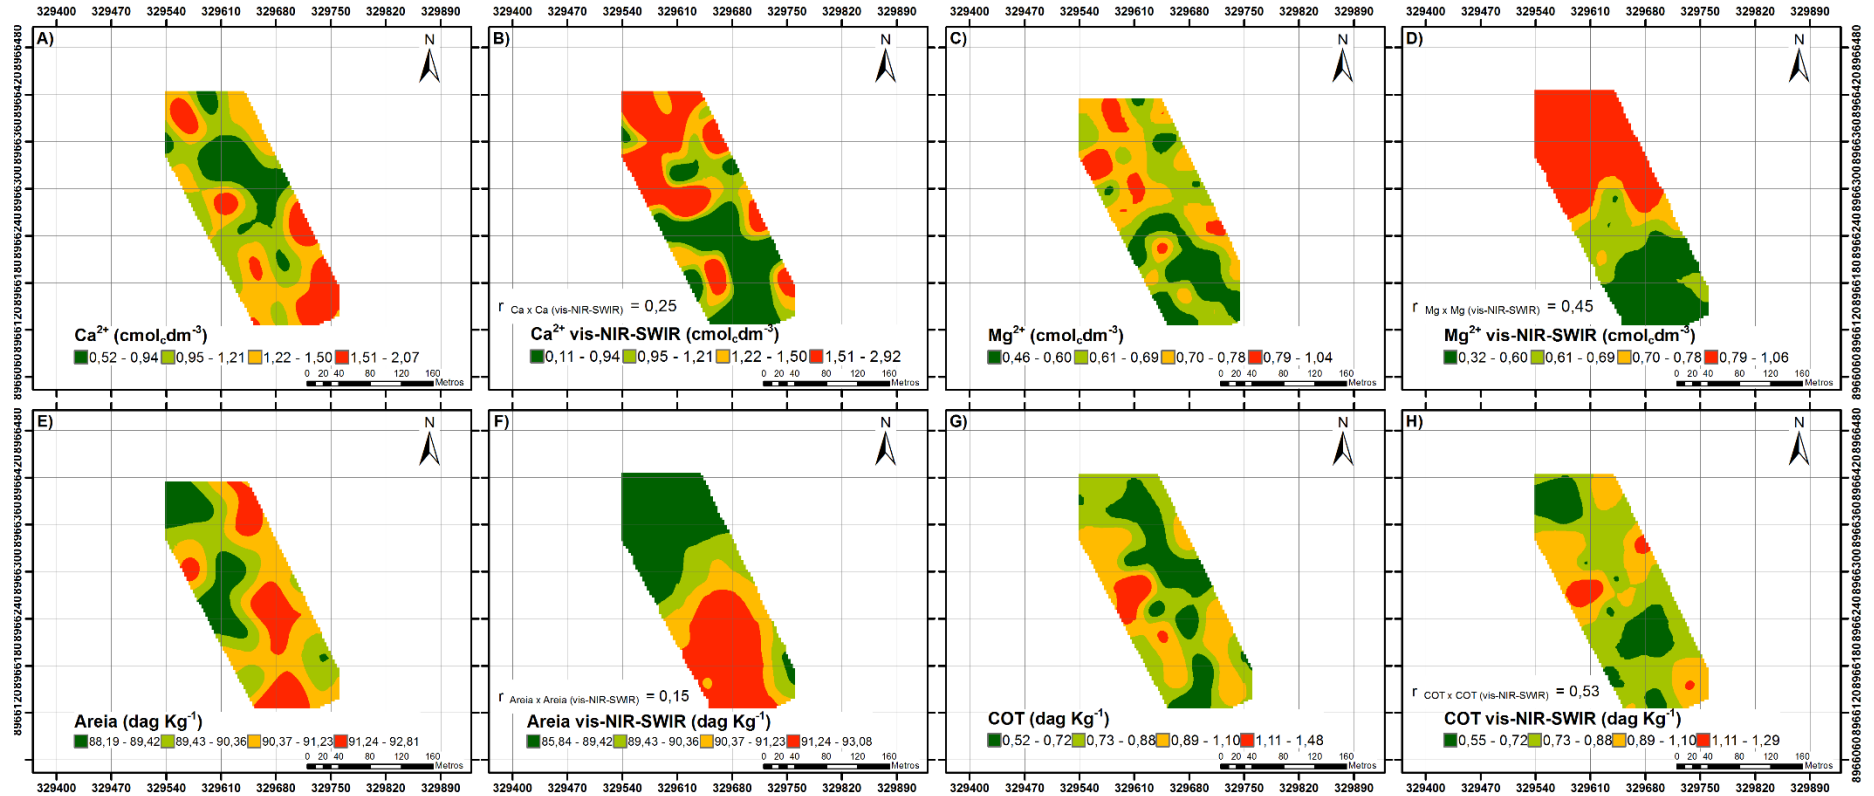
**Figura 2.3.** Mapas interpolados da área 1 da camada de 0,00-0,20 m de profundidade dos atributos (A)  $Ca^{2+}$  de referência; (B)  $Ca^{2+}$  Vis-NIR-SWIR; (C)  $Mg^{2+}$  de referência; (D)  $Mg^{2+}$  Vis-NIR-SWIR; (E) areia de referência; (F) areia Vis-NIR-SWIR; (G) argila de referência; (H) argila Vis-NIR-SWIR; (I) COT de referência; e (J) COT Vis-NIR-SWIR.



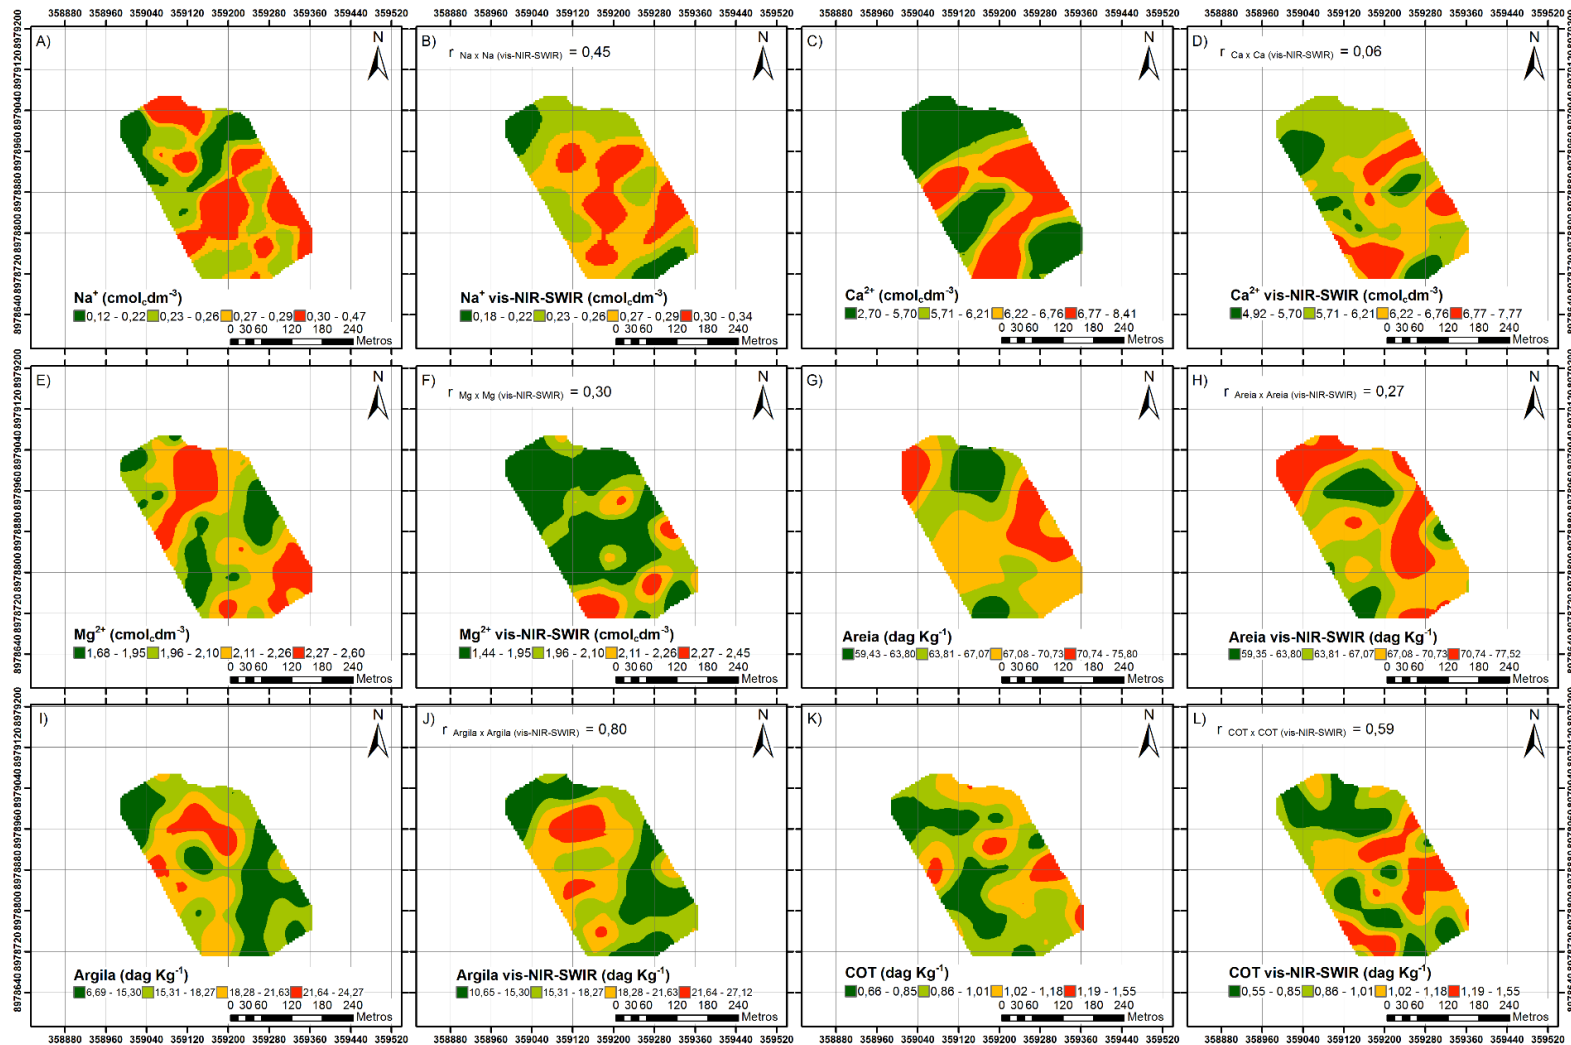
**Figura 2.4.** Mapas interpolados da área 1 da camada de 0,20-0,40 m de profundidade dos atributos (A) Ca<sup>2+</sup> de referência; (B) Ca<sup>2+</sup> Vis-NIR-SWIR; (C) areia de referência; (D) areia Vis-NIR-SWIR; (E) argila de referência; (F) argila Vis-NIR-SWIR; (G) COT de referência; e (H) COT Vis-NIR-SWIR.



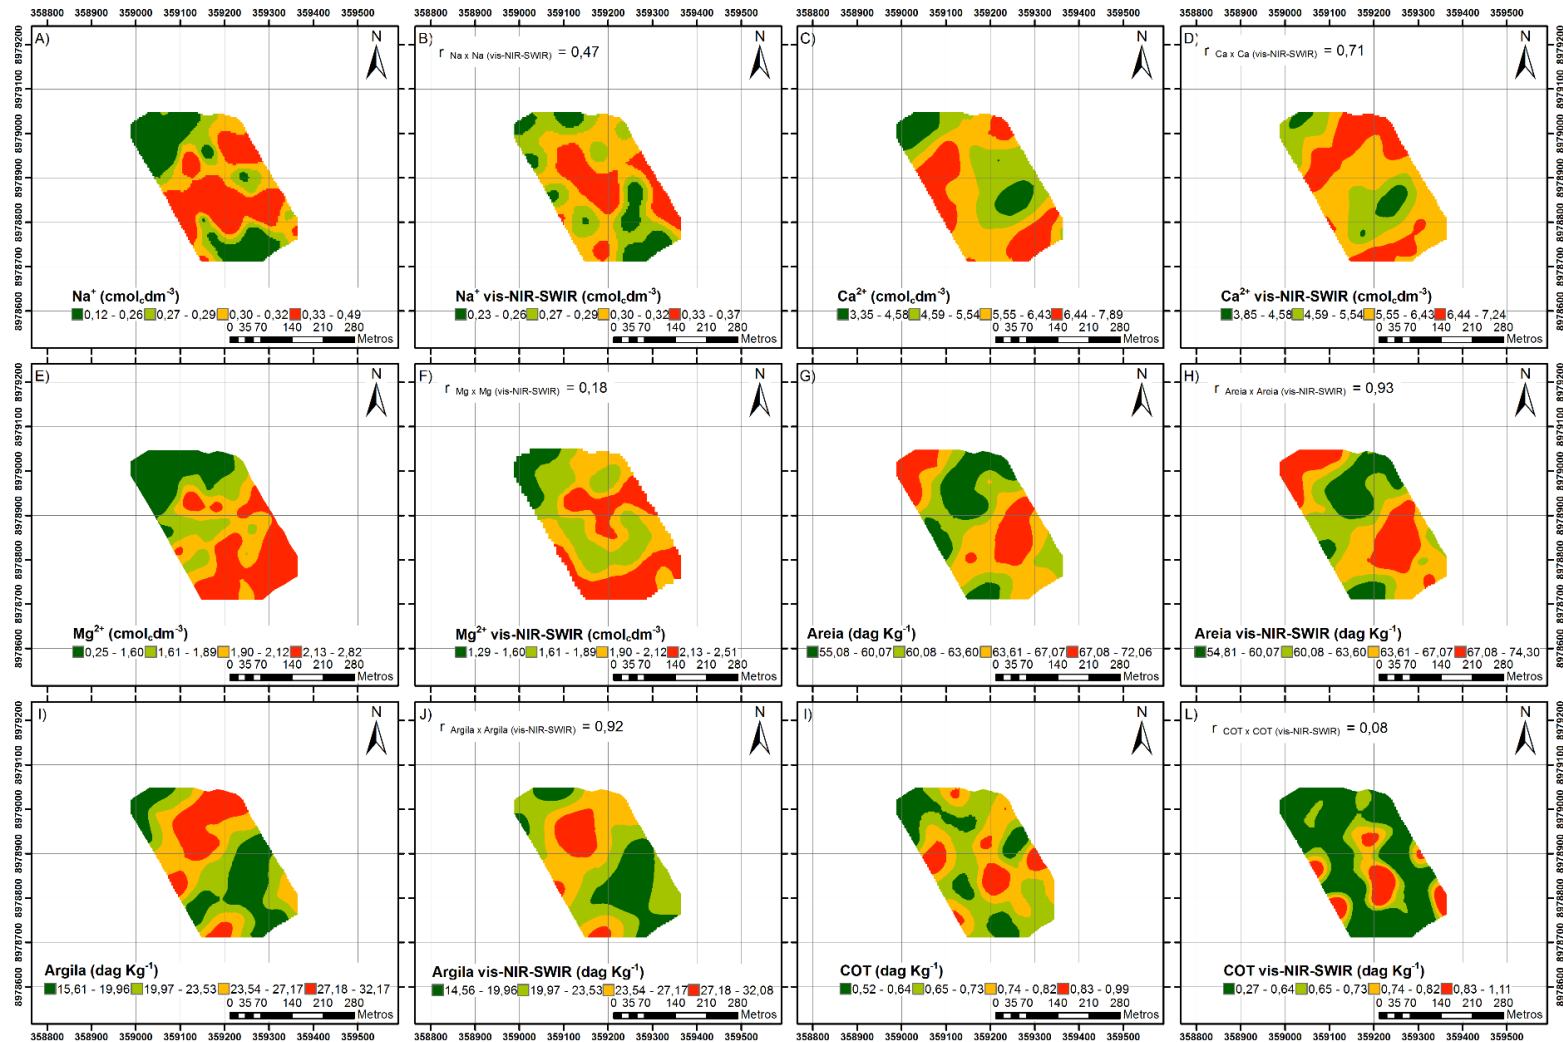
**Figura 2.5.** Mapas interpolados da área 2 da camada de 0,00-0,20 m de profundidade dos atributos (A) Na<sup>+</sup> de referência; (B) Na<sup>+</sup> Vis-NIR-SWIR; (C) Ca<sup>2+</sup> de referência; (D) Ca<sup>2+</sup> Vis-NIR-SWIR; (E) Mg<sup>2+</sup> de referência; (F) Mg<sup>2+</sup> Vis-NIR-SWIR; (G) areia de referência; (H) areia Vis-NIR-SWIR; (I) argila de referência; (J) argila Vis-NIR-SWIR; (K) COT de referência; e (L) COT Vis-NIR-SWIR.



**Figura 2.6.** Mapas interpolados da área 2 da camada de 0,20-0,40 m de profundidade dos atributos (A) Ca<sup>2+</sup> de referência; (B) Ca<sup>2+</sup> Vis-NIR-SWIR; (C) Mg<sup>2+</sup> de referência; (D) Mg<sup>2+</sup> Vis-NIR-SWIR; (E) areia de referência; (F) areia Vis-NIR-SWIR; (G) COT de referência; e (H) COT Vis-NIR-SWIR.



**Figura 2.7.** Mapas interpolados da área 3 da camada de 0,00-0,20 m de profundidade dos atributos (A) Na<sup>+</sup> de referência; (B) Na<sup>+</sup> Vis-NIR-SWIR; (C) Ca<sup>2+</sup> de referência; (D) Ca<sup>2+</sup> Vis-NIR-SWIR; (E) Mg<sup>2+</sup> de referência; (F) Mg<sup>2+</sup> Vis-NIR-SWIR; (G) areia de referência; (H) areia Vis-NIR-SWIR; (I) argila de referência; (J) argila Vis-NIR-SWIR; (K) COT de referência; e (L) COT Vis-NIR-SWIR.



**Figura 2.8.** Mapas interpolados da área 3 da camada de 0,20-0,40 m de profundidade dos atributos (A) Na<sup>+</sup> de referência; (B) Na<sup>+</sup> Vis-NIR-SWIR; (C) Ca<sup>2+</sup> de referência; (D) Ca<sup>2+</sup> Vis-NIR-SWIR; (E) Mg<sup>2+</sup> de referência; (F) Mg<sup>2+</sup> Vis-NIR-SWIR; (G) areia de referência; (H) areia Vis-NIR-SWIR; (I) argila de referência; (J) argila Vis-NIR-SWIR; (K) COT de referência; e (L) COT Vis-NIR-SWIR.

## DISCUSSÃO

### **Análise exploratória dos atributos do solo e do espectro**

Bottega et al. (2013) e Resende et al. (2014) também encontraram alta variação de P em Latossolo Vermelho distroférico no município de Sidrolândia - MS e em Argissolo Amarelo distrocoeso no município de Brejo - MA respectivamente. A alta variabilidade do P está relacionada à forma de aplicação desse fertilizante que, no caso do presente estudo, ocorreu via fertirrigação por meio de microaspersores, sendo, portanto, aplicado de forma localizada na projeção da copa das plantas (KADYAMPAKENI et al., 2016). Isso associado a baixa mobilidade do P no solo contribui para um acúmulo desse nutriente em locais específicos levando a uma distribuição irregular nas áreas (OLIVEIRA et al., 2013).

Outros estudos também encontraram uma menor variação do pH do solo em comparação com os demais atributos físico-químicos do solo (CASTRO et al., 2016; LAEKEMARIAM et al., 2018; SHARMA et al., 2020). A baixa variabilidade do pH ocorre devido aos valores de pH serem a escala logarítmica da concentração de prótons na solução do solo, de forma que essa variabilidade seria maior se a acidez do solo fosse expressa em termos de concentração de prótons diretamente (REZA et al., 2017; MOHARANA et al., 2020).

A normalidade dos dados não é uma exigência da geoestatística (HUO et al., 2012). Na geoestatística, mais importante que uma distribuição normal, é que a condição básica de suposição estacionária seja atendida, isto é, que os semivariogramas apresentem patamares bem definidos, permitindo assim aceitar a hipótese intrínseca (ISAAKS & SRIVASTAVA, 1989). Bodaghabadi (2018) ao comparar a interpolação de atributos do solo de dados normalizados e não normalizados, verificou que os mapas resultantes apresentaram pequenas diferenças e que a precisão das estimativas foi superior para os dados originais. Assim, optou-se pela não transformação dos dados no presente trabalho.

Embora as amostras tenham sido coletadas em áreas relativamente pequenas, os atributos físico-químicos do solo apresentaram uma amplitude considerável, de modo que os valores médios não representam adequadamente a variabilidade espacial dos atributos do solo (MARQUES JR. et al., 2014). Essa alta variabilidade é um indicativo de que um manejo agrícola uniforme pode levar a uma aplicação



adequada de insumos em alguns locais enquanto em outros a aplicação será sub ou superdimensionada (BOGUNOVI et al., 2017).

O aumento de refletância na região do visível (350-700 nm) é característico do quartzo, presente em solos com predominância de textura arenosa, pois reflete grande quantidade de energia (DEMATTÊ et al., 2014). As curvas espectrais das camadas de 0,00-0,20 m de profundidade apresentaram menor intensidade de refletancia em comparação com as curvas espectrais das camadas de 0,20-0,40 m de profundidade na região entre 400 e 1000 nm, isso devido aos maiores teores de matéria orgânica na camada mais superficial. A matéria orgânica absorve energia nessa faixa espectral (CONFORTI et al., 2015).

Nas curvas espectrais das áreas 1 e 2, os espectros das camadas de 0,00-0,20 e 0,20-0,40 m de profundidade mantêm um paralelismo, indicando pouca diferença entre os teores de argila. Contudo, na área 3, os espectros das duas camadas avaliadas se cruzam, apontando a existência de gradiente textural em profundidade (DEMATTÊ et al., 2014).

A existência de picos absorptivos em 1400 e 2200 nm estão associadas à flexão e ao alongamento das ligações O – H, absorção das ligações Al – OH do mineral de argila, e moléculas orgânicas (CH<sub>2</sub>, CH<sub>3</sub> e NH<sub>3</sub>) (LIU et al., 2019). Também, a existência de pico absorptivo em 2300 nm está associado a existência de ligações C – H presentes na matéria orgânica (ZHOU et al., 2014). Portanto, as curvas espectrais contêm feições específicas tornando possível extrair informações relevantes acerca das propriedades dos solos.

### **Modelos quimiométricos**

A correção do sinal ortogonal (OSC) foi o pré-processamento que proporcionou os melhores resultados para a predição dos atributos avaliados. A técnica OSC se baseia na eliminação da variação que não está relacionada à variável de interesse que se espera estimar sem, contudo, eliminar as informações essenciais. Isso é feito por meio da omissão de informações matematicamente ortogonais à resposta, ou o mais próximo possível da ortogonal (BINEY et al., 2020). Ademais, a redução do número de fatores do modelo PLSR proporcionada pela aplicação do pré-processamento OSC leva a uma simplificação do modelo (BALCEROWSKA et al., 2005). O OSC vem sendo utilizado em dados espectrais de algumas áreas do

conhecimento como, por exemplo, em avaliações pós-colheita de frutas (WANG et al., 2017; HEMRATTRAKUN et al., 2020; SOUZA et al., 2022), análises de alimentos (CAPUANO et al., 2014; BILGE et al., 2016) e avaliações farmacológicas (WANG et al., 2015; NAGUIB e DARWISH, 2016). Entretanto, sua aplicação na ciência do solo ainda tem sido limitada.

Biney et al. (2021) avaliaram diferentes pré-processamentos para o ajuste de modelos matemáticos para a quantificação de COT, verificando que o OSC se sobressaiu aos demais em termos de desempenho preditivo dos modelos gerados. No presente trabalho, verificou-se a eficiência do OSC no pré-processamento dos dados de vários atributos do solo, antes da calibração dos modelos de regressão.

Os atributos do solo foram estimados com maior desempenho na faixa do NIR-SWIR. Viscarra Rossel et al. (2006) e Wetterlind et al. (2008) também verificaram que previsões de atributos físico-químicos do solo usando a faixa espectral do Vis, geralmente, são menos precisas. O pH não possui respostas espectrais diretas nos espectros Vis-NIR-SWIR, sendo a determinação realizada indiretamente, devido a sua relação com os comprimentos de onda dos minerais do solo e matéria orgânica (WENJUN et al., 2014). O desempenho das previsões para CE é frequentemente específico para tipos de solo e ambientes particulares e depende das relações desses fatores com compostos infravermelhos ativos, como matéria orgânica e argila (SORIANO-DISLA, et al., 2014; ZOVKO et al., 2018).

Os teores de  $K^+$  não apresentam resposta direta nos espectros Vis-NIR-SWIR, sendo a predição devido à presença de correlações com a matéria orgânica e argilominerais (TERRA et al., 2015). A concentração de  $K^+$  trocável no solo é relativamente baixa, em comparação com  $Ca^{2+}$  e  $Mg^{2+}$ , de modo que o efeito do  $K^+$  no espectro do solo pode ser suprimido pelas características espectrais do  $Ca^{2+}$  e  $Mg^{2+}$ . Os teores de  $Ca^{2+}$  e  $Mg^{2+}$  também não possuem relação direta com os espectros Vis-NIR-SWIR, mas apresentam boa capacidade preditiva devido à presença desses nutrientes em carbonatos e minerais argilosos, além da sua relação com a matéria orgânica, que são espectralmente ativos (SORIANO-DISLA, et al., 2014).

Os teores de  $Na^+$  não apresentam relação espectral direta, de modo que a determinação é realizada indiretamente por meio das informações espectrais relacionadas à matéria orgânica e aos argilominerais (MOUAZEN et al., 2010). Para os teores de  $Al^{3+}$ , resultado semelhante foi obtido por Viscarra Rossel et al. (2006). Os teores de P não possuem relação espectral direta, mesmo assim se ligam aos

oxihidróxidos de ferro e alumínio, e estes por sua vez, possuem uma relação espectral direta (CAMARGO et al., 2015; TERRA et al., 2015). Coutinho et al. (2019) também observaram resultados insatisfatórios na predição de P com espectroscopia Vis-NIR-SWIR em solos arenosos no município de Campinas, estado de São Paulo, Brasil.

Os teores de COT foram determinados com desempenho adequado ( $R^2 = 0,85$ ). A matéria orgânica do solo, expressa em COT, é constituída por grupos funcionais como hidroxilas (OH), carboxilas (COOH) e aminas (NH<sub>2</sub>). Essas moléculas apresentam resposta espectral direta, possibilitando a determinação da matéria orgânica por espectroscopia Vis-NIR-SWIR (NING et al., 2019). Além disso, a matéria orgânica fornece cargas negativas que podem ser neutralizadas por cátions como Mg<sup>2+</sup>, Ca<sup>2+</sup> e K<sup>+</sup>, de modo que as respostas espectrais desses elementos trocáveis estão relacionadas à matéria orgânica (DEMATTE et al., 2017).

Os teores de areia e argila foram determinados com bons desempenhos ( $R^2 = 0,93$  e  $0,89$ , respectivamente). Os grupos hidroxila presentes na estrutura dos argilominerais, a água higroscópica que é mantida dentro de estruturas de minerais de argila, e os minerais caulinita, ilita, esmectita e carbonatos, possuem resposta espectral direta, permitindo a determinação dos teores de argila com boa precisão (STEMBERG et al., 2010). O quartzo, principal constituinte da areia, induz um aumento da intensidade de refletância, de modo que as curvas espectrais de solos arenosos apresentam maior intensidade que os solos argilosos, o que possibilita a determinação da areia por espectroscopia Vis-NIR-SWIR (LACERDA et al., 2016).

### **Modelos geoestatísticos**

O efeito pepita puro (EPP), observado para alguns dos atributos do solo, indica aleatoriedade dos dados desses atributos nas áreas avaliadas, o que significa que os valores das amostras existiram em seus locais por acaso sem qualquer padrão de distribuição descritível e, portanto, sem nenhuma correlação espacial entre elas para as distâncias amostrais escolhidas no experimento (AKIŞ et al., 2014). O EPP pode ocorrer devido a erros de medição e amostragem ou em virtude de pequenas variações existentes em uma distância menor do que a distância amostral e, portanto, não detectadas (ABDEL RAHMAN et al., 2021).

Os atributos determinados pelos métodos convencionais, areia na área 1 (camada de 0,00-0,20 m de profundidade), argila na área 2 (camada de 0,00-0,20 m

de profundidade) e argila na área 3 (camada de 0,20-0,40 m de profundidade), apresentaram os maiores alcances nas suas respectivas áreas, o que mostra uma maior continuidade espacial desses atributos (AKIŞ et al., 2014). Rodrigues et al. (2012) também encontraram maiores valores de alcance para os atributos referentes a textura do solo. Isso ocorre devido a textura estar mais relacionada aos processos pedogenéticos de formação do solo, o que a torna um atributo muito estável, sendo menos influenciada pelo manejo agrícola advindo de atividades antrópicas (RODRIGUES et al., 2019). O alcance representa a distância a partir da qual os atributos se tornam totalmente independentes no espaço (MAZELLA e MAZELLA, 2013) de modo que o valor de uma variável não influencia os valores vizinhos (REZA et al., 2015). Assim, os valores de alcance podem auxiliar na definição do procedimento amostral.

Verifica-se que a área 2 apresentou as correlações mais baixas para os atributos do solo. Das três áreas avaliadas, a área 2 possui os maiores teores de areia (90,50 e 90,27 dag kg<sup>-1</sup> para as camadas de 0,00-0,20 e 0,20-0,40 m de profundidade respectivamente). Neste sentido, Stenberg et al. (2002) e Sørensen e Dalsgaard (2005) observaram que modelos ajustados com espectroscopia Vis-NIR-SWIR apresentam melhores precisões para solos com menores teores de areia.

### **Considerações práticas do uso da espectroscopia VIS-NIR-SWIR na agricultura de precisão**

Os resultados do presente trabalho indicam que a calibração de modelos matemáticos preditivos para Na<sup>+</sup>, Ca<sup>2+</sup>, Mg<sup>2+</sup>, areia, argila e COT a partir de dados espectrais Vis-NIR-SWIR podem auxiliar no processo de mapeamento desses atributos do solo. Portanto, a existência de correlações entre os valores medidos pelos métodos de referência e o método espectroscopia Vis-NIR-SWIR pode ser uma importante ferramenta na adoção das técnicas de agricultura de precisão.

A calibração de modelos preditivos com espectroscopia Vis-NIR-SWIR pode diminuir a quantidade de análises laboratoriais necessárias para o mapeamento dos atributos físico-químicos do solo, ao mesmo tempo que permite um aumento de amostras analisadas pelo sensor, reduzindo dessa forma os custos do mapeamento e aumentando a qualidade dos mapas por possibilitar uma maior densidade amostral (RODRIGUES et al., 2019).

Os mapas dos atributos do solo permitem a delimitação de zonas de manejo, que são unidades agrícolas dentro das quais pode-se adotar as mesmas práticas agronômicas, como adubação e irrigação, de forma mais eficiente (SOUZA et al., 2021). Um manejo nutricional correto é essencial tanto para uma alta produtividade da mangueira, como para a produção de frutos com qualidade (LIU et al., 2021). Considerando a adequada correlação entre os valores de  $\text{Ca}^{2+}$  determinados pelos métodos convencionais e pelo método de espectroscopia Vis-NIR-SWIR, o uso do Vis-NIR-SWIR mostra-se de grande importância para o manejo deste nutriente, principalmente porque o  $\text{Ca}^{2+}$  é um dos nutrientes mais importantes para a cultura da mangueira. Níveis adequados de  $\text{Ca}^{2+}$  evitam o aparecimento de desordens fisiológicas nos frutos após a colheita, como o colapso interno (SINGH et al., 2013; SILVA et al., 2014).

Os mapas de textura do solo permitem a realização de um manejo específico da irrigação por mostrarem os locais dentro da área mapeada que apresentam maior e menor capacidade de retenção de água (FORTES et al., 2015). Essa é uma informação de grande relevância para o manejo da cultura da mangueira na região do Vale do São Francisco, pois uma prática muito importante que auxilia na indução do florescimento da mangueira, é o estresse hídrico (FARIA et al., 2016 a). Assim, o mapeamento da composição granulométrica permite o controle adequado da lâmina de irrigação. Além disso, os mapas de textura fornecem informações para a adoção de um manejo racional da irrigação, o que tem se tornado uma necessidade cada vez maior considerando-se a água como um recurso natural não-renovável cada vez mais escasso (SUN et al., 2017).

Além da relevância do COT para a fertilidade do solo, esse atributo também influencia nas mudanças climáticas, pois o solo constitui um importante ecossistema de sequestro do  $\text{CO}_2$  atmosférico (JANDL et al., 2014). Para um programa global de monitoramento do carbono do solo, é essencial estimar os estoques de COT para relatórios de emissão de gases de efeito estufa, o que não é uma tarefa simples, principalmente considerando-se grandes escalas (ANGELOPOULOU et al., 2020). Assim, os modelos preditivos de COT a partir de espectros Vis-NIR-SWIR surgem como uma alternativa que viabiliza um acompanhamento frequente das reservas de carbono do solo. Ademais, o conhecimento do estoque de COT nas áreas cultivadas com mangueira é fundamental, tendo em vista que devido ao predomínio de solos

arenosos na região semiárida brasileira, a reposição e incremento de matéria orgânica é essencial em áreas de fruticultura.

A espectroscopia Vis-NIR-SWIR também reduz os impactos ambientais decorrentes da agricultura de precisão, pela diminuição do número de análises de solo, o que implica em um menor consumo de reagentes, e conseqüentemente, menor quantidade de resíduos gerados, pois as análises de solo por métodos convencionais envolvem o uso de reagentes como hidróxido de sódio, ácido sulfúrico, ácido clorídrico e dicromato (DEMATTÊ et al., 2019).

## CONCLUSÕES

A região espectral do SWIR é sensível aos teores de  $\text{Na}^+$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ , areia, argila e COT em Latossolo e Argissolo cultivados com mangueira na região semiárida brasileira. Assim, a predição dos teores de  $\text{Na}^+$ ,  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  é moderada ( $0,70 > R^2 > 0,65$ ), enquanto a predição dos teores de areia, argila e COT é forte ( $R^2 > 0,85$ ), com uso da espectroscopia Vis-NIR-SWIR (350 a 2500 nm).

A geoestatística permitiu verificar que a maioria dos atributos do solo apresentou dependência espacial nas áreas avaliadas, não sendo, portanto, viável a adoção de práticas agrícolas com base em valores médios.

A espectroscopia Vis-NIR-SWIR captura a variação e a dependência espacial dos atributos físico-químicos do solo, aperfeiçoando a qualidade do mapeamento e reduzindo as análises laboratoriais. Portanto, a espectroscopia Vis-NIR-SWIR é uma ferramenta complementar no processo de mapeamento dos teores de  $\text{Na}^+$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ , areia, argila e COT em solos cultivados com mangueira na região semiárida brasileira.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABDELRAHMAN, M. A. E.; ZAKARYA, Y. M.; METWALY, M. M.; KOUBOURIS, G. Deciphering soil spatial variability through geostatistics and interpolation techniques. **Sustainability**, v. 13, n. 194, p. 1-13, 2021.
- ANGELOPOULOU, T.; BALAFOUTIS, A.; ZALIDIS, G.; BOCHTIS, D. From Laboratory to Proximal Sensing Spectroscopy for Soil Organic Carbon Estimation – A Review. **Sustainability**, v. 12, n. 443, p. 1-24, 2020.
- AKIŞ, R. Spatial variability of soil solute and saturated hydraulic conductivity affected by undrained water table conditions. **Precision Agriculture**, v. 16, n. 3, p. 330-359, 2014.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; MORAES, G.; LEONARDO, J.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

ARÉTOUYAP, Z.; NOUCK, P. M.; NOUAYOU, R.; KEMGANG, F. E. G.; TOKO, A. D. P.; ASFAHANI, J. Lessening the adverse effect of the semivariogram model selection on an interpolative survey using kriging technique. **Springer Plus**, v. 5, p. 549-559, 2016.

BALCEROWSKA, G.; SIUDA, R.; CZARNIK-MATUSEWICZ, H. Orthogonal signal correction to PLS modelling in application to spectral data. **Acta Agrophysica**, v. 6, n. 1, p. 7-18, 2005.

BARNES, R. J.; DHANOA, M. S.; LISTER, S. J. Standard normal variate transformation and detrending of near-infrared diffuse reflectance spectra, **Applied Spectroscopy**, v. 43, n. 5, p. 772-777, 1989.

BILGE, G.; VELIOGLU, H. M.; SEZER, B.; ESELLER, K. E.; BOYACI, I. H. Identification of meat species by using laser-induced breakdown spectroscopy. **Meat Science**, v. 119, p. 118-122, 2016.

BINEY, J. K. M.; BORUVKA, J.; AGYEMAN, P. C.; NEMECEK, K.; KLEMENT, A. Comparison of field and laboratory wet soil spectra in the Vis-NIR range for soil organic carbon prediction in the absence of laboratory dry measurements. **Remote Sensing**, v. 12, p. 1-16, 2020. doi:10.3390/rs12183082

BINEY, J. K. M.; BLOCHER, J. R.; BORUVKA, L.; VASÁT, R. Does the limited use of orthogonal signal correction pre-treatment approach to improve the prediction accuracy of soil organic carbon need attention? **Geoderma**, v. 388, p. 1-3, 2021.

BODAGHABADI, M. B. Is it necessarily a normally distributed data for kriging? A case study: soil salinity map of Ghahab area, central Iran. **Desert**, v. 23, n. 2, p. 285-294, 2018.

BOGUNOVIC, I.; TREVISANI, S.; SEPUT, M.; JUZBASIC, D.; DURDEVIC, B. Short-range and regional spatial variability of soil chemical properties in an agro-ecosystem in eastern Croatia. **Catena**, v. 154, p. 50-62, 2017.

BOTTEGA, E. L.; QUEIROZ, D. M.; PINTO, F. A. C.; SOUZA, C. M. A. Variabilidade espacial de atributos do solo em sistema de semeadura direta com rotação de culturas no cerrado brasileiro. **Revista Ciência Agronômica**, v. 44, n. 1, p. 1-9, 2013.

BOWERS, S. A.; HANKS, R. J. Reflection of radiant energy from soils. **Soil Science**, v. 100, n. 2, p. 130-138, 1965.

CAMARGO, L. A.; MARQUES, J.; BARRÓN, V.; ALLEONI, L. R. F.; BARBOSA, R. S.; PEREIRA, G. T. Mapping of clay, iron oxide and adsorbed phosphate in oxisols using diffuse reflectance spectroscopy. **Geoderma**, v. 251-252, p. 124-132, 2015.

CAPUANO, E.; RADEMAKER, J.; BIJGAART, H.; RUTH, S. M. Verification of fresh grass feeding, pasture grazing and organic farming by FTIR spectroscopy analysis of bovine milk. **Food Research International**, v. 60, p. 59-65, 2014.

CASTRO, D. B.; PEDROSA, E. M. R.; MONTENEGRO, A. A. A.; ROLIM, M. M.; LEITÃO, D. A. H. S.; OLIVEIRA, A. K. S. Spatial variability of Regosol chemical

attributes in guava management with neem under semi-arid conditions. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 7, p. 618-624, 2016.

CEZAR, E.; NANNIA, M. F.; GUERRERO, C.; SILVA JUNIOR, C. A.; CRUCIOL, L. G. T.; CHICATIA, M. L.; SILVA, G. F. C. Organic matter and sand estimates by spectroradiometry: Strategies for the development of models with applicability at a local scale. **Geoderma**, v. 340, p. 224-233, 2019.

CONFORTI, M.; CASTRIGNANÒ, A.; ROBUSTELLI, G.; SCARCIGLIA, F.; STELLUTI, M.; BUTTAFUOCO, G. Laboratory-based Vis–NIR spectroscopy and partial least square regression with spatially correlated errors for predicting spatial variation of soil organic matter content. **Catena**, v. 124, p. 60-67, 2015.

COUTINHO, M. A. N.; ALARI, F. O.; FERREIRA, M. M. C.; AMARAL, L. R. Influence of soil sample preparation on the quantification of NPK content via spectroscopy. **Geoderma**, v. 338, p. 401-409, 2019.

DEMATTE, J. A. M.; BELINASSO, H.; ROMERO, D. J.; FONGARO, C. T. Morphological interpretation of reflectance spectrum (MIRS) using libraries looking towards soil classification. **Scientia Agrícola**, v. 71, n. 6, p. 509-520, 2014.

DEMATTE, J. A. M.; RAMIREZ-LOPEZ, L.; MARQUES, K.P.P.; RODELLA, A. A. Chemometric soil analysis on the determination of specific bands for the detection of magnesium and potassium by spectroscopy. **Geoderma**, v. 288, p. 8-22, 2017.

DEMATTE, J. A. M.; DOTTO, A. C.; BEDIN, L. C.; SAYÃO, V. M.; SOUZA, A. B. Soil analytical quality control by traditional and spectroscopy techniques: Constructing the future of a hybrid laboratory for low environmental impact. **Geoderma**, v. 337, p. 111-121 2019.

FAO-Food and Agriculture Organization of the United Nations. 2020. FAOSTAT, Disponível em: <http://www.fao.org/faostat/en/#home>. Acesso em: 25/10/21.

FARIA, L. N.; SOARES, A. A.; DONATO, S. L. R.; SANTOS, M. R.; CASTRO, L. G. The effects of irrigation management on floral induction of 'Tommy Atkins' mango in Bahia semiarid. **Engenharia Agrícola**, v. 36, n. 3, p. 387-398, 2016 a.

FARIA, L. N.; DONATO, S. L. R.; SANTOS, M. R.; CASTRO, L. G. Nutrient contents in 'Tommy Atkins' mango leaves at flowering and fruiting stages. **Journal of the Brazilian Association of Agricultural Engineering**, v. 36, n. 6, p. 1073-1085, 2016 b.

FORTES, R.; MILLÁN, S.; PRIETO, M. H.; CAMPILLO, C. A methodology based on apparent electrical conductivity and guided soil samples to improve irrigation zoning. **Precision Agriculture**, v. 16, n. 4, p. 441-454, 2015.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, p. 1-17, 1986.

GÓMEZ, A. H.; HE, Y.; PEREIRA, A. G. Non-destructive measurement of acidity, soluble solids and firmness of Satsuma mandarin using Vis/NIR-spectroscopy techniques. **Journal of Food Engineering**, v. 77, n. 2, p. 313-319, 2006.

GORRY, P. A. General least-square smoothing and differentiation by the convolution (Savitzky-Golay) method. **Analytical Chemistry**, v. 62, n. 6, p. 570-573, 1990.



HEMRATTRAKUN, P.; NAKANO, K.; BOONYAKIAT, D.; OHASHI, S.; MANIWARA, P.; THEANJUMPOL, P.; SEEHANAM, P. Comparison of reflectance and interactance modes of Visible and Near-Infrared spectroscopy for predicting persimmon fruit quality. **Food Analytical Methods**, v. 14, n. 1, p. 117–126, 2020.

HU, W.; SHU, X.; JIA, X.; HUANG, B. Geostatistical analysis of intelligent compaction measurements for asphalt pavement compaction. **Automation in Construction**, v. 89, p. 162-169, 2018.

HUO, X.; LI, H.; SUN, D.; ZHOU, L.; LI, B. Combining geostatistics with moran's i analysis for mapping soil heavy metals in Beijing, China. **International Journal of Environmental Research and Public Health**, v. 9, p. 995-1017, 2012.

INMPE, Instituto Nacional de Meteorologia. **Dados climáticos: estação meteorológica de Petrolina**, 2017. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/inmet/?mRelE>, Acesso em 30 out. 2021.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. New York: Oxford University, 1989. 561p.

ISAKSSON, T.; NAES, T. The effect of multiplicative scatter correction (MSC) and linearity improvement in NIR spectroscopy. **Applied Spectroscopy**, v. 42, n. 7, p. 1273-1284, 1998.

JANDL, R.; RODEGHIERO, M.; MARTINEZ, C.; COTRUFO, M. F.; BAMPÀ, F.; WESEMAEL, B.; HARRISON, R. B.; GUERRINI, I. A.; RICHTER JR, D. B.; RUSTAD, L.; LORENZ, K.; CHABBI, A.; MIGLIETTA, F. Current status, uncertainty and future needs in soil organic carbon monitoring. **Science of the Total Environment**, v. 468, p. 376-383, 2014.

KADYAMPAKENI, D. M.; MORGAN, K. T.; SCHUMANN, A. W. Citrus fertigation and irrigation practices for managing HLB in Florida. **Florida State Horticultural Society**, v. 129, p. 64-68, 2016.

KENNARD, R. W.; STONE, L. A. Computer aided design of experiments. **Technometrics**, v. 11, n. 1, p. 137-148, 1969.

KIST, B. B.; SANTOS, C. E.; CARVALHO, C.; BELING, R. R. Anuário brasileiro de Horti&Fruti 2021. Santa Cruz do Sul: **Gazeta Santa Cruz**, 104 p. 2021.

KNADEL, M.; THOMSEN, A.; SCHELDE, K.; GREVE, M. H. Soil organic carbon and particle sizes mapping using vis–NIR, EC and temperature mobile sensor platform. **Computers and Electronics in Agriculture**, v. 114, p. 134-144, 2015.

KODAIRA, M.; SHIBUSAWA, S. Using a mobile real-time soil visible-near infrared sensor for high resolution soil property mapping. **Geoderma**, v. 199, p. 64–79, 2013.

LACERDA, M. P. C.; DEMATTÊ, J. A. M.; SATO, M. V.; FONGARO, C. T.; GALLO, B. C.; SOUZA, A. B. Tropical Texture Determination by Proximal Sensing Using a Regional Spectral Library and Its Relationship with Soil Classification, **Remote Sensing**, v. 701, n. 8, p. 1-20, 2016.

LAEKEMARIAM, F.; KIBRET, K.; MAMO, T.; SHIFERAW, H. Accounting spatial variability of soil properties and mapping fertilizer types using geostatistics in Southern

Ethiopia. **Communications in Soil Science and Plant Analysis**, v. 49, n. 1, p. 124-137, 2018.

LIMA, T. M.; WEINDORF, D. C.; CURI, N.; GUILHERME, L. R. G.; LANA, R. M. Q.; RIBEIRO, B. T. Elemental analysis of Cerrado agricultural soils via portable X-ray fluorescence spectrometry: Inferences for soil fertility assessment. **Geoderma**, v. 353, p. 264–272, 2019.

LIU, S.; SHEN, H.; CHEN, S.; ZHAO, X.; BISWAS, A.; JIA, X.; SHI, Z.; FANG, J. Estimating forest soil organic carbon content using vis-NIR spectroscopy: Implications for large-scale soil carbon spectroscopic assessment. **Geoderma**, v. 348, p. 37-44, 2019.

LU, P.; WANG, L.; NIU, Z.; LI, L.; ZHANG, W. Prediction of soil properties using laboratory VIS–NIR spectroscopy and Hyperion imagery. **Journal of Geochemical Exploration**, v. 132, p. 26-33, 2013.

MARQUES JR., J.; SIQUEIRA, D. S.; CAMARGO, L. A.; TEIXEIRA, D. D. B.; BARRÓN, V.; TORRENT, J. Magnetic susceptibility and diffuse reflectance spectroscopy to characterize the spatial variability of soil properties in a Brazilian Haplustalf. **Geoderma**, v. 219–220, p. 63-71, 2014.

MAZZELLA, A.; MAZZELLA A. The Importance of the model choice for experimental semivariogram modeling and its consequence in evaluation process. **Journal of Engineering**, v. 2013, p. 1-10, 2013.

MOHARANA, P. C.; JENA, R. K.; PRADHAN, U. K.; NOGIYA, M.; TAILOR, B. L.; SINGH, R. S.; SINGH, S. K. Geostatistical and fuzzy clustering approach for delineation of site-specific management zones and yield-limiting factors in irrigated hot arid environment of India. **Precision Agriculture**, v. 21, p 426-448, 2020.

MOORE, D. S.; KIRKLAND, S. **The basic practice of statistics**. New York: WH Freeman, v. 2, 2007.

MOUAZEN, A. M.; KUANG, B.; BAERDEMAEKER, J. D.; RAMON, H. Comparison among principal component, partial least squares and back propagation neural network analyses for accuracy of measurement of selected soil properties with visible and near infrared spectroscopy. **Geoderma**, v. 158, p. 23-31, 2010.

MUKHERJEE, S.; LASKAR, S. Vis–NIR-based optical sensor system for estimation of primary nutrients in soil. **Journal of Optics**, v. 48, n. 1, p. 87-103, 2019.

NAGUIB, I. A.; DARWISH, H. W. Determination of cefoperazone sodium in presence of related impurities by improved classical least squares chemometric methods: A comparative study. **Journal of Chemistry**, p. 1-8, 2016.

NING, J.; SHENG, M.; YI, X.; WANG, Y.; HOU, Z.; ZHANG, Z.; GU, X. Rapid evaluation of soil fertility in tea plantation based on near-infrared spectroscopy, **Spectroscopy Letters**, p. 1-9, 2019.

NOCITA, M.; STEVENS A.; NOON C.; WESEMAEL B. Prediction of soil organic carbon for different levels of soil moisture using Vis-NIR spectroscopy. **Geoderma**, v. 199, p. 37-42, 2013.

OLIVEIRA, I. R.; TEIXEIRA, D. B.; ALAN RODRIGO PANOSSO, A. R. CAMARGO, L. A.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Modelagem geoestatística das incertezas da distribuição espacial do fósforo disponível no solo, em área de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, v. 37, p. 1481-1491, 2013.

OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **Catena**, v. 113, n. 0, p. 56-69, 2014.

RESENDE, J. M. A.; MARQUES JÚNIOR, J.; MARTINS FILHO, M. V.; DANTAS, J. S.; SIQUEIRA, D. S.; TEIXEIRA, D. B. Variabilidade espacial de atributos de solos coesos do leste maranhense. **Revista Brasileira de Ciência do Solo**, v. 38, p. 1077-1090, 2014.

REZA, S. K.; NAYAK, D. C.; CHATTOPADHYAY, T.; MUKHOPADHYAY, S.; SINGH, S. K.; SRINIVASAN, R. Spatial distribution of soil physical properties of alluvial soils: a geostatistical approach. **Archives of Agronomy and Soil Science**, v. 62, n. 7, p. 972-981, 2015.

REZA, S. K.; NAYAK, D. C.; MUKHOPADHYAY, S.; CHATTOPADHYAY, T.; SINGH, S. K. Characterizing spatial variability of soil properties in alluvial soils of India using geostatistics and geographical information system. **Archives of Agronomy and Soil Science**, v. 63, n. 11, p. 1489-1498, 2017.

RODRIGUES, M. S.; CORÁ, J. E.; FERNANDES, C. Spatial relationships between soil attributes and corn yield in no-tillage system. **Revista Brasileira de Ciência do Solo**, v. 36, p. 599-609, 2012.

RODRIGUES, M. S.; SANTANA, M. C.; UCHOA, A. L. P.; MENEZES, A. X. S. M.; CAVALCANTE, I. H. L.; LIMA, A. M. N.; Delineation of management zones based on soil physical attributes in an irrigated guava field in the Semi-Arid region, Brazil. **African Journal of Agricultural Research**, v. 10, n. 45, p. 4185-4192, 2015.

RODRIGUES, M. S.; ALVES, D. C.; CUNHA, J. C.; LIMA, A. M. N.; CAVALCANTE, Í. H. L.; SILVA, K. A.; MELO JUNIOR, J. C. F. Spatial analysis of soil salinity in a mango irrigated area in semi-arid climate region. **Australian Journal Crop Science**, v. 12, n. 08 p. 1288-1296, 2018.

RODRIGUES, M. S.; ALVES, D. C.; CUNHA, J. C.; MELO JÚNIOR, J. C. F.; LIMA, A. M. N.; LIRA, A. L. F.; MOREIRA, F. B. R.; SILVA, K. A. Soil mapping quality for site-specific management in fruit fields in the semiarid region of Brazil. **Ciencia del Suelo**, v. 37, n. 2, p. 328-337, 2019.

SAVITZKY, A.; GOLAY, M. J. E.; Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SEIDEL, E. J.; OLIVEIRA, M. S. D. A Classification for a geostatistical index of spatial dependence. **Revista Brasileira de Ciência do Solo**, v. 40, n. 1, p. 1-10, 2016.

SHARMA, R.; SOOD, K. Characterization of spatial variability of soil parameters in apple orchards of Himalayan region using geostatistical analysis. **Communications in Soil Science and Plant Analysis**, p. 1-13, 2020.

SILVA, K. A.; RODRIGUES, M. S.; MOREIRA, F. B. R.; LIRA, A. L. F.; LIMA, A. M. N.; CAVALCANTE, I. H. L. Soil sampling optimization using spatial analysis in irrigated

mango fields under brazilian semi-arid conditions. **Revista Brasileira de Fruticultura**, v. 42, n. 5, p. 1-18, 2020.

SORIANO-DISLA, J. M.; JANIK, L. J.; ROSSEL, R. 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**, v. 49, p. 139-186, 2014.

SØRENSEN, L. K., DALSGAARD, S. Determination of clay and other soil properties by near infrared spectroscopy. **Soil Science Society of America Journal**, v. 69, p. 159-167, 2005.

SOUZA, E. R. D.; MELO, H. F. D.; ALMEIDA, B. G. D.; MELO, D. V. M. D. Comparação de métodos de extração da solução do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 5, p. 510-517, 2013.

SOUZA, P.; RODRIGUES, M.; SILVA, K.; MOREIRA, F.; SILVA, A.; LIMA, A. Geoestatística multivariada para o delineamento de zonas de manejo para a alocação de experimentos agrícola. **Revista de Ciências Agrárias**, v. 44, n. 2-3, p. 101-113, 2021.

SOUZA, P. A.; FERREIRA, I. J. S.; COSTA, D. S. Determination of quality attributes and ripening stage using vis-nir spectroscopy in intact seriguela and umbu fruits. **Revista Engenharia na Agricultura**, v. 30, p. 127-141, 2022.

STENBERG, B., JONSSON, A., BÖRJESSON, T. Near infrared technology for soil analysis with implications for precision agriculture. In A. Davies & R. Cho (Eds.), *Near Infrared Spectroscopy: Proceedings of the 10th International Conference*, Kyongju S. Korea. **NIR Publications**, Chichester, UK, p. 279-284, 2002.

STONER, E. R.; BAUMGARDNER, M. F. Characteristic variations in reflectance of surface soils. **Soil Science Society of America Proceedings**, v. 45, n. 6, p. 1161-1165, 1981.

SUN, H.; WANG, S.; HAO, X. An Improved Analytic Hierarchy Process Method for the evaluation of agricultural water management in irrigation districts of north China. **Agricultural Water Management**, v. 179, p. 324-337, 2017.

TEIXEIRA, P. C.; DONAGEMMA, G. G.; FONTANA, A.; TEIXEIRA, W. G. **Manual de métodos de análise de solos**. 3.ed. Brasília: Embrapa, 2017. 573 p.

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**, v. 255-256, p. 81-93, 2015.

VAŠÁT, R.; KODEŠOVÁ, R.; BORŮVKA, L.; KLEMENT, A.; JAKŠÍK, O.; GHOLIZADEH, A. Consideration of peak parameters derived from continuum-removed spectra to predict extractable nutrients in soils with visible and near-infrared diffuse reflectance spectroscopy (VNIR-DRS). **Geoderma**, v. 232-234, p. 208-218, 2014.

VIEIRA, S. R.; CARVALHO, J. R. P.; CEDDIA, M. B.; GONZÁLEZ, A. P. Detrending non stationary data for geostatistical applications. **Bragantia**, v. 69, p. 1-8, 2010.

VISCARRA ROSSEL, R. A.; WALVOORT, D. J. J.; MCBRATNEY, A. B.; JANIK, L. J.; SKJEMSTAD, J. O. Visible, near infrared, mid infrared or combined diffuse reflectance

spectroscopy for simultaneous assessment of various soil properties. **Geoderma**, v. 131, n. 1–2, p. 59-75, 2006.

VISCARRA ROSSEL, R. A. .; BEHRENS, T.; BEN-DOR, E.; BROWN, D. J.; DEMATTÉ, J.A.M.; SHEPHERD, K.D.; SHI, Z.; STENBERG, B.; STEVENS, A.; ADAMCHUK, V.; AICHI, H.; BARTHÈS, B.G.; BARTHOLOMEUS, H. M.; BAYER, A. D.; BERNOUX, M.; BÖTTCHER, K.; BRODSKÝ, L.; DU, C.W.; CHAPPELL, A.; FOUAD, Y.; GENOT, V.; GOMEZ, C.; GRUNWALD, S.; GUBLER, A.; GUERRERO, C.; HEDLEY, C. B.; KNADEL, M.; MORRÁS, H.J.M.; NOCITA, M.; RAMIREZ-LOPEZ, L.; ROUDIER, P.; CAMPOS, E. M. R.; SANBORN, P.; SELBITTO, V. M.; SUDDUTH, K. A.; RAWLINS, B. G.; WALTER, C.; WINOWIECKI, L. A.; HONG, S. Y.; JI, W. A global spectral library to characterize the world's soil. **Earth-Science Reviews**, v. 155, p. 198-230, 2016.

WANG, T.; IBRAHIM, A.; POTTS, A. R.; HOAG, S. W. Application of multivariate strategies to the classification of pharmaceutical excipient manufacturers based on near-infrared (NIR) spectra. **Applied Spectroscopy**, v. 69, n. 11, p. 1257-1270, 2015.

WANG, J.; WANG, J.; CHEN, Z.; HAN, D. Development of multi-cultivar models for predicting the soluble solid content and firmness of European pear (*Pyrus communis* L.) using portable vis–NIR spectroscopy. **Postharvest Biology and Technology**, v. 129, p. 143-151, 2017.

WARRICK, A. W; NIELSEN, D. R. Spatial variability of soil physical properties in the field. In: Hillel, D. (ed.). **Applications of soil physics**. New York: Academic Press, p.319-344, 1980.

WETTERLIND, J.; STENBERG, B.; SÖDERSTRÖM, M. The use of near infrared (NIR) spectroscopy to improve soil mapping at the farm scale. **Precision Agriculture**, v. 9, n. 1-2, p. 57-69, 2008. doi:10.1007/s11119-007-9051-z

WENJUN, J.; ZHOU, S.; JINGYI, H.; SHUO, L. In situ measurement of some soil properties in paddy soil using visible and near-infrared spectroscopy. **Plos one**, v. 9, n. 8, p. 1-11, 2014.

WOLD, S.; RUHE, A.; WOLD, H. The collinearity problem in linear regression. The partial least square (PLS) approach to generalized inverses. **SIAM Journal on Scientific Computing**, v. 5, n. 3, p. 735–743, 1984.

YEOMANS, J. C.; BREMNER, J. M. A rapid and precise method for routine determination of organic carbon in soil. **Communications in Soil Science and Plant Analysis**, v. 19, n. 13, p.1467-1476, 1988.

ZOVKO, C. M.; ROMIĆ, D.; COLOMBO, C.; IORIO, E. D.; ROMIĆ, M.; BUTTAFUOCO, G.; CASTRIGNANÒ, A. A geostatistical Vis-NIR spectroscopy index to assess the incipient soil salinization in the Neretva River valley. **Geoderma**, v. 332, p. 60-72, 2018.

ZŮVALA, R.; FIŠEROVÁ, E.; MAREK, L. Mathematical aspects of the kriging applied on landslide in Halenkovice (Czech Republic). **Open Geosciences**, v. 8, n. 1, p. 275-288, 2016.

### CAPÍTULO 3

## ESPECTROSCOPIA VIS-NIR-SWIR NA AVALIAÇÃO DO ESTADO NUTRICIONAL DE MANGUEIRA IRRIGADA NO SEMIÁRIDO BRASILEIRO<sup>2</sup>

### RESUMO

A análise foliar é um importante instrumento que auxilia no manejo de adubação das culturas agrícolas. Entretanto, a demora e o alto custo dos métodos convencionais dificultam a sua realização. Nesse sentido, a espectroscopia vis-NIR-SWIR (visível - infravermelho - infravermelho de ondas curtas) surge como uma ferramenta de análise mais rápida, de menor custo e sem grandes impactos ambientais. Assim, objetivou-se com este estudo quantificar macro e micronutrientes foliares na cultura da mangueira cv. 'Tommy Atkins' cultivada sob irrigação no semiárido brasileiro com uso da espectroscopia vis-NIR-SWIR. Foram utilizadas 159 amostras de folhas de mangueira cv. 'Tommy Atkins' provenientes de três áreas comerciais distintas. Para essas amostras obteve-se os espectros de refletância para uma faixa espectral de 350 a 2500 nm e determinou-se os teores de N, P, K, Ca, Mg, B, Zn, Fe, Mn e Cu pelos métodos de referência. Os dados espectrais foram inicialmente submetidos a técnicas de pré-processamento de suavização, derivação e correção. Em seguida, foram desenvolvidos modelos de Regressão dos Mínimos Quadrados Parciais (PLSR) utilizando o espectro completo (350-2500 nm) e regiões espectrais específicas no Vis (350-700 nm), NIR (701-1100 nm) e SWIR (1101-2500 nm). Também foram desenvolvidos modelos de Regressão Linear Múltipla (MLR) a partir de uma seleção de variáveis espectrais. Para todos os modelos calibrados realizou-se a validação cruzada e para os modelos com melhor desempenho, realizou-se a validação externa. Os modelos regressivos tiveram desempenho preditivo forte para P e Ca ( $R^2 > 0,70$ ), moderado para N e Zn ( $0,50 < R^2 < 0,70$ ), fraco para Fe ( $0,30 < R^2 < 0,50$ ) e muito fraco para K, Mg, B, Cu e Mn ( $R^2 < 0,30$ ). Portanto, a espectroscopia vis-NIR-SWIR é uma ferramenta potencial complementar para quantificar os teores destes nutrientes em mangueira cv. 'Tommy Atkins'.

**Palavras-chave:** Fruticultura; Macronutrientes; *Mangifera indica* L.; Micronutrientes; Sensoriamento proximal.

### VIS-NIR-SWIR SPECTROSCOPY IN THE ASSESSMENT OF NUTRITIONAL STATUS OF IRRIGATED MANGO IN THE BRAZILIAN SEMIARID REGION

### ABSTRACT

Leaf analysis is an important tool that helps in the management of fertilization of agricultural crops. However, the delay and high cost of conventional methods make it difficult to perform. In this sense, vis-NIR-SWIR spectroscopy (visible - infrared - shortwave infrared) emerges as a faster and cheaper analysis tool, without major environmental impacts. Thus, the objective of this study was to quantify leaf macro and

---

<sup>2</sup> Artigo a ser submetido para publicação

micronutrients in mango cv. 'Tommy Atkins' cultivated under irrigation in the Brazilian semiarid region using vis-NIR-SWIR spectroscopy. 159 samples of cv. 'Tommy Atkins' mango leaves from three different commercial areas were used. For these samples, reflectance spectra were obtained for a spectral range from 350 to 2500 nm and the contents of N, P, K, Ca, Mg, B, Zn, Fe, Mn and Cu were determined by the reference methods. The spectral data were initially submitted to smoothing, derivation and correction pre-processing techniques. Then, Partial Least Squares Regression (PLSR) models were developed using the full spectrum (350-2500 nm) and specific spectral regions in Vis (350-700 nm), NIR (701-1100 nm), and SWIR (1101 -2500 nm). Multiple Linear Regression (MLR) models were also developed from a selection of spectral variables. For all calibrated models, cross-validation was carried out and for the models with the best performance, external validation was carried out. Regressive models had strong predictive performance for P and Ca ( $R^2 > 0.70$ ), moderate for N and Zn ( $0.50 < R^2 < 0.70$ ), weak for Fe ( $0.30 < R^2 < 0.50$ ) and very weak for K, Mg, B, Cu and Mn ( $R^2 < 0.30$ ). Therefore, vis-NIR-SWIR spectroscopy is a potential complementary tool to quantify the levels of these nutrients in mango cv. 'Tommy Atkins'.

**Keywords:** Fruit growing; macronutrients; *Mangifera indica* L.; micronutrients; Proximal sensing.

## INTRODUÇÃO

A mangueira (*Mangifera indica* L.) está entre as principais espécies de frutíferas tropicais cultivadas no Brasil. O país é o terceiro maior exportador mundial de manga (FAO, 2020) e esta por sua vez, é uma das frutas de maior valor agregado das exportações brasileiras. Nesse contexto, ressalta-se que a região do Vale do São Francisco é responsável pela produção de quase toda a manga exportada pelo Brasil (KIST et al., 2021).

A cultura da mangueira possui uma alta demanda nutricional ao longo de seu ciclo produtivo, de modo que a prática da adubação é essencial para a obtenção de altos rendimentos dos frutos (SARKER e RAHIM, 2012). Considerando que a análise foliar complementa a análise de solo, a caracterização do estado nutricional das plantas é muito relevante, e nessa perspectiva, a análise de nutrientes foliares é uma importante ferramenta para otimizar o processo de fertilização (COMINO et al., 2018).

Entretanto, um monitoramento da nutrição mineral vegetal no desenvolvimento de frutos pode exigir uma série de análises químicas complexas de um grande número de amostras foliares, o que é um trabalho muito demorado, oneroso e, obviamente, com um impacto ambiental negativo devido à produção de produtos químicos nocivos durante as técnicas de análise (GALVEZ-SOLA et al., 2015).

Nesse sentido, o uso do sensoriamento proximal, com a espectroscopia vis-NIR-SWIR (visible - near infrared - short-wave infrared), pode auxiliar na avaliação do

programa de adubação por ser um método mais rápido, econômico e limpo de analisar as características estruturais e morfológicas das folhas. Ademais, devido à facilidade de aquisição e processamento de dados, permite sua aplicação em áreas que adotam os conceitos da Agricultura de Precisão (AP), tendo vista o grande número de amostras demandadas nesse tipo de sistema (RODRIGUES et al., 2020).

Estudos têm demonstrado resultados promissores do uso de espectroscopia vis-NIR-SWIR na análise de constituintes celulares vegetais como clorofila, umidade e pigmentos (STEIDLE NETO et al., 2017; WANG, et al., 2018; LIU et al., 2019) e de nutrientes minerais foliares em culturas anuais e perenes (YANLI et al., 2015; RODRIGUES et al., 2020; JIN et al., 2022). Contudo, poucos estudos foram relatados a respeito da determinação quantitativa da concentração de macro e micronutrientes foliares na cultura da mangueira (MAHAJAN et al., 2021), principalmente em condições semiáridas.

A hipótese deste estudo é que os teores de nutrientes foliares da mangueira cv. 'Tommy Atkins' apresentam correlação com os espectros do sensor Vis-NIR-SWIR, permitindo sua quantificação de forma mais rápida e com menor custo, e, portanto, viabilizando um monitoramento dos níveis nutricionais da cultura.

Portanto, o objetivo deste trabalho foi quantificar macro e micronutrientes foliares na cultura da mangueira irrigada cv. 'Tommy Atkins' no semiárido brasileiro com uso da espectroscopia vis-NIR-SWIR.

## **MATERIAL E MÉTODOS**

### **Descrição da área de estudo e coleta de dados**

As amostras de folha foram provenientes de três áreas comerciais cultivadas com mangueira irrigada cv. 'Tommy Atkins', localizadas nos municípios de Petrolina-PE e Juazeiro-BA, na região do Vale do Submédio São Francisco, semiárido brasileiro (Tabela 3.1). O clima da região, segundo classificação de Köppen e Geiger, é do tipo BSh – semiárido quente. A temperatura média é 32,7 °C com máxima de 36,7 °C e mínima 18,4 °C, a umidade relativa média é de 56,7%, a precipitação média anual é de 373,3 mm distribuídos em quatro a cinco meses durante o ano (ALVARES et al., 2013).



**Tabela 3.1.** Localização, relevo, solo, área, idade e espaçamento da cultura, irrigação e adubação das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas com mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

|                        | Área 1  | Área 2  | Área 3  |
|------------------------|---|---|---|
| Localização            | Fazenda Barreiro de Santa Fé, Petrolina, Pernambuco (9°23'39,37" S e 40°44'32,91" W)                                    | Fazenda Mandacaru, Petrolina, Pernambuco (9°20'50,58" S e 40°33'04,51" W)   | Fazenda Sempre Verde, Juazeiro, Bahia (9°14'59,38" S e 40°16'5840" W)   |
| Relevo                 | Plano   | Plano   | Plano   |
| Solo                   | Latossolo   | Argissolo   | Argissolo   |
| Área                   | 9 ha (797 x 114 m)  | 4,5 ha (353 x 125 m)  | 9,5 ha (411 x 232 m)  |
| Idade da cultura       | 25 anos   | 26 anos   | 25 anos   |
| Espaçamento da cultura | 8 x 5 m   | 8 x 5 m   | 7 x 5 m   |
| Irrigação              | Localizada por microaspersão (2 microaspersores/planta) Via fertirrigação para N, P e K e aplicação manual para Ca e Mg | Localizada por microaspersão (2 microaspersores/planta) Via fertirrigação para N, P e K e aplicação manual para Ca e Mg | Localizada por microaspersão (2 microaspersores/planta) Via fertirrigação para N, P e K e aplicação manual para Ca e Mg |

As amostras de folha foram coletadas na forma de malhas amostrais regulares após a colheita (antes da aplicação de insumos) nas áreas das fazendas Barreiro de Santa Fé, Mandacaru e Sempre Verde respectivamente, totalizando 159 amostras. Coletou-se folhas nos quatro quadrantes e na altura do terço médio do dossel das plantas, sendo coletadas duas folhas por quadrante dos últimos fluxos vegetativos (GENÚ e PINTO, 2002).

### **Análises de referência e estatística descritiva**

As amostras de folha foram lavadas rapidamente com água destilada, sendo em seguida colocadas em sacos de papel e levadas a uma estufa com circulação de ar forçado a 60 °C até atingirem peso constante. Depois foram trituradas em moinho de facas de aço inoxidável (tipo Willey) obtendo-se partículas de 0,85 mm de diâmetro. As amostras de folha foram submetidas à digestão úmida com ácido sulfúrico para a determinação dos teores de N (via destilação de Kjeldahl) e com solução nitro-perclórica para a determinação dos teores de P (via espectrofotometria UV-Vis), K (via fotometria de chama), Ca, Mg, Fe, Zn, Cu, B e Mn (via espectrometria de absorção atômica), conforme Silva (2009).

Os dados de referência foram submetidos à análise descritiva (médias, valores máximos, mínimos, desvio padrão e coeficiente de variação (CV)) e suas distribuições foram testadas quanto à normalidade por meio do teste Shapiro-Wilk a 5% de probabilidade. O CV foi classificado segundo Pimentel-Gomes e Garcia (2002) como baixo ( $CV \leq 10\%$ ), médio ( $10\% < CV \leq 20\%$ ), alto ( $20\% < CV \leq 30\%$ ) e muito alto ( $CV > 30\%$ ). Também se utilizou a classificação proposta por Quaggio (1996) (Tabela 3.2) para a interpretação dos teores nutricionais foliares médios.

**Tabela 3.2.** Teores adequados de nutrientes foliares para a cultura da mangueira na fase de floração plena.

| Nutrientes                 | Faixas de teores adequados |
|----------------------------|----------------------------|
| N ( $\text{g kg}^{-1}$ )   | 12,0 a 14,0                |
| P ( $\text{g kg}^{-1}$ )   | 0,8 a 1,6                  |
| K ( $\text{g kg}^{-1}$ )   | 5,0 a 10,0                 |
| Ca ( $\text{g kg}^{-1}$ )  | 20,0 a 35,0                |
| Mg ( $\text{g kg}^{-1}$ )  | 2,5 a 5,0                  |
| B ( $\text{mg kg}^{-1}$ )  | 50 a 100                   |
| Zn ( $\text{mg kg}^{-1}$ ) | 20 a 40                    |
| Fe ( $\text{mg kg}^{-1}$ ) | 50 a 200                   |
| Cu ( $\text{mg kg}^{-1}$ ) | 10 a 50                    |
| Mn ( $\text{mg kg}^{-1}$ ) | 50 a 100                   |

nd = não definido. Fonte: Quaggio (1996).

### Aquisição dos dados espectrais

Para a obtenção dos dados espectrais, foram utilizados 10 cm<sup>3</sup> das amostras de folhas secas e moídas (ROTBART et al., 2013). Os espectros de reflectância das amostras foram adquiridos por: (1) um espectrorradiômetro FieldSpec 3 (*Analytical Spectral Devices*, Boulder, Colorado, USA) que possui sensor óptico com campo de visão 8°, faixa espectral de 350 a 2500 nm, resolução de 8 nm, e precisão de  $\pm 1$  nm; (2) fonte de luz halogêneo-tungstênio-quartzo com 50 W; (3) câmara escura com dimensões 100 x 50 x 50 cm; e (4) computador com *software* RS3 (*Analytical Spectral Devices*, Boulder, Colorado, EUA). O sensor de fibra óptica foi posicionado perpendicularmente ao plano de medição, com altura de 7,0 cm, e as amostras de solo foram colocadas no centro do referido plano.

Utilizou-se como referência branca uma placa cerâmica Spectralon (*Labsphere Inc.*, North Sutton, NH, EUA), com a qual as operações de calibração foram realizadas

antes da aquisição dos dados. Cada espectro de cada amostra de folha foi composto por uma média de 30 varreduras realizadas pelo equipamento. Obteve-se os valores de refletância, os quais foram utilizados para a construção das curvas espectrais médias das amostras de folha. Posteriormente, os valores de refletância foram transformados em medidas de absorbância ( $\log(1/R)$ ), onde R significa refletância, utilizando o *software* ViewSpec Pro (*Analytic Spectral Devices*, Boulder, Colorado, EUA). Os dados de absorbância foram usados para a construção dos modelos preditivos.

### **Análises quimiométricas**

Para a realização das análises quimiométricas, utilizou-se o *software* Unscrambler X 10.4 (CAMO ASA, Oslo, Noruega). Inicialmente, os dados espectrais foram submetidos a diferentes combinações de pré-processamentos. Aplicou-se aos dados espectrais suavização com filtro da média móvel (FMM) em vários tamanhos de segmento (7, 15, 25 e 35 pontos). Sobre os dados suavizados, foram aplicadas a primeira e segunda derivada de Savitzky-Golay (GORRY, 1990; SAVITZKY e GOLAY, 1964) com polinômio de segunda ordem e vários tamanhos de segmento (7, 15, 25 e 35 pontos). Sobre os dados suavizados e/ou derivadas, foram aplicadas a correção multiplicativa de espalhamento (MSC) (ISAKSSON e NAES, 1988), a transformação de variável normal padrão (SNV) (BARNES et al., 1989), e a correção ortogonal do sinal (OSC) (WOLD et al., 1984).

O desenvolvimento dos modelos preditivos para a determinação dos nutrientes foliares foi realizado com a regressão de mínimos quadrados parciais (PLSR). O conjunto de dados foi dividido utilizando o algoritmo Kennard-Stone (KENNARD e STONE, 1969), sendo 212 amostras para calibração e validação cruzada, e 106 amostras para validação externa. Foram utilizados os dados espectrais pré-processados, como variáveis preditoras (X), e os teores dos diferentes nutrientes foliares, como variáveis resposta (Y). Também, os dados espectrais foram divididos por regiões, sendo modelados para região Vis (visível: 350-700 nm), região NIR (infravermelho próximo: 701-1100 nm), região SWIR (infravermelho de ondas curtas: 1101-2500 nm), e região Vis-NIR-SWIR (350-2500 nm). Foi utilizado o algoritmo NIPALS (GELADI e KOWALSKI, 1986) com 100 iterações.

A fim de resolver os problemas de colinearidade da matriz de dados e permitir o desenvolvimento de modelos preditivos com a regressão linear múltipla (MLR), foi realizada uma seleção de variáveis dos comprimentos de onda a partir da análise gráfica dos pesos das variáveis espectrais dos nutrientes foliares nos modelos PLSR. Esses comprimentos de onda selecionados foram utilizados como variáveis preditoras para os modelos MLR. Após a construção dos modelos MLR, as variáveis selecionadas foram submetidas a uma análise de variância (ANOVA) e os modelos foram reconstruídos com as variáveis significativas ( $p$ -valor < 0,05).

O desempenho dos modelos foi avaliado a partir dos parâmetros estatísticos: coeficiente de determinação ( $R^2$ ); raiz quadrada média do erro de calibração (RMSEC); erro padrão de calibração (SEC); raiz quadrada média do erro de validação cruzada (RMSECV); erro padrão de validação cruzada (SECV); raiz quadrada média do erro de predição (RMSEP); erro padrão da predição (SEP); e viés. Esses parâmetros são definidos pelas seguintes equações:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{(n-1)\sigma_r\sigma_p} \quad (\text{Equação 3.1})$$

$$RMSEC = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (\text{Equação 3.2})$$

$$SEC = \sqrt{\frac{n RMSEC^2}{n-1}} \quad (\text{Equação 3.3})$$

$$RMSECV = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_{i*})^2}{n}} \quad (\text{Equação 3.4})$$

$$SECV = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i - bias)^2}{n-1}} \quad (\text{Equação 3.5})$$

$$RMSEP = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{m}} \quad (\text{Equação 3.6})$$

$$SEP = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i - bias)^2}{m-1}} \quad (\text{Equação 3.7})$$

$$viés = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{m} \quad (\text{Equação 3.8})$$

Onde  $\hat{y}_i$  é o valor estimado pelo modelo de calibração;  $\hat{y}_{i*}$  é o valor estimado pelo modelo na etapa de validação cruzada;  $y_i$  é o valor de referência;  $\bar{y}$  é a média dos valores de referência;  $\bar{\hat{y}}$  é a média dos valores previstos;  $n$  é o número de amostras nas etapas de calibração ou validação;  $m$  é o número de amostras previstas;  $\sigma_r$  é o

desvio padrão dos valores de referência;  $\sigma_p$  é o desvio padrão dos valores previstos; e  $S_r^2$  é a variação dos valores de referência.

Comparou-se o desempenho dos modelos PLSR e MLR e selecionou-se para a predição dos nutrientes foliares àqueles que apresentaram, simultaneamente, menores valores de erro padrão e maiores valores de coeficiente de determinação de calibração e validação cruzada (GÓMEZ et al., 2006). Para os modelos selecionados, realizou-se a validação externa. Por fim, utilizou-se a classificação proposta por Moore e Kirkland (2007) em termos de forte ( $R^2 > 0,70$ ), moderado ( $0,50 < R^2 < 0,70$ ), fraco ( $0,30 < R^2 < 0,50$ ) e muito fraco ( $R^2 < 0,30$ ).

## **RESULTADOS**

### **Análise exploratória dos nutrientes foliares e do espectro**

Na Tabela 3.3, encontra-se a estatística descritiva dos teores de nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' provenientes das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde. Os maiores teores foliares foram encontrados para o Ca nas três áreas avaliadas.

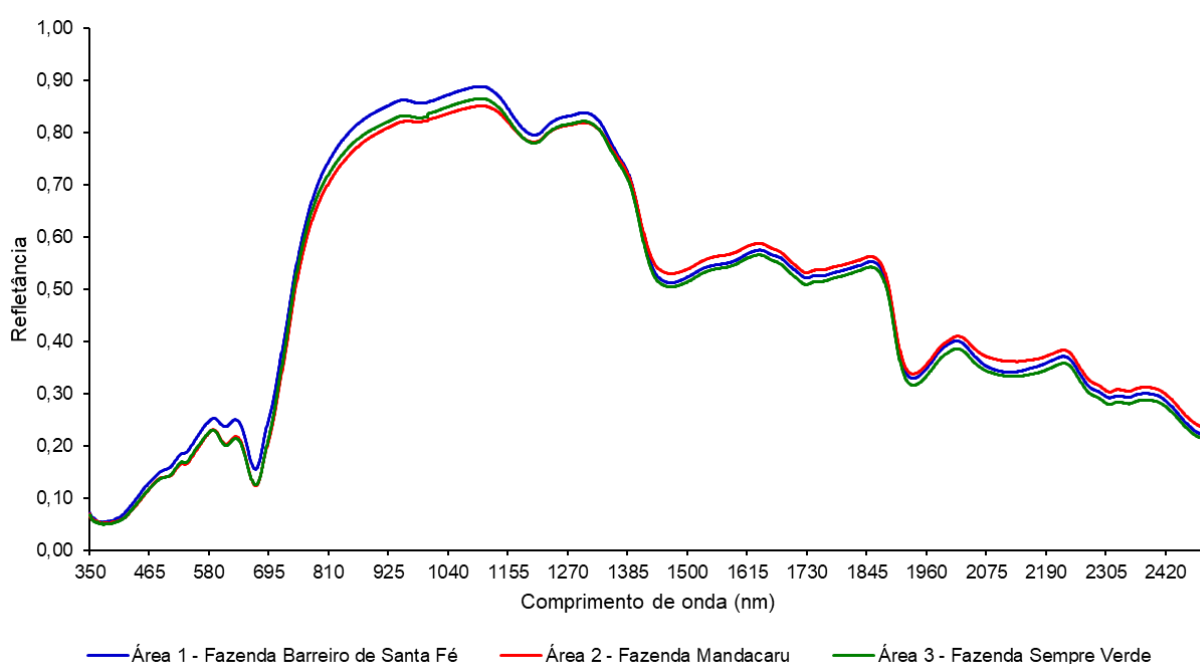
A partir dos valores de coeficiente de variação (CV), é possível verificar que os nutrientes foliares nas três áreas apresentaram variabilidade de média a muito alta, segundo Pimentel-Gomes e Garcia (2002). A presença de variação nos valores de referência permite o desenvolvimento de modelos preditivos estáveis, amplamente aplicáveis e altamente robustos (SOUZA et al., 2022).

**Tabela 3.3.** Análise descritiva dos teores de nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' das áreas Barreiro de Santa Fé, Mandacaru e Sempre Verde cultivadas na região semiárida brasileira

| Nutrientes                            | -----g kg <sup>-1</sup> ----- |      |       |        |      | -----mg kg <sup>-1</sup> ----- |       |        |       |        |
|---------------------------------------|-------------------------------|------|-------|--------|------|--------------------------------|-------|--------|-------|--------|
|                                       | N                             | P    | K     | Ca     | Mg   | B                              | Zn    | Fe     | Cu    | Mn     |
| Área 1 – Fazenda Barreiro de Santa Fé |                               |      |       |        |      |                                |       |        |       |        |
| Média                                 | 7,82                          | 1,14 | 9,00  | 41,55  | 2,26 | 88,03                          | 29,90 | 51,89  | 1,07  | 188,09 |
| Máximo                                | 11,10                         | 1,62 | 27,48 | 73,85  | 5,92 | 162,52                         | 62,77 | 168,41 | 5,21  | 348,26 |
| Mínimo                                | 3,22                          | 0,74 | 2,25  | 23,06  | 1,55 | 50,23                          | 14,10 | 18,27  | 0,00  | 70,59  |
| CV (%)                                | 19                            | 19   | 65    | 41     | 30   | 33                             | 34    | 49     | 110   | 31     |
| Classificação do CV                   | M                             | M    | MA    | MA     | A    | MA                             | MA    | MA     | MA    | MA     |
| W                                     | 0,01                          | 0,19 | 0,00  | 0,00   | 0,00 | 0,00                           | 0,03  | 0,00   | 0,00  | 0,08   |
| Área 2 – Fazenda Mandacaru            |                               |      |       |        |      |                                |       |        |       |        |
| Média                                 | 13,50                         | 1,24 | 7,89  | 443,00 | 2,63 | 132,79                         | 24,94 | 38,37  | 4,25  | 158,25 |
| Máximo                                | 17,78                         | 1,94 | 22,50 | 547,96 | 3,54 | 547,36                         | 62,94 | 95,14  | 10,62 | 252,29 |
| Mínimo                                | 10,36                         | 0,00 | 0,00  | 281,55 | 1,81 | 27,24                          | 4,48  | 22,74  | 2,37  | 93,40  |
| CV (%)                                | 12                            | 22   | 72    | 11     | 19   | 52                             | 64    | 33     | 33    | 22     |
| Classificação do CV                   | M                             | A    | MA    | M      | M    | MA                             | MA    | MA     | MA    | A      |
| W                                     | 0,61                          | 0,00 | 0,00  | 0,00   | 0,01 | 0,00                           | 0,00  | 0,00   | 0,00  | 0,08   |
| Área 3 – Fazenda Sempre Verde         |                               |      |       |        |      |                                |       |        |       |        |
| Média                                 | 12,12                         | 3,28 | 5,92  | 92,55  | 2,46 | 78,15                          | 9,63  | 85,44  | 5,67  | 147,03 |
| Máximo                                | 14,70                         | 5,25 | 14,00 | 124,30 | 3,78 | 148,69                         | 34,85 | 169,86 | 12,47 | 856,30 |
| Mínimo                                | 3,50                          | 2,21 | 1,59  | 48,38  | 1,14 | 28,33                          | 2,20  | 42,80  | 1,28  | 33,29  |
| CV (%)                                | 16                            | 21   | 55    | 25     | 25   | 29                             | 54    | 35     | 47    | 71     |
| Classificação do CV                   | M                             | A    | MA    | A      | A    | A                              | MA    | MA     | MA    | MA     |
| W                                     | 0,00                          | 0,02 | 0,00  | 0,00   | 0,33 | 0,48                           | 0,00  | 0,01   | 0,02  | 0,00   |

Legenda: Coeficiente de variação (CV); Classificação do CV segundo Pimentel-Gomes e Garcia (2002): médio (M) = 10% < CV ≤ 20, alto (A) = 20% < CV ≤ 30 e muito alto (MA) = CV > 30%; Teste de normalidade de Shapiro-Wilk (W); não significativo a 5% de probabilidade, indicando normalidade dos dados (ns).

A Figura 3.1 mostra as curvas espectrais de refletância média das amostras de folhas de mangueira irrigada cv. 'Tommy Atkins' das três áreas avaliadas. A menor refletância para as amostras foliares ocorreu na faixa de 350 a 700 nm, observando-se picos de absorção em torno de 450 e 650 nm, sendo a absorção em 450 nm mais forte que em 650 nm e houve a formação de um pico de reflexão em torno de 580 nm. Na faixa de 700 a 770 nm, a reflexão aumentou acentuadamente se mantendo elevada até 1332 nm. De 1332 a 2500 nm ocorreu uma diminuição gradual da refletância das folhas com a presença de feições nas curvas espectrais.



**Figura 3.1.** Espectros de refletância média das amostras de folhas de mangueira irrigada cultivar 'Tommy Atkins' em três áreas produtivas na região semiárida brasileira.

Observa-se ainda que dentre as três áreas avaliadas, a área 1 apresentou o menor teor médio de N (Tabela 3.3) e também mostrou a maior refletância média na região do visível (Figura 3.1). Para as amostras foliares das áreas 2 e 3 houve maior absorção nesta faixa do espectro.

### Desempenho dos modelos quimiométricos

A Tabela 3.4 apresenta as assinaturas espectrais para os nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins'. Observa-se que Zn e Mn tiveram assinaturas espectrais na faixa do visível e do NIR, o K teve seus comprimentos de onda mais responsivos na parte final da curva espectral, enquanto os demais nutrientes tiveram assinaturas espectrais ao longo de todo o espectro vis-NIR-SWIR.

**Tabela 3.4.** Assinaturas espectrais dos nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| Nutriente                 | Comprimento de onda (nm)   |
|---------------------------|--|
| N (g kg <sup>-1</sup> )   | 432; 479; 509; 762; 1921; 2053; 2093 e 2100.   |
| P (g kg <sup>-1</sup> )   | 499; 520; 565; 582; 617; 630; 673; 746; 1722 e 2306.   |
| K (g kg <sup>-1</sup> )   | 1867; 1903; 2101; 2369; 2426 e 2477.   |
| Ca (g kg <sup>-1</sup> )  | 614; 675; 1198; 1904; 2106 e 2330.   |
| Mg (g kg <sup>-1</sup> )  | 494; 665; 1907; 1917; 1985; 1991; 2006; 2029; 2116; 2217; 2260; 2282; 2311; 2326; 2370 e 2381. |
| B (mg kg <sup>-1</sup> )  | 548; 647; 649; 669 e 2002.   |
| Fe (mg kg <sup>-1</sup> ) | 521; 537; 631; 664; 1453; 2012; 2116 e 2276.   |
| Zn (mg kg <sup>-1</sup> ) | 524; 551; 568; 673; 678; 716; 726 e 745.   |
| Cu (mg kg <sup>-1</sup> ) | 474; 506; 520; 539; 564; 580; 588; 617; 633; 674; 765; 1406; 1715; 1967; 2103 e 2305.          |
| Mn (mg kg <sup>-1</sup> ) | 474; 502; 507; 522; 536; 582; 614; 632; 671; 752 e 777.  |

A Tabela 3.5 apresenta os parâmetros de desempenho dos modelos preditivos para nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' com uso da espectroscopia vis-NIR-SWIR. O pré-processamento que alcançou os melhores desempenhos preditivos foi o OSC.

Para K, o modelo PLSR proporcionou o melhor desempenho preditivo, sendo utilizada a região espectral do SWIR. Para os demais nutrientes, o modelo MLR alcançou os melhores desempenhos preditivos, sendo utilizado assinaturas espectrais. Segundo a classificação de Moore e Kirkland (2007), considerando o resultado da validação externa, os modelos preditivos ajustados tiveram desempenho forte para P e Ca, moderado para N e Zn, fraco para Fe, e muito fraco para K, Mg, B,



Cu e Mn. Para todos os nutrientes, observou-se que a seleção de regiões específicas do espectro ou assinaturas espectrais levou a calibração de modelos com maior capacidade preditiva do que espectro completo.

**Tabela 3.5.** Parâmetros dos modelos de regressão que apresentaram o melhor desempenho preditivo para os nutrientes foliares de mangueira irrigada cv. 'Tommy Atkins' na região semiárida brasileira.

| Atributos | Modelos | Faixa<br>espc. | Calibração     |       |       |      | Validação cruzada |        |       |       | Validação externa |                |       |       |        |
|-----------|---------|----------------|----------------|-------|-------|------|-------------------|--------|-------|-------|-------------------|----------------|-------|-------|--------|
|           |         |                | R <sup>2</sup> | RMSEC | SEC   | BIAS | R <sup>2</sup>    | RMSECV | SECV  | BIAS  | Fatores           | R <sup>2</sup> | RMSEP | SEP   | BIAS   |
| N         | MLR     | -              | 0,69           | 1,80  | 1,73  | 0,00 | 0,63              | 1,90   | 1,90  | -0,01 | -                 | 0,52           | 1,94  | 1,84  | -0,65  |
| P         | MLR     | -              | 0,79           | 0,53  | 0,50  | 0,00 | 0,73              | 0,57   | 0,57  | 0,00  | -                 | 0,78           | 0,54  | 0,54  | -0,10  |
| K         | PLSR    | SWIR           | 0,41           | 3,84  | 3,85  | 0,00 | 0,27              | 4,33   | 4,35  | 0,04  | 5                 | 0,11           | 5,28  | 5,32  | 0,21   |
| Ca        | MLR     | -              | 0,90           | 58,14 | 56,45 | 0,00 | 0,89              | 60,65  | 60,65 | -0,14 | -                 | 0,85           | 70,46 | 71,05 | -3,34  |
| Mg        | MLR     | -              | 0,66           | 0,41  | 0,38  | 0,00 | 0,52              | 0,45   | 0,45  | -0,01 | -                 | 0,20           | 0,55  | 0,55  | 0,03   |
| B         | MLR     | -              | 0,33           | 46,81 | 45,68 | 0,00 | 0,22              | 49,62  | 49,62 | -0,05 | -                 | 0,22           | 33,25 | 33,56 | 1,01   |
| Zn        | MLR     | -              | 0,50           | 10,72 | 10,31 | 0,00 | 0,39              | 11,40  | 11,40 | 0,00  | -                 | 0,57           | 8,61  | 8,61  | 1,20   |
| Fe        | MLR     | -              | 0,62           | 21,63 | 20,79 | 0,00 | 0,54              | 23,01  | 23,01 | 0,00  | -                 | 0,30           | 22,70 | 22,49 | 4,35   |
| Cu        | MLR     | -              | 0,76           | 1,39  | 1,28  | 0,00 | 0,66              | 1,55   | 1,55  | 0,01  | -                 | 0,28           | 2,45  | 2,40  | -0,57  |
| Mn        | MLR     | -              | 0,32           | 74,22 | 70,23 | 0,00 | 0,14              | 80,88  | 80,88 | -0,40 | -                 | 0,05           | 55,70 | 54,97 | -11,78 |

Regressão dos mínimos quadrados parciais (PLSR); Regressão linear múltipla (MLR); Infravermelho (NIR); Infravermelho de ondas curtas (SWIR); Coeficiente de determinação (R<sup>2</sup>); Raiz Quadrada média do erro de calibração (RMSEC); Erro padrão de calibração (SEC); Raiz quadrada média do erro de validação cruzada (RMSECV); Erro padrão de validação cruzada (SECV); Raiz quadrada média do erro de predição (RMSEP); Erro padrão da predição (SEP).

## DISCUSSÃO

### **Análise exploratória dos nutrientes foliares e do espectro**

A alta variação dos nutrientes foliares pode ter ocorrido pela aplicação de fertilizantes de maneira uniforme em áreas que apresentaram variabilidade espacial dos atributos do solo (SILVA et al., 2020) levando a uma disponibilidade variada dos nutrientes em diferentes locais, o que conseqüentemente resultou em taxas de absorção diferentes (BEHERA et al., 2016).

Segundo Quaggio (1996), os teores foliares de N, P e K variaram de deficientes a excessivos, de Ca e B oscilaram de adequados a excessivos, de Mg, Zn e Cu variaram de deficientes a adequados, enquanto os teores de Fe e Mn se mantiveram dentro da faixa adequada considerando as três áreas avaliadas.

Entretanto, apesar dos teores de nutrientes abaixo e acima das faixas adequadas, as plantas não apresentaram sintomas de deficiência ou toxicidade. Lira et al. (2021) observaram que as faixas de suficiência nutricional estabelecidas na literatura podem não suprir a demanda nutricional da mangueira irrigada na região semiárida, uma vez que a maioria das tabelas de interpretação dos teores de macro e micronutrientes foi desenvolvida em condições de cultivo diferentes e para produtividades esperadas inferiores ao rendimento médio alcançado pelo Vale do São Francisco.

No sistema de produção de manga da região, é comum se fazer a indução floral com a aplicação de nitratos de cálcio e potássio, o que pode levar a ocorrência de altos teores de Ca foliar (FARIA et al., 2016; MARTINEZ et al., 2020). Os menores níveis de K em relação ao Ca podem ser explicados devido a boa mobilidade do K no floema e a grande remobilização desse nutriente para os frutos, que são drenos preferenciais, durante a frutificação (COSTA et al., 2011; DIAS et al., 2013). Além de que o K é o nutriente exportado em maior quantidade pelos frutos, estando associado aos parâmetros de qualidade da manga (MELLADO-VÁZQUEZ et al., 2012; AHMAD et al 2018; TOHIDLOO et al., 2018).

A refletância na faixa de 350 a 700 nm está associada a radiação fotossinteticamente ativa, de forma que a baixa reflexão nesta região espectral é devida a forte absorção pelos pigmentos fotossintéticos (WEBER et al., 2012). Os comprimentos de onda em torno de 450 e 650 nm correspondem respectivamente às faixas do azul e do vermelho do espectro eletromagnético. Na faixa do azul ocorre

absorção pelas clorofilas e carotenoides e na faixa do vermelho ocorre absorção apenas pelas clorofilas de modo que, alterações no teor de clorofila da folha resultam em variações nos dados espectrais (LIU et al., 2019). A formação de um pico de reflexão entre as faixas do azul e do vermelho mostra que as folhas absorvem fortemente luz azul e vermelha e refletem a luz verde na faixa do visível (LI e HE, 2008).

Na região do NIR não houve características de absorção fortes. Esta faixa do espectro contém informações da estrutura foliar, sendo que a alta reflexão no NIR ocorre devido aos múltiplos reflexos causados pelo espalhamento da luz no arranjo celular (PEÑUELAS e FILELLA, 1998). A região do SWIR apresenta vários sinais espectrais causados por compostos orgânicos que compõe a matéria seca nas folhas vegetais como carboidratos, proteínas e aminoácidos, dentre outros (GE et al., 2019).

### **Desempenho dos modelos quimiométricos**

A seleção de comprimentos de onda para a quantificação de nutrientes foliares foi importante por reduzir as informações redundantes nos espectros vis-NIR-SWIR otimizando o desempenho dos modelos preditivos (MALMIR et al., 2019).

Os nutrientes foliares não podem ser detectados diretamente por espectroscopia vis-NIR-SWIR, mas compostos orgânicos da folha que contém esses elementos – tais como pigmentos, proteínas e carboidratos dentre outros – devido as suas ligações C–H, O–H e N–H, são espectralmente ativos podendo, portanto, ser usados para prever quantitativamente os nutrientes foliares de forma indireta (WANG et al., 2018).

Os comprimentos de onda a 432, 479, 509 e 762 nm estão próximos da absorção das clorofilas localizada em torno de 500 e 675 nm que podem, por sua vez caracterizar o estado de N das folhas dado que a concentração de clorofila está diretamente relacionada ao teor de N (PEÑUELAS e FILELLA, 1998). Wang et al. (2018) observaram na espécie de chá *Camellia sinensis* L. que um aumento na dose de N aplicada causou um aumento das concentrações de N foliar e da síntese de clorofilas e levou a uma diminuição dos valores de refletância na faixa do visível, o que esteve associado a maior absorção de energia pelas moléculas de clorofila. Os comprimentos de onda entre as regiões de 700 e 770 nm estão na transição entre o vermelho e o infravermelho e a posição da borda vermelha também pode ser usada

para prever o teor de clorofila que está relacionado a concentração de N (MALMIR et al., 2019).

O espectro de refletância no SWIR também pode ser um bom indicador do conteúdo de N foliar. A superioridade da região do SWIR sobre o NIR para a predição de N está relacionada com sobretons e combinações de modos vibracionais associados as ligações N–H e C–H presentes nos aminoácidos e as ligações C–H das moléculas de clorofila (CURRAN, 1989; ROTBART et al., 2013).

A previsão de N a partir de espectroscopia vis-NIR-SWIR também foi moderada para folhas de dendê (KHORRAMNIA et al., 2014). Entretanto, modelos com boa predição foram relatados em folhas de colza (ZHANG et al., 2013), de soja e de milho (PANDEY et al., 2017).

A amplitude dos dados utilizada para calibrar modelos regressivos desempenha um importante papel para melhorar a precisão da previsão. A faixa dos teores de N deste estudo (3,22 a 17,78 g kg<sup>-1</sup>) apresentou uma amplitude menor que outros estudos realizados (15,00 a 45,00 g kg<sup>-1</sup>) (PANDEY et al., 2017), o que pode ter prejudicado a capacidade preditiva do modelo regressivo desenvolvido para N. Assim, o uso de amostras foliares de outras fases fenológicas da cultura da mangueira pode precisar ser considerado em estudos futuros a fim de se obter uma variação maior da concentração de N foliar e dessa forma, melhorar a previsibilidade de N a partir de espectros vis-NIR-SWIR.

Os principais compostos fosforados celulares são moléculas energéticas, ácidos nucleicos (DNA e RNA), fosfoproteínas, fosfolipídeos e fosfatos de açúcar, nos quais grupos fosfatos estão vinculados por uma ligação C–O–P (DISSANAYAKA et al., 2021). O P está presente na molécula de ATP (Adenosina trifosfato) estando, portanto, associado diretamente com processos fisiológicos que requerem energia como a fotossíntese, de modo que informações espectrais na faixa do visível podem colaborar com a previsão do conteúdo de P foliar (MAHAJAN et al., 2014). Siedliska et al. (2021) observaram que diferentes taxas de P causam alterações na concentração de clorofila nas folhas. Ademais, dentro das plantas o P está relacionado a processos metabólicos vegetais, podendo-se utilizar a faixa do SWIR para associar espectralmente às concentrações de P a proteínas, açúcares e amidos como produtos finais representativos do metabolismo (KNOX et al., 2012). Petisco et al. (2005) ainda descobriram que comprimentos de onda próximos a 2330 nm estão correlacionados com fosfolipídios.

O P também foi previsto com boa precisão com uso de espectroscopia vis-NIR-SWIR em folhas de colza (ZHANG et al., 2013), de soja e de milho (PANDEY et al., 2017). A faixa de teores foliares deste estudo (0,00 a 5,25 g kg<sup>-1</sup>) teve uma amplitude maior em relação a outros estudos desenvolvidos (2,00 a 4,00 g kg<sup>-1</sup>) (PANDEY et al., 2017), o que pode ter levado a calibração de um modelo regressivo com desempenho de previsão forte para P.

O K não é constituinte de nenhuma molécula vegetal estando presente na célula em sua forma iônica ou inorgânica (BANG et al., 2020). A faixa espectral entre 1800 e 2100 nm está associada à absorção da sacarose e de outros carboidratos (RÉBUFA et al., 2018). A relevância da região do SWIR para a previsão do conteúdo de K se dá em virtude da relação do K com carboidratos e ácidos orgânicos. O K influencia na fotossíntese e na translocação de assimilados como sacarose, celulose e amido, de modo que a abundância desses assimilados e ácidos orgânicos, como o ácido málico por exemplo (que podem ser diretamente medidos por espectros vis-NIR-SWIR), pode ser correlacionada indiretamente à concentração de K nas plantas (CIAVARELLA et al., 1998). O K ainda forma complexos de cátion-carboidratos que são espectralmente ativos (CADET e OFFMANN, 1996).

O K também não foi previsto com desempenho confiável em folhas de cacau com espectroscopia vis-NIR-SWIR (MALMIR et al., 2019), mas teve bom desempenho de predição em folhas de colza (ZHANG et al., 2013), de soja e de milho (PANDEY et al., 2017). A faixa de concentração de K foliar deste estudo (0,00 a 27,48 g kg<sup>-1</sup>) está próxima da faixa relatada por outros estudos (6,00 a 31,00 g kg<sup>-1</sup>) (ZHANG et al. 2013; PANDEY et al. 2017), de modo que o intervalo de variação dos dados provavelmente não foi um problema.

O K atua como regulador osmótico sendo importante na absorção de água pelas plantas, de modo que o K foliar é em geral altamente correlacionado com o conteúdo de água da folha (BANG et al., 2020). Assim, o uso de amostras de folhas frescas pode precisar ser considerado para melhorar a previsibilidade de K em estudos futuros.

O Ca atua como cofator no fotossistema II (SIEGBAHN e CRABTREE, 1999) de modo que a radiação fotossinteticamente ativa contribui para sua previsão. A sensibilidade das características do NIR ao Ca está relacionada à estrutura celular da folha, uma vez que o Ca também é um elemento estrutural que confere rigidez a parede celular e integridade a membrana plasmática (BANG et al., 2020).

Comprimentos de onda na região do SWIR relacionados à absorção de amido e aminoácidos também podem contribuir com modelos preditivos de Ca foliar (AMIRRUDDIN et al., 2020).

O Ca também foi previsto de forma confiável com uso de espectroscopia vis-NIR-SWIR em folhas de oliva (COMINO et al., 2018), de citrus (GALVEZ-SOLA et al., 2015) e de cacau (MALMIR et al., 2019). O intervalo dos teores de Ca deste estudo teve uma amplitude superior (23,06 a 547,96 g kg<sup>-1</sup>) ao de outros estudos semelhantes (0,89 a 6,77 g kg<sup>-1</sup>) (GALVEZ-SOLA et al., 2015), o que pode ter contribuído para o desenvolvimento de um modelo com desempenho de previsão forte para Ca foliar.

O Mg é o elemento central da molécula de clorofila (BANG et al., 2020) de modo que as características espectrais sensíveis a clorofila, compreendidas na faixa do visível, contribuem a com a previsão de Mg (LIU et al., 2019). Características espectrais do SWIR em torno de 2060, 2130, 2240, 2300 e 2350 nm estão relacionadas à absorção de energia pelas proteínas (CURRAN, 1989). Assinaturas espectrais próximas aos comprimentos de onda responsivos às proteínas podem contribuir com a previsão de Mg foliar, uma vez que este nutriente é um elemento de ponte para a agregação entre as subunidades ribossômicas, um processo essencial na síntese proteica, além de o Mg ser ativador de algumas enzimas nas plantas (BANG et al., 2020).

Semelhante aos resultados encontrados neste estudo, Comino et al. (2018) também observaram modelos regressivos com baixa precisão de previsão para Mg em folhas de oliva. Entretanto, Pandey et al. (2017) encontraram resultados moderados na previsão de Mg em folhas de soja e milho. A faixa de variação dos teores de Mg deste estudo (1,14 a 5,92 g kg<sup>-1</sup>) esteve próxima das relatadas em outros estudos (5,00 a 7,00 g kg<sup>-1</sup>) (PANDEY et al., 2017), de forma que o intervalo dos dados provavelmente não constituiu um problema na calibração do modelo. Assim, a predição de Mg foliar com espectroscopia vis-NIR-SWIR precisará de mais investigações futuras para o desenvolvimento de modelos preditivos satisfatórios na cultura da mangueira.

Em relação aos micronutrientes, alguns estudos têm demonstrado que os modelos preditivos geralmente têm um desempenho inferior aos dos macronutrientes (GALVEZ-SOLA et al., 2015; COMINO et al., 2018). Segundo Liao et al. (2012), a previsão vis-NIR-SWIR de micronutrientes pode ser comprometida principalmente devido a suas baixas concentrações nas folhas. Entretanto, para o micronutriente Zn,

Rodrigues et al. (2019) também desenvolveram modelo regressivo de previsão moderada na cultura da soja, semelhante aos resultados encontrados no presente estudo.

O Zn é utilizado no processo de biossíntese de clorofila podendo ser, portanto, relacionado com comprimentos de onda na região do visível (ZHANG et al., 2019). Corroborando com os resultados do presente trabalho, Shao e He (2013) encontraram, na cultura do arroz, assinaturas espectrais entre 680 e 720 nm sensíveis ao teor de Zn foliar.

Apesar de algumas limitações, este estudo demonstra o uso potencial da espectroscopia vis-NIR-SWIR para quantificar nutrientes foliares na cultura da mangueira cv. 'Tommy Atkins' que apresentaram  $R^2$  acima de 0,50, como foi o caso do Ca, P, N e Zn, com destaque para os dois primeiros que tiveram  $R^2$  superior a 0,70.

Os nutrientes devem estar nos níveis adequados para se alcançar uma produção de frutos de qualidade. Na cultura da mangueira por exemplo, o N deve estar alto especialmente nas fases de crescimento vegetativo, de desenvolvimento da panícula e de crescimento do fruto (SILBER et al., 2022). Além disso, este nutriente possui um limite máximo ( $14 \text{ g kg}^{-1}$ ) na fase da indução floral, não devendo ultrapassar este valor (DAVENPORT et al., 2013).

Os teores de Ca devem estar altos principalmente nas fases de crescimento vegetativo, desenvolvimento da flor e do fruto (SINGH et al., 2013). Ademais, deve-se ter uma atenção especial a relação Ca/N na folha a fim de evitar a ocorrência de desordens fisiológicas como o colapso interno (BIBI et al., 2019). O P é normalmente fornecido no início do ciclo produtivo e no florescimento, e os maiores teores foliares deste nutriente ocorrem nas fases de floração e frutificação (FARIA et al., 2016). E o Zn por sua vez, apresenta picos de concentração foliar antes do florescimento e no desenvolvimento dos frutos (MAHIDA et al., 2018).

Diante disso, a espectroscopia vis-NIR-SWIR pode auxiliar no programa de adubação dos nutrientes supracitados, tendo em vista que uma previsão rápida do conteúdo de nutriente foliar é de grande importância para avaliar o estado nutricional da planta, possibilitando a adoção de uma gestão mais adequada dos fertilizantes na cultura da mangueira.



## CONCLUSÕES

Comprimentos de onda específicos do espectro vis-NIR-SWIR se mostraram sensíveis aos teores foliares de N, P, Ca e Zn em mangueira cv. 'Tommy Atkins' cultivada sob irrigação na região semiárida brasileira. Assim, a predição dos teores de P e Ca é forte ( $R^2 > 0,70$ ) enquanto a predição dos teores de N e Zn é moderada ( $0,70 > R^2 > 0,50$ ) com o uso de sensoriamento proximal. Portanto, a espectroscopia vis-NIR-SWIR se mostrou uma ferramenta viável para complementar as análises convencionais de quantificação de nutrientes foliares, facilitando a avaliação do estado nutricional da mangueira devido a sua rapidez e menor custo. Assim, esta tecnologia possui potencial de aplicação em modelos de manejo agrícola com fruticultura de precisão.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; MORAES, G.; LEONARDO, J.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- AHMAD I.; BIBI F.; BAKHSH A.; ULLAH H.; DANISH S.; REHMAN, A. Assessment of various levels of potassium citrate and sucrose along with boric acid on quality and yield of Sufaid Chaunsa. **International Journal Bioscience**, v. 13, n. 1, p. 188-195, 2018.
- AMIRRUDDIN, A. D.; MUHARAM, F. M.; ISMAIL, M. H.; TAN, N. P.; ISMAIL. M. F. Hyperspectral spectroscopy and imbalance data approaches for classification of oil palm's macronutrients observed from frond 9 and 17. **Computers and Electronics in Agriculture**, v. 178, p. 1-11, 2020.
- BANG, T. C.; HUSTED, S.; LAURSEN, K. H.; PERSSON, D. P.; SCHJOERRING, J. K. The molecular-physiological functions of mineral macronutrients and their consequences for deficiency symptoms in plants. **New Phytologist**, v. 229, n. 5, p. 2446-2469, 2020.
- BARNES, R. J.; DHANOA, M. S.; LISTER, S. J. Standard normal variate transformation and detrending of near-infrared diffuse reflectance spectra. **Applied Spectroscopy**, v. 43, n. 5, p. 772-777, 1989.
- BEHERA, S. K.; SURESH, K.; RAMACHANDRUDU, K.; MANORAMA, K.; RAO, B. N. Mapping spatial variability of leaf nutrient status of oil palm (*Elaeis guineensis* Jacq.) plantations in India. **Crop and Pasture Science**, v. 67, n. 1, p. 109-116, 2016.
- BIBI, F.; AHMAD.; BAKHSH, A.; KIRAN, S.; DANISH, S.; ULLAH, H.; REHMAN, A. Effect of foliar application of boron with calcium and potassium on quality and yield of mango cv. Summer Bahisht (SB) chaunsa. **Open Agriculture**, v. 4, n. 1, p. 98-106, 2019.

CADET, F.; OFFMANN, B. Evidence for potassium-sucrose interaction in biological mid-infrared spectra by multidimensional analysis. **Spectroscopy Letters**, v. 29, n. 7, p. 1353-1365, 1996.

CIAVARELLA, S.; BATTEN, G. D.; BLAKENEY, A. B. Measuring potassium in plant tissues using near infrared spectroscopy. **Journal of Near Infrared Spectroscopy**, v. 6, p. A63-A66, 1998.

COMINO, F.; AYORA-CAÑADAA, M. J.; ARANDAB, V.; DÍAZC, A.; DOMÍNGUEZ-VIDALA, A. Near-infrared spectroscopy and X-ray fluorescence data fusion for olive leaf analysis and crop nutritional status determination. **Talanta**, v. 188, p. 676-684, 2018.

COSTA, M. E.; CALDAS, A. V. C.; OLIVEIRA, A. F. M.; GURGEL, M. T.; SILVA, R. M. Caracterização nutricional da mangueira 'Tommy Atkins' em função da adubação nitrogenada. **ACSA-Agropecuária Científica no Semiárido**, v. 7, n. 1, p. 16-22, 2011.

CURRAN, P. J. Remote Sensing of Foliar Chemistry. **Remote Sensing of Environment**, v. 30, n. 3, p. 271-278, 1989.

DAVENPORT, T. L. Management of flowering in three tropical and sub-tropical fruit tree species. **HortScience**, v. 38, p. 1331-1335, 2003.

DIAS, J. R. M.; TUCCI, C. A. F.; WADT, P. G. S.; PARTELLI, F. L.; PEREZ, D. V.; CURITIBA, M. E.; TOMIO, D. B. Antecipação do período de diagnose foliar em laranja 'Pêra' no Amazonas. **Pesquisa Agropecuária Brasileira**, v. 48, n. 7, p. 757-764, 2013.

DISSANAYAKA, D. M. S. B.; GHAREMANI, M.; SIEBERS, M.; WASAKI, J.; PLAXTON, W. C. Recent insights into the metabolic adaptations of phosphorus-deprived plants. **Journal of Experimental Botany**, v. 72, n. 2, p. 199-223, 2021.

FAO-Food and Agriculture Organization of the United Nations. 2020. FAOSTAT, Disponível em: <http://www.fao.org/faostat/en/#home>. Acesso em: 25/10/21.

FARIA, L. N.; DONATO, S. L. R.; SANTOS, M. R.; CASTRO, L. G. Nutrient contents in 'Tommy Atkins' mango leaves at flowering and fruiting stages. **Journal of the Brazilian Association of Agricultural Engineering**, v. 36, n. 6, p. 1073-1085, 2016.

GALVEZ-SOLA, L.; GARCÍA-SÁNCHEZ, F.; PÉREZ-PÉREZ, J. G.; GIMENO, V.; NAVARRO, J. M.; MORAL, R.; MARTÍNEZ-NICOLÁS, J. J.; NIEVES, M. Rapid estimation of nutritional elements on citrus leaves by near infrared reflectance spectroscopy. **Frontiers in Plant Science**, v. 6, p. 1-8, 2015.

GE, Y.; ATEFI, A.; ZHANG, H.; MIAO, C.; RAMAMURTHY, R. K.; SIGMON, B.; YANG, J.; SCHNABLE, J. C. High-throughput analysis of leaf physiological and chemical traits with VIS-NIR-SWIR spectroscopy: a case study with a maize diversity panel. **Plant Methods**, v. 15, p. 1-12, 2019.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, p. 1-17, 1986.

GENÚ, P. J. C.; PINTO, A. C. Q. (ed.). **A cultura da mangueira**. Brasília: Embrapa Informação Tecnológica, 2002. 454p.

GÓMEZ, A. H.; HE, Y.; PEREIRA, A. G. Non-destructive measurement of acidity, soluble solids and firmness of Satsuma mandarin using Vis/NIR-spectroscopy techniques. **Journal of Food Engineering**, v. 77, n. 2, p. 313-319, 2006.

GORRY, P. A. General least-square smoothing and differentiation by the convolution (Savitzky-Golay) method. **Analytical Chemistry**, v. 62, n. 6, p. 570-573, 1990.

JIN, X.; WANG, L.; ZHENG, W.; ZHANG, X. D.; LIU, L.; LI, S.; RAO, Y.; XUAN, J. Predicting the nutrition deficiency of fresh pear leaves with a miniature near-infrared spectrometer in the laboratory. **Measurement**, v. 188, p. 1-12, 2022.

KIST, B. B.; SANTOS, C. E.; CARVALHO, C.; BELING, R. R. Anuário brasileiro de Horti&Fruti 2021. Santa Cruz do Sul: **Gazeta Santa Cruz**, 104 p. 2021.

KNOX, N. M.; SKIDMORE, A. K.; PRINS, H. H. T.; HEITKÖNIG, I. M. A.; SLOTOW, R.; WAAL, C.; BOER, W. F. Remote sensing of forage nutrients: Combining ecological and spectral absorption feature data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 72, p. 27-35, 2012.

LI, X.; HE, Y. Discriminating varieties of tea plant based on Vis/NIR spectral characteristics and using artificial neural networks. **Biosystems Engineering**, v. 99, p. 313-321, 2008.

LIRA, A. L. F.; SILVA, K. A.; RODRIGUES, M. S.; SOUZA, C. G. P.; MOREIRA, F. B. R. LIMA, A. M. N. Spatial correlation between soil and leaf macronutrients in semiarid Brazilian mango (*Mangifera indica* L.) fields. **Revista Brasileira de Fruticultura**, v. 43, n. 4, p. 1-17, 2021.

LIU, J.; HAN, J.; CHEN, X.; SHI, L.; ZHANG, L. Nondestructive detection of rape leaf chlorophyll level based on Vis-NIR spectroscopy. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 222, p. 1-7, 2019.

LU, J.; YANG, T.; SU, X.; QI, H.; YAO, X.; CHENG, T.; ZHU, Y.; CAO, W.; TIAN, Y. Monitoring leaf potassium content using hyperspectral vegetation indices in rice leaves. **Precision Agriculture**, v. 21, p. 324-348, 2019.

ISAKSSON, T.; NAES, T. The effect of multiplicative scatter correction (MSC) and linearity improvement in NIR spectroscopy. **Applied Spectroscopy**, v. 42, n. 7, p. 1273-1284, 1998.

KENNARD, R. W.; STONE, L. A. Computer aided design of experiments. **Technometrics**, v. 11, n. 1, p. 137-148, 1969.

KHORRAMNIA, K.; KHOT, L. R.; SHARIFF, A. R. B. M.; EHSANI, R.; MANSOR, S. B.; RAHIM, A. B. A. Oil palm leaf nutrient estimation by optical sensing techniques. **Transactions of the ASABE**, v. 57, n. 4, p. 1267-1277, 2014.

MAHAJAN, G. R.; SAHOO, R. N.; PANDEY, R. N.; GUPTA, V. K.; KUMAR, D. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). **Precision Agriculture**, v. 15, n. 5, p. 499-522, 2014.

MALMIR, M.; TAHMASBIAN, I.; XU, Z.; FARRAR, M. B.; BAI, S. H. Prediction of macronutrients in plant leaves using chemometric analysis and wavelength selection. **Journal of Soils and Sediments**, v. 20, n. 1, p. 249-259, 2019.

MAHIDA, A.; TANDEL, Y. N.; MANTRI, A.; PATEL, N.; PARMAR, V. K. Effect of Fe and Zn fertilization on fruit setting and yield attributes of mango cv. Kesar. **International Journal of Chemical Studies**, v. 6, n. 5, p. 532-534, 2018.

MARTINEZ, M. M.; RAMIREZ, P. A. M.; ESTRADA, M. C.; OLIVA, A. C. Effect of nitrates alone or with paclobutrazol on flowering induction and production in mango cv. Tommy Atkins. **Biotecnia**, v. 22, n. 2, p. 20-27, 2020.

MELLADO-VÁZQUEZ, A.; SALAZAR-GARCÍA, S.; FUENTE, C. A. T.; GONZÁLEZ-DURÁN, I. J. L.; JIMÉNEZ, L. A. Fruit nutrient composition and removal by 'Haden' and 'Tommy Atkins' mangos fruits under forced production. **Revista Mexicana de Ciencias Agrícolas**, v. 3, n. 5, p. 925-941, 2012.

MISHRA, P.; HERRMANN, I.; ANGILERI, M. Improved prediction of potassium and nitrogen in dried bell pepper leaves with visible and near-infrared spectroscopy utilising wavelength selection techniques. **Talanta**, v. 225, p. 1-5, 2021.

MOORE, D. S.; KIRKLAND, S. **The basic practice of statistics**. New York: WH Freeman, v. 2, 2007.

PANDEY, P.; GE, Y.; STOERGER, V.; SCHNABLE, J. C. High throughput in vivo analysis of plant leaf chemical properties using hyperspectral imaging. **Frontiers in Plant Science**, v. 8, n. 1348, p. 1-12, 2017.

PEÑUELAS, J.; FILELLA, I. Visible and near-infrared reflectance techniques for diagnosing plant physiological status. **Trends in Plant Science**, v. 3, n. 4, p. 151-156, 1998.

PETISCO, C.; GARCÍA-CRIADO, B.; ALDANA, B. R. V.; ZABALGOGEAZCOA, I.; MEDIAVILLA, S.; GARCÍA-CIUDAD, A. Use of near-infrared reflectance spectroscopy in predicting nitrogen, phosphorus and calcium contents in heterogeneous woody plant species. **Analytical Bioanalytical Chemistry**, v. 382, n. 2, p. 458-465, 2005.

PIMENTEL-GOMES, F.; GARCIA, C. H. **Estatística aplicada a experimentos agrônômicos e florestais: exposição com exemplos e orientações para uso de aplicativos**. Piracicaba: FEALQ, 2002. 309 p.

SARKER, B. C.; RAHIM, M. A. Effects of doses and splits of fertilizer application on harvesting time, yield and quality of mango cv. Amrapali. **Bangladesh Journal Agricultural Research**, v. 37, n. 2, p. 279-293, 2012.

SAVITZKY, A.; GOLAY, M. J. E.; Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SHAO, Y.; HE, Y. Visible/near infrared spectroscopy and chemometrics for the prediction of trace element (Fe and Zn) levels in rice leaf. **Sensors**, v. 13, n. 2, p. 1872-1883, 2013.

SILBER, A.; GOLDBERG, T.; SHAPIRA, O.; HOCHBERG, U. Nitrogen uptake and macronutrients distribution in mango (*Mangifera indica* L. cv. Keitt) trees. **Plant Physiology and Biochemistry**, v. 181, n. 15, p. 23-32, 2022.

SINGH, D. K.; RAM, R. B.; YADAVA, L. P. Preharvest treatment of Ca, K, and B reduces softening of tissue in “Dashehari” Mango. **International Journal of Fruit Science**, v. 13, n. 3, p. 299-311, 2013.

SOUZA, P. A.; FERREIRA, I. J. S.; COSTA, D. S. Determination of quality attributes and ripening stage using vis-nir spectroscopy in intact seriguela and umbu fruits. **Revista Engenharia na Agricultura**, v. 30, p. 127-141, 2022.

QUAGGIO, J. A. Adubação e calagem para mangueira e qualidade dos frutos. In: São José, A. R.; Souza, I. V. B.; Martins Filho, J.; Morais, O. M. (Eds.) **Manga, tecnologia de produção e mercado**. Vitória da Conquista: DBZ/UESB, p.106-135, 1996.

RÉBUFA, C.; PANY, I.; BOMBARDA, I. NIR spectroscopy for the quality control of *Moringa oleifera* (Lam.) leaf powders: Prediction of minerals, protein and moisture contents. **Food Chemistry**, v. 261, n. 30, p. 311-321, 2018.

RODRIGUES, M.; NANNI, M. R.; CEZAR, E.; SANTOS, G. L. A. A.; REIS, A. S.; OLIVEIRA, K. M.; OLIVEIRA, R. B. Vis–NIR spectroscopy: from leaf dry mass production estimate to the prediction of macro- and micronutrients in soybean crops. **Journal of Applied Remote Sensing**, v. 14, n. 4, p. 1-20, 2020.

ROTBART, N.; SCHMILOVITCH, Z.; COHEN, Y.; ALCHANATIS, V.; EREL, R.; IGNAT, T.; SHENDEREY, C.; DAG, A.; YERMIYAHU, U. Estimating olive leaf nitrogen concentration using visible and near-infrared spectral reflectance. **Biosystems Engineering**, v. 114, p. 426-434, 2013.

SIEDLISKA, A.; BARANOWSKI, P.; PASTUSZKA-WOŹNIAK, J.; ZUBIK, M.; KRZYSZCZAK, J. Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance. **BMC Plant Biology**, v. 21, n. 28, 2021.

SIEGBAHN, P. E. M.; CRABTREE, R. H. Manganese oxyl radical intermediates and O–O bond formation in photosynthetic oxygen evolution and a proposed role for the calcium cofactor in photosystem II. **Journal of the American Chemical Society**, v. 121, n. 1, p. 117-127, 1999.

SILVA, F. C. S. (ed.). **Manual de análises químicas de solos, plantas e fertilizantes**. Brasília (DF): Embrapa Informação Tecnológica, 2009. 627 p.

SILVA, K. A.; RODRIGUES, M. S.; MOREIRA, F. B. R.; LIRA, A. L. F.; LIMA, A. M. N.; CAVALCANTE, I. H. L. Soil sampling optimization using spatial analysis in irrigated mango fields under brazilian semi-arid conditions. **Revista Brasileira de Fruticultura**, v. 42, n. 5, p. 1-18, 2020.

STEIDLE NETO, A. J.; LOPES, D. C.; PINTO, F. A. C.; ZOLNIER, S. Vis/NIR spectroscopy and chemometrics for non-destructive estimation of water and chlorophyll status in sunflower leaves. **Biosystems Engineering**, v. 155, p. 124-133, 2017.

TOHIDLOO G.; SOURI M. K.; ESKANDARPOUR S. Growth and fruit biochemical characteristics of three strawberry genotypes under different potassium concentrations of nutrient solution. **Open Agricultural**, v. 3, p. 356-362, 2018.

WANG, Y.; HU, X.; JIN, G.; HOU, Z.; NING, J.; ZHANG, Z. Rapid prediction of chlorophylls and carotenoids content in tea leaves under different levels of nitrogen application based on hyperspectral imaging. **Science of Food and Agriculture**, v. 99, n. 4, p. 1997-2004, 2018.

WEBER, V. S.; ARAUS, J. L.; CAIRNS, J. E.; SANCHEZ, C.; MELCHINGER, A. E.; ORSINI, E. Prediction of grain yield using reflectance spectra of canopy and leaves in maize plants grown under different water regimes. **Field Crops Research**, v. 128, p. 82-90, 2012.

WOLD, S.; RUHE, A.; WOLD, H. The collinearity problem in linear regression. The partial least square (PLS) approach to generalized inverses. **SIAM Journal on Scientific Computing**, v. 5, n. 3, p. 735–743, 1984.

YANLI, L.; QIANG, L.; SHAOLAN, H.; SHILAI, Y.; XUEFENG, L.; RANGJIN, X.; YONGQIANG, Z.; LIE, D. Prediction of nitrogen and phosphorus contents in citrus leaves based on hyperspectral imaging. **International Journal of Agricultural and Biological Engineering**, v. 8, n. 2, p. 80-88, 2015.

ZHANG, X.; LIU, F.; HE, Y.; GONG, X. Detecting macronutrients content and distribution in oilseed rape leaves based on hyperspectral imaging. **Biosystems Engineering**, v. 115, n. 1, p. 56-65, 2013.

ZHANG, J.; WANG, S.; SONG, S.; XU, F.; PAN, Y.; WANG, H. Transcriptomic and proteomic analyses reveal new insight into chlorophyll synthesis and chloroplast structure of maize leaves under zinc deficiency stress. **Journal of Proteomics**, v. 199, p. 123-134, 2019.

## CONSIDERAÇÕES FINAIS

A seleção de comprimentos de onda e de regiões espectrais específicas da faixa vis-NIR-SWIR alcançou melhor desempenho no desenvolvimento de modelos preditivos de atributos do solo e nutrientes foliares do que o espectro completo.

A espectroscopia vis-NIR-SWIR conseguiu estimar satisfatoriamente os níveis de N, P, Ca e Zn em folhas de mangueira cv. 'Tommy Atkins' cultivada sob irrigação. Também foi capaz de quantificar de maneira satisfatória os teores de Na<sup>+</sup>, Ca<sup>2+</sup>, Mg<sup>2+</sup>, areia, argila e COT em solos da região semiárida brasileira, bem como de captar a variabilidade e a dependência espacial desses atributos existente nas áreas.

Portanto, a espectroscopia vis-NIR-SWIR possui potencial para ser utilizada como uma ferramenta complementar nas análises de solo e folha, auxiliando no monitoramento do estado nutricional da cultura da mangueira cv. 'Tommy Atkins' e no mapeamento de atributos do solo.