

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – UNIOESTE**  
**CAMPUS CASCAVEL**  
**CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS – CCET**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA – PGEAGRI**

**RODRIGO LORBIESKI**

**ANÁLISE DA VARIABILIDADE ESPAÇO-TEMPORAL DE ATRIBUTOS QUÍMICOS  
DO SOLO EM UMA ÁREA AGRÍCOLA PRODUTORA DE GRÃOS**

Cascavel – PR

2024

RODRIGO LORBIESKI

**ANÁLISE DA VARIABILIDADE ESPAÇO-TEMPORAL DE ATRIBUTOS QUÍMICOS  
DO SOLO EM UMA ÁREA AGRÍCOLA PRODUTORA DE GRÃOS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, da Universidade Estadual do Oeste do Paraná (UNIOESTE) – *campus* Cascavel, em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola

Orientadora: Profa. Dra. Luciana Pagliosa Carvalho Guedes

Coorientador: Prof. Dr. Miguel Angel Uribe Opazo

Cascavel – PR

2024

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Lorbieski, Rodrigo  
Análise da variabilidade espaço-temporal de atributos químicos do solo em uma área agrícola produtora de grãos / Rodrigo Lorbieski; orientadora Dra. Luciana Pagliosa Carvalho Guedes; coorientador Dr. Miguel Angel Uribe-Opazo. -- Cascavel, 2024.  
104 p.

Tese (Doutorado Campus de Cascavel) -- Universidade Estadual do Oeste do Paraná, Centro de Ciências Exatas e Tecnológicas, Programa de Pós-Graduação em Engenharia Agrícola, 2024.

1. Correlação canônica. 2. Funções Empíricas Ortogonais. 3. Geoestatística. 4. Transformada de Fourier de Lomb-Scargle. I. Pagliosa Carvalho Guedes, Dra. Luciana , orient. II. Angel Uribe-Opazo, Dr. Miguel , coorient. III. Título.

Revisão de português, inglês e normas realizada por Me. Andreia Piechontcoski Uribe Opazo, em 24 de outubro de 2024.



**unioeste**

Universidade Estadual do Oeste do Paraná  
Reitoria  
CNPJ 78.680.337/0001-84  
Rua Universitária, 1619, Jardim Universitário  
Tel.: (45) 3220-3000 - www.unioeste.br  
CEP: 85819-110 - Cx. P.: 701  
Cascavel - PARANÁ



## **RODRIGO LORBIÉSKI**

### **ANÁLISE DA VARIABILIDADE ESPAÇO-TEMPORAL DE ATRIBUTOS QUÍMICOS DO SOLO EM UMA ÁREA AGRÍCOLA PRODUTORA DE GRÃOS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:

Orientador(a) - Luciana Pagliosa Carvalho Guedes

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Gustavo Henrique Dalposso

Universidade Tecnológica Federal do Paraná (UTFPR)

Miguel Angel Uribe Opazo

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Elizabeth Giron Cima

Centro Universitário da Fundação Assis Gurgacz (FAG)

Tamara Cantú Maltauro

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 15 de agosto de 2024.

## **BIOGRAFIA**

Rodrigo Lorbieski, nascido em 16 de julho de 1983 no município de Campo Mourão, estado do Paraná, é filho de Maria do Carmo Alves Lorbieski e Adolfo Lorbieski.

Graduou-se em Licenciatura Plena em Ciências Biológicas pela Universidade Estadual do Oeste do Paraná, em 2008, e em Licenciatura Plena em Matemática, também pela Universidade Estadual do Oeste do Paraná, em 2018.

Em 2012, especializou-se em Docência do Ensino Superior, pela Faculdade Assis Gurgaz, e em Ensino de Ciências e Matemática, pela Universidade Estadual do Oeste do Paraná. Também é Mestre em Engenharia Agrícola pela Universidade Estadual do Oeste do Paraná, tendo concluído em 2020.

Em 2024, tornou-se Doutor em Engenharia Agrícola pela Universidade Estadual do Oeste do Paraná, sob a orientação da Profa. Dra. Luciana Pagliosa Carvalho Guedes e coorientação do Prof. Dr. Miguel Angel Uribe Opazo.

## **AGRADECIMENTOS**

Primeiramente, agradeço à Deus, por me dar a força, sabedoria e perseverança que foram necessárias para concluir esta etapa tão importante da minha vida.

Agradeço imensamente à minha família, em especial aos meus pais, Adolfo e Maria, por todo amor, apoio e incentivo ao longo desta jornada. Aos meus irmãos, Robson e Rodolfo, pela compreensão, apoio e por estarem sempre ao meu lado, mesmo nos momentos mais desafiadores.

À minha orientadora, Professora Doutora Luciana Pagliosa Carvalho Guedes, a qual expresso minha profunda gratidão pela orientação, pela paciência e pelas valiosas contribuições durante todo o desenvolvimento desta tese. Sua dedicação foi fundamental para meu crescimento acadêmico e pessoal.

Ao meu coorientador, Professor Doutor Miguel Angel Uribe Opazo, agradeço pelo suporte técnico, pelas sugestões valiosas e pelo constante incentivo ao longo deste trabalho. Seus conselhos foram essenciais para a realização deste estudo.

Aos colegas de laboratório e de doutorado, que compartilharam comigo esta caminhada, meus sinceros agradecimentos. Em especial, agradeço ao Roney Peterson, pela amizade, pelo companheirismo e pelo apoio incondicional durante esta jornada.

Agradeço à Universidade Estadual do Oeste do Paraná (UNIOESTE) por oportunizar a realização da minha pós-graduação, e à coordenação do Programa de Pós-Graduação em Engenharia Agrícola (PGEAGRI) pelo auxílio prestado em diversos momentos.

Por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro em forma de bolsa de estudo, sem a qual a realização deste trabalho não seria possível.

A todos vocês, muito obrigado!

## RESUMO

Lorbieski, Rodrigo. **Análise da variabilidade espaço-temporal de atributos químicos do solo em uma área agrícola produtora de grãos.** Orientadora: Luciana Pagliosa Carvalho Guedes; Coorientador: Miguel Angel Uribe Opazo. 2024. 104 f. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2024.

A avaliação das mudanças nos atributos dos solos é essencial na agronomia, impactando diretamente a produtividade e a saúde do solo. A agricultura de precisão tornou essencial para quantificar essas variações, pois a caracterização da variabilidade espacial e temporal dos atributos do solo envolve diferentes técnicas estatísticas. Assim, o objetivo principal desta tese é analisar o padrão de distribuição espaço-temporal de atributos químicos do solo em uma área agrícola comercial, aplicando diferentes técnicas estatísticas. Para alcançar esse objetivo, a tese foi organizada em dois artigos científicos. O primeiro estudo analisa a variabilidade espaço-temporal dos atributos químicos do solo em uma área de cultivo de soja entre 2010 e 2022, utilizando técnicas de geoestatística espaço-temporal. Foram avaliados modelos de semivariância, com destaque para os modelos soma-métrico e soma-métrico simples. Observou-se que os atributos químicos do solo apresentaram dependência espacial moderada, com alcance restrito, e dependência temporal variando de moderada a forte, com alcance de um a seis anos, dependendo do atributo. A dependência espaço-temporal conjunta foi de fraca a moderada, sugerindo pouca interação entre as componentes. O estudo destacou a sensibilidade dos atributos químicos, as influências temporais e a importância da geoestatística para uma gestão agrícola sustentável. Já no segundo, analisou-se a variação de teor de cálcio, teor de fósforo, teor de matéria orgânica e pH em uma área de 167,35 hectares de soja em Cascavel, no Paraná, ao longo dos anos de 2010 a 2022. Utilizou-se de Funções Ortogonais Empíricas (EOFs) e Transformada Discreta de *Fourier de Lomb-Scargle* (LSDFT) para dados irregulares. Verificou-se que a variabilidade dos atributos é capturada por poucas EOFs: duas para teor de cálcio, três para pH e teor de matéria orgânica e quatro para teor de fósforo. Os padrões revelados indicam variações específicas para cada atributo e destacam a influência de certos anos na variabilidade. Espectros de potência ajudaram a identificar eventos sazonais e padrões espaciais e temporais importantes para o entendimento da variabilidade dos atributos químicos do solo.

**Palavras-chave:** Correlação canônica; Funções Empíricas Ortogonais; Geoestatística; Transformada de Fourier de Lomb-Scargle.

## ABSTRACT

Lorbieski, Rodrigo. **Analysis of the spatio-temporal variability of soil chemical attributes in a grain-producing agricultural area**. Advisor: Luciana Pagliosa Carvalho Guedes; Co-advisor: Miguel Angel Uribe Opazo. 2024. 104 f. Thesis (Doctorate in Agricultural Engineering) - State University of Western Paraná, Cascavel – Paraná, 2024.

Assessing changes in soil attributes is essential in agronomy, as it directly impacts both productivity and soil health. With the advancement of precision agriculture, quantifying these variations has become increasingly important. The characterization of the spatial and temporal variability of soil attributes requires the application of various statistical techniques. Thus, the main objective of this thesis is to analyze the spatio-temporal distribution pattern of soil chemical attributes in a commercial agricultural area, applying a diverse set of statistical techniques. To achieve this objective, the thesis was structured into two scientific articles. The first study focused on analyzing the spatio-temporal variability of soil chemical attributes in a soybean cultivation area from 2010 to 2022, using spatio-temporal geostatistics techniques. Semivariance models were evaluated, particularly the metric-sum and simple metric-sum models. The results indicated that soil chemical attributes displayed moderate spatial dependence, with a limited range, while temporal dependence ranged from moderate to strong, with a span of one to six years, depending on the attribute. The joint spatio-temporal dependence was observed to be weak to moderate, suggesting limited interaction between spatial and temporal components. The study emphasized the sensitivity of chemical attributes to temporal factors and reinforced the significance of geostatistical methods for sustainable agricultural management. In the second article, the study analyzed the variation in calcium content, phosphorus content, organic matter content, and pH in a 167.35-hectare soybean area located in Cascavel, Paraná, between 2010 and 2022. By applying Empirical Orthogonal Functions (EOFs) and the Lomb-Scargle Discrete Fourier Transform (LSDFT) for irregular data, it was found that the variability of the attributes could be captured by a small number of EOFs: two for calcium content, three for pH and organic matter content, and four for phosphorus content. The patterns identified specific variability trends for each attribute and highlighted the influence of certain years on their variation. Power spectra were used to detect seasonal events, providing valuable insights. This technique proved effective in identifying relevant spatial and temporal patterns that are crucial for a deeper understanding of soil chemical attribute variability.

**Keywords:** Canonical correlation; Empirical Orthogonal Functions; Geostatistics; Lomb-Scargle Fourier Transform.

# LISTA DE FIGURAS

## ARTIGO 1

Figura 1. Representação do gráfico com os pontos de amostragem (Sistema de coordenadas planas, projeção UTM, zona 22 Sul, datum SIRGAS 2000) .....	23
Figura 2. Combinação de distâncias espaço-temporais; nos exemplos, foram consideradas as seguintes combinações: (A) puramente espacial: considerando a distância espacial com X e a distância temporal com 0 anos (X, 0); (B) puramente temporal: considerando a distância espacial com 0 e a distância temporal com T (0, T); (C) espaço-temporal: considerando a distância espacial com X e a distância temporal com T (X, T).....	24
Figura 3 – Semivariograma espaço-temporal amostral para: (A) teor de Cálcio; (B) pH .....	27
Figura 4 – Semivariograma espaço-temporal amostral para: (A) teor de fósforo; (B) teor de magnésio; (C) teor de matéria orgânica .....	28
Figura 5 – Representação dos modelos ajustados para as variáveis (A) teor de fósforo; (B) teor de magnésio; (C) teor de matéria orgânica .....	29
Figura 6 – Representação dos modelos ajustados para as variáveis (A) teor de cálcio; (B) pH.....	30
Figura 7 – Semivariogramas amostrais separados por defasagens temporais; A) pH, B) teor de cálcio .....	32
Figura 8– Semivariogramas amostrais separados por defasagens temporais; A) teor de fósforo, B) teor de magnésio; C) teor de matéria orgânica.....	32
Figura 9– Biplot da correlação canônica entre variáveis climáticas e atributos químicos do solo.....	37
Figura 10 – Mapa do teor de matéria orgânica do solo entre os anos de 2010 e 2022 .....	39
Figura 11– Mapa do teor de cálcio no solo entre os anos de 2010 e 2022 .....	40
Figura 12 – Mapa do pH do solo entre os anos de 2010 e 2022.....	41
Figura 13 – Mapa do teor de fósforo no solo entre os anos de 2010 e 2022 .....	41
Figura 14 – Mapa do teor de magnésio no solo entre os anos de 2010 e 2022.....	42

## ARTIGO 2

Figura 1 – Representação do mapa com os pontos de amostragem (sistema de coordenadas planas, projeção UTM, zona 22 Sul, datum SIRGAS 2000) .....	52
--	----

Figura 2. Mapa das duas primeiras EOFs do teor de Cálcio no solo, considerando todos os anos-safra entre os anos de 2010 e 2022 .....	59
Figura 3. Mapa do teor de cálcio no solo entre os anos de 2010 e 2022.....	60
Figura 4. Espectros de potência para o teor de cálcio no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes. ....	61
Figura 5. Mapa dos três primeiros EOFs do teor de pH no solo, considerando todos os anos-safra entre os anos de 2010 e 2022 .....	63
Figura 6. Mapa do pH do solo entre os anos de 2010 e 2022 .....	64
Figura 7. Espectros de potência para o pH no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes. ....	65
Figura 8. Mapa das quatro primeiras EOFs do teor de fósforo no solo, considerando todos os anos-safra entre os anos de 2010 e 2022.....	68
Figura 9. Mapa do teor de fósforo no solo entre os anos de 2010 e 2022.....	69
Figura 10. Espectros de potência para o teor de fósforo no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes .....	71
Figura 11 - Mapa dos três primeiros EOFs do teor de matéria orgânica no solo, considerando todos os anos-safra entre os anos de 2010 e 2022 .....	73
Figura 12. Mapa do teor de matéria orgânica do solo entre os anos de 2010 e 2022. ....	74
Figura 13. Espectros de potência para o teor de matéria orgânica no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes .....	75

## LISTA DE TABELAS

### ARTIGO 1

Tabela 1 – Parâmetros geoestatísticos para o componente puramente espacial .....	31
Tabela 2 – Parâmetros geoestatísticos para o componente puramente temporal ....	35
Tabela 3 – Variâncias dos pares canônicos U e V e a correlação entre eles.....	35
Tabela 4 – Teste de significância dos pares canônicos .....	36
Tabela 5 – Carga Canônica para a Primeira Função Canônica (U1V1).....	36
Tabela 6 – Parâmetros geoestatísticos para a componente conjunta espaço-temporal (joint) .....	38

### ARTIGO 2

Tabela 1. Variância das EOFs para teor de Cálcio. ....	57
Tabela 2. Proporção da importância de cada ano para explicação dos padrões de variabilidade do teor de cálcio para cada EOF selecionada. Em vermelho se destacam os maiores coeficiente.....	58
Tabela 3. Variância das EOFs para pH.....	62
Tabela 4. Proporção da importância de cada ano para explicação dos padrões de variabilidade para o pH de cada EOF selecionada. Em vermelho se destacam os maiores coeficientes.....	62
Tabela 5. Variância das EOFs para Teor de fósforo. ....	66
Tabela 6. Proporção da importância de cada ano para explicação dos padrões de variabilidade para o teor de fósforo de cada EOF selecionada. Em vermelho se destacam os maiores coeficientes. ....	67
Tabela 7. Variância das EOFs para teor de Matéria Orgânica.....	72
Tabela 8. Proporção da importância de cada ano para explicação dos padrões de variabilidade para o teor de matéria orgânica de cada EOF selecionada. Em vermelho se destacam os maiores coeficientes.....	72

## Sumário

1. INTRODUÇÃO .....	1
2. OBJETIVOS .....	4
2.1 Objetivo geral.....	4
2.2 Objetivos específicos.....	4
3. REVISÃO BIBLIOGRÁFICA.....	5
3.1 Agricultura de Precisão e análise da variabilidade espaço-temporal.....	5
3.2 Variabilidade espaço-temporal de atributos químicos do solo.....	5
3.3 Geoestatística espaço-temporal .....	6
3.4 Modelos espaço-temporais.....	12
3.4.1 Modelo métrico.....	12
3.4.2 Modelo soma.....	14
3.4.3 Modelo soma-métrico .....	14
3.4.4 Modelo soma-produto .....	15
3.5 <i>Krigagem</i> espaço-temporal.....	15
3.6 Funções Ortogonais Empíricas (EOFs).....	16
4. METODOLOGIA GERAL .....	18
5. ARTIGOS .....	20
5.1 Artigo 1: Análise Geoestatístico Espaço-Temporal De Atributos Químicos Do Solo Em Uma Área Agrícola Produtora De Soja .....	20
5.1.1 Introdução .....	20
5.1.2 Metodologia.....	22
5.1.2.1 Área de Estudo .....	22
5.1.2.2 Análise Geoestatística Espaço-Temporal.....	23
5.1.2.3 Análise da Relação das Variáveis Climáticas e dos Atributos Químicos do Solo .....	26
5.1.3 Resultados e Discussões .....	27
5.1.3.1 Análise dos semivariogramas espaço-temporais amostrais .....	27
5.1.3.2 Análise dos modelos ajustados e seus parâmetros .....	28
5.1.3.3 Análise da Componente puramente espacial .....	30
5.1.3.4 Análise da Componente puramente temporal.....	33
5.1.3.5 Componente espaço-temporal (joint).....	38
5.1.3.6 Análise dos diferentes atributos químicos do solo .....	39
5.1.4 Conclusão .....	42
<b>Referências</b> .....	43

5.2 Artigo 2 – Funções Ortogonais Empíricas Com Irregularidade Temporal: Análise Da Variabilidade Espacial E Temporal Dos Atributos Químicos Do Solo Em Uma Área Produtora De Soja.....	49
Resumo.....	49
5.2.1 Introdução.....	49
5.2.2 Metodologia.....	51
5.2.2.1 Coleta de Dados e Área de Estudo.....	51
5.2.2.2 Funções Ortogonais Empíricas (EOF).....	52
5.2.2.3 Transformação de Fourier de Lomb-Scargle.....	55
5.2.2.4 Geração da Matriz de Covariância usando LSDFT.....	56
5.2.2.5 Análise dos Espectros de Potência.....	56
5.2.3 Resultados e Discussões.....	57
5.2.3.1 Teor de Cálcio.....	57
5.2.3.2 pH.....	62
5.2.3.3 Teor de fósforo.....	66
5.2.3.4 Teor de Matéria Orgânica.....	71
5.2.3.5 Análise geral.....	76
5.2.4 Conclusão.....	78
<b>Referências.....</b>	<b>79</b>
6. CONSIDERAÇÕES FINAIS.....	84
REFERÊNCIAS.....	86

## 1. INTRODUÇÃO

O aumento populacional, ao longo dos anos, exigirá maior oferta de alimentos, a qual depende do uso eficiente das terras disponíveis, já que a expansão de novas áreas é limitada (Ortiz, 2012). Ademais, sustentabilidade dessa produção é crucial considerando os desafios ambientais, como mudanças climáticas que podem impactar os recursos hídricos e a produtividade (Ferreira *et al.*, 2016). Assim, o uso de tecnologias sustentáveis e práticas agrícolas resilientes será essencial para garantir a segurança alimentar e a conservação dos ecossistemas (Costa; Pauletto, 2021).

Para tanto, avaliar as mudanças nos atributos dos solos devido ao uso e ao manejo é crucial, especialmente em relação aos atributos físico-químicos alterados pelo cultivo (Canellas *et al.*, 2003). Monitorar e quantificar as variações nos atributos do solo é essencial para compreender os efeitos do uso da terra e dos sistemas de gestão de solos.

Destaca-se que, com a agricultura de precisão (AP), o manejo da variabilidade dos atributos químicos do solo tornou-se comum em áreas agrícolas, uma vez que alterações em atributos físico-químicos podem resultar em perdas de produtividade e nutrientes (Dalla Nora *et al.*, 2013). Além do mais, os atributos de fertilidade química, física e biológica do solo apresentam variabilidade espacial e temporal, influenciando o potencial produtivo em ambientes agrícolas. Considerando que a adubação é um componente fundamental da produtividade, estudar as características do solo, por meio de frequentes análises, é essencial para a tomada de decisões no gerenciamento agrônômico das lavouras (Bernardi *et al.*, 2015).

De acordo com Viana *et al.* (*et al.*, 2019), a análise espaço-temporal teve um grande crescimento nos últimos anos, assim como a diversificação das temáticas abordadas com aplicações em ampla variedade de ramos da ciência. Dados espaço-temporais são observações tomadas em diferentes localizações no espaço e no tempo que podem ser analisados de três formas distintas: pela análise espacial para cada tempo; pela análise temporal para cada ponto no espaço e pela análise espaço-temporal conjunta (Ndongo, 2017).

A análise espacial e temporal é fundamental para o estudo da agricultura e para a avaliação dos atributos químicos do solo, pois permite identificar a variabilidade e as tendências que influenciam diretamente a produtividade agrícola e a saúde do solo. O conhecimento da variabilidade espacial e temporal dos atributos do solo é de suma

importância para a aplicação de práticas de manejo específicas que otimizam a produtividade, bem como a sustentabilidade agrícola (Nielsen; Alemi, 1989).

Estudos mostram que a análise dessas variabilidades pode revelar padrões de degradação ou melhorias no solo, permitindo intervenções mais precisas (Tomaz *et al.*, 2022). Além disso, o manejo agrícola baseado no conhecimento das características dos atributos químicos do solo pode levar a uma aplicação mais eficiente de insumos, como fertilizantes, permitindo melhorar a produtividade e reduzir os impactos ambientais (Schepers *et al.*, 2004).

O uso de diferentes técnicas estatísticas para analisar dados espaciais e temporais agrícolas tem contribuído para um melhor entendimento de padrões de comportamento de variabilidades de atributos químicos do solo, produtividade, manejo, entre outros (De Bastiani *et al.*, 2017; Dal'Canton *et al.*, 2023; Lorbieski *et al.*, 2023; Maltauro *et al.*, 2023). Dentro desse contexto, a caracterização da variabilidade dos atributos químicos do solo pode ser realizada por meio da Geoestatística Espaço-temporal, que é uma abordagem estatística empírica que analisa, de forma integrada, padrões de variação do solo no espaço e no tempo (Viana *et al.*, 2019).

Ademais, na modelagem geoestatística espaço-temporal, os modelos são especificados e os parâmetros são estimados a partir de dados observados, portanto, são utilizados a partir da coleta de dados ao longo do tempo e do espaço (De Bastiani *et al.*, 2017). Diante disso, essa abordagem permite identificar correlações entre observações feitas em diferentes locais e momentos, sendo útil para detectar padrões espaço-temporais complexos que podem ser negligenciados em análises univariadas (Montero; Aviles; Mateu, 2015).

Outra técnica estatística utilizada para caracterizar a variabilidade espaço-temporal são as Funções Ortogonais Empíricas (EOFs), que permitem decompor dados espaciais e temporais complexos em funções ortogonais que capturam padrões de variabilidade (Neha; Pasari, 2021). Essa técnica facilita a visualização de tendências na variabilidade espacial e temporal (Finkenstädt; Held; Isham, 2006), entretanto, requer dados completos, o que é desafiador devido à frequente ausência desses em pesquisas agrícolas (Dupuis; Schumacher, 2018; Şentop *et al.*, 2023).

Há também a Transformada de *Fourier de Lomb-Scargle* Discreta (LSDFT), vista como uma alternativa eficaz para analisar dados temporais não equiespaçados, criando matrizes de covariância precisas e detectando padrões temporais em séries irregulares, que são essenciais para avaliar a variabilidade em sistemas agrícolas (Seilmayer; Gonzalez; Wondrack, 2020). Além disso, a análise do espectro de

potência ajuda a identificar e avaliar eventos sazonais que influenciam os atributos químicos do solo (Pytharouli; Stiros, 2008).

A partir do pressuposto de que a análise da a variabilidade espacial e temporal dos atributos químicos do solo contribui para otimizar a produtividade agrícola e promover a sustentabilidade ambiental, objetiva-se, mediante esta tese, investigar o padrão de distribuição espaço-temporal desses atributos em uma área agrícola comercial, durante o período de 2010 a 2022, aplicando as técnicas estatísticas de Geoestatística Espaço-temporal, Funções Ortogonais Empíricas (EOFs) e Transformada de Fourier de *Lomb-Scargle Discreta* (LSDFT). Logo, com a aplicação dessas metodologias, identifica-se e compreende-se padrões de variação nos dados agrícolas, o que é crucial para aprimorar a aplicação de insumos e aumentar a eficiência no manejo do solo.

A fim de minimizar os impactos ambientais da agricultura, este estudo contribui para a aplicação de práticas sustentáveis com ganhos esperados, visando, também, proporcionar gestões agrícolas mais eficientes e precisas, avanços na agricultura de precisão e benefícios tanto para os produtores quanto para o meio ambiente.

## 2. OBJETIVOS

### 2.1 Objetivo geral

Analisar o padrão de distribuição espaço-temporal de atributos químicos do solo, durante o período de 2010 a 2022, em uma área agrícola comercial com aplicação de diferentes técnicas estatísticas.

### 2.2 Objetivos específicos

- a) Caracterizar a variabilidade espacial e temporal dos teores de cálcio, fósforo, matéria orgânica, magnésio e pH do solo de uma área agrícola comercial, durante o período de 2010 a 2022;
- b) Avaliar modelos geoestatísticos que melhor caracterizaram a estrutura de dependência espaço-temporal dos atributos químicos do solo analisado;
- c) Estudar o comportamento espaço-temporal de cada atributo químico do solo analisado por meio de semivariogramas espaço-temporais, assim como seus parâmetros espaço-temporais;
- d) Examinar a relação entre as variáveis climáticas (precipitação média diária e temperatura média diária) e os atributos químicos do solo analisado, utilizando a Análise de Correlação Canônica;
- e) Verificar o comportamento conjunto das relações espaço-temporais dos atributos químicos do solo em estudo por meio de Mapas Variográficos;
- f) Utilizar da técnica de Funções Ortogonais Empíricas (EOFs) para decompor os dados dos atributos químicos do solo analisado em modos a fim de capturar padrões dominantes de variabilidade;
- g) Gerar Mapas Temáticos das EOFs para visualizar a distribuição espacial e temporal dos atributos químicos do solo estudado;
- h) Analisar as variações regionais e identificar os anos, entre 2010 e 2022, que mais influenciaram os padrões de variabilidade;
- i) Produzir dois artigos científicos a fim de expor os resultados alcançados a partir dos objetivos listados.

### **3. REVISÃO BIBLIOGRÁFICA**

#### **3.1 Agricultura de Precisão e análise da variabilidade espaço-temporal**

A Agricultura de Precisão (AP) baseia-se no fato de que as áreas agrícolas apresentam variabilidade espacial, sendo amplamente utilizada no setor agropecuário (Grego *et al.*, 2020). Tendo como objetivo resolver problemas relacionados à falta de uniformidade do solo, a AP permite o gerenciamento localizado de culturas e alternativas de manejo conforme a necessidade (Molin *et al.*, 2013;).

No Brasil, a prática predominante da AP é a Gestão da Adubação das Lavouras, baseada em amostragem georreferenciada de solo e aplicação de corretivos e fertilizantes em taxas variáveis (Molin; Amaral; Colço, 2015; Aikes Jr. *et al.*, 2021). Ainda, a AP envolve a análise da variabilidade espacial e compreende as fases de coleta de dados, gerenciamento de informações, aplicação de insumos com teor variado e avaliação econômica e ambiental dos resultados (Basso *et al.*, 2019).

A partir do advento do *Global Positioning System* (GPS), houve a expansão de práticas de AP, permitindo que as informações coletadas fossem geograficamente referenciadas (Molin, 2002). Dessa forma, técnicas como a Geoestatística são empregadas para estudar as variabilidades (Câmara; Medeiros, 1998) e construir mapas temáticos que são essenciais para representar as características de produções e identificar locais críticos na área (Molin; Amaral; Colço, 2015).

A implementação da AP visa melhorar o rendimento econômico da atividade agrícola, aumentando a produtividade e reduzindo custos e riscos ambientais (Braga; Pinto, 2011; Bottega *et al.*, 2017). Além disso, ao otimizar o uso de fertilizantes, a AP contribui para a redução de impactos ambientais e custos desnecessários ao produtor (Bernardi *et al.*, 2014; Aikes Jr. *et al.*, 2021). Logo, identificar a A variabilidade espacial dos atributos químicos e físicos do solo permite o manejo diferenciado de acordo com a necessidade, influenciando diretamente o nível de produtividade das culturas (Guedes, 2008; Hauschild *et al.*, 2014).

#### **3.2 Variabilidade espaço-temporal de atributos químicos do solo**

A Análise espaço-temporal na agricultura combina dados coletados ao longo do tempo e em diferentes locais geográficos para fornecer uma compreensão abrangente de como esses fatores influenciam a produção agrícola (Campos; Sossa;

Pajares, 2016). Essa abordagem é essencial para otimizar as práticas de gestão, melhorar a produtividade de culturas e promover a sustentabilidade ambiental (Donald; Mengersen; Young, 2015), além de possibilitar a identificação de padrões, tendências e relações que, de outra forma, passariam despercebidos em análises unidimensionais ou estáticas (Maddison, 2009).

As Técnicas de Análise espaço-temporal oferecem uma ampla gama de aplicações na agricultura. Um exemplo notável é a identificação de áreas com maior potencial produtivo, considerando fatores como solo, clima, topografia e histórico de produção (Sun; Zhou, 2016). Ao direcionar recursos como fertilizantes e irrigação para áreas onde haverá maior impacto, os agricultores podem maximizar a produtividade e minimizar o desperdício (Julea *et al.*, 2012).

Além da otimização da produção, a Análise espaço-temporal desempenha um papel fundamental no monitoramento de pragas e doenças, gerenciamento de riscos climáticos e implementação de práticas agrícolas sustentáveis (Teslenok; Teslenok, 2020). Ao analisar dados coletados ao longo do tempo e em diferentes locais, os agricultores podem identificar focos de pragas e doenças, prever sua propagação e adotar medidas preventivas e de controle mais eficazes (Zamberletti *et al.*, 2021).

Diversas técnicas têm sido empregadas para explorar a variabilidade espaço-temporal, incluindo a Geoestatística espaço-temporal e as Funções Ortogonais Empíricas (EOF). Em seus estudos, Diacono *et al.* (2020) analisam a variabilidade espacial e temporal da produção e a qualidade do trigo em ambientes mediterrâneos, utilizando uma Abordagem Geoestatística Multivariada para identificar zonas específicas de manejo.

Além do mais, Stein (1998) oferece uma visão geral da variabilidade espaço-temporal na agricultura ao empregar a Geoestatística para modelar o desenvolvimento de doenças em plantas, como o repolho. Já em relação às EOF, Kim *et al.* (2020) aplicaram a técnica para analisar padrões espaciais e temporais na variabilidade dos rendimentos de milho em campos com diferentes tipos de fertilização.

### 3.3 Geoestatística espaço-temporal

Atribuindo  $\mathbb{R}^d$  o espaço euclidiano;  $d$  dimensional;  $D \subset \mathbb{R}^d$  o domínio espacial; e  $T \subset \mathbb{R}$  o domínio temporal, a Geoestatística Espacial pode ser estendida para o caso espaço-temporal.

Nessa situação, suas coordenadas são denominadas de espaço-temporal  $D \times T$ , com um par de elementos  $(s_i, t_i)$  – com  $s_i \in D$  e  $t_i \in T$  –, e seu campo aleatório (função aleatória) espaço-temporal em  $D \times T$  dado pelo conjunto  $\{Z(s, t): s \in D, t \in T\}$ , em que a variável aleatória  $Z(s, t)$  é vista como o atributo de interesse. A relação entre duas observações  $Z(s_i, t_i)$  e  $Z(s_j, t_j)$ , nesse caso, dependerá tanto do vetor de distância de separação espacial (*lag* espacial),  $\mathbf{h} = s_i - s_j$ , como da distância temporal (*lag* temporal),  $u = t_i - t_j$ . O par  $(\mathbf{h}, u)$  é, então, denominado como *lag* espaço-temporal (Cressie; Huang, 1999).

De forma semelhante ao caso espacial para a realização de inferências sobre algumas estatísticas dentro do contexto espaço-temporal, deve-se assumir graus de estacionariedade sobre o campo aleatório  $\{Z(s, t): s \in D, t \in T\}$  (Kyriakidis; Journel, 1999). De acordo com os pressupostos da Geoestatística Clássica, a distribuição espaço-temporal das observações é modelada como uma Distribuição Gaussiana.

Essa distribuição será perfeitamente caracterizada pela definição de seus momentos de primeira e segunda ordem, ou seja, sua função de expectativa e covariância. Assim, o espaço-temporal em  $D \times T$ , dado pelo conjunto  $\{Z(s, t): s \in D, t \in T\}$ , pode ser considerado como de segunda ordem se (Eq.1 e Eq.2; Montero; Aviles; Mateu, 2015):

$$E[Z(s_i, t_i)] = \mu(s_i, t_i) = \mu, \quad \forall (s, t) \in D \times T \quad (1)$$

$$Cov[Z(s_i, t_i), Z(s_j, t_j)] = Cov(\mathbf{h}, u), \quad \forall (s, t) \in D \times T, \quad i, j = 1, \dots, n \quad (2)$$

Sendo para quaisquer dois pares de localizações espaço-temporais  $(s_i, t_i)$  e  $(s_j, t_j) \in D \times T$  e com  $\mathbf{h} = s_i - s_j$  e  $u = t_i - t_j$  sendo a distância no espaço e no tempo, respectivamente. Dessa forma, observa-se que a média é constante e a covariância depende só de  $\mathbf{h}$  e  $u$ .

Além disso, se uma função aleatória tem uma função de covariância estacionária, então a variância não depende da localização no espaço-tempo. Nesse caso, (Eq.3, Eq.4 e Eq.5; Montero; Aviles; Mateu, 2015):

$$Var(Z(s, t)) = C(\mathbf{0}, 0) = \sigma^2 \quad (3)$$

Em que  $Cov_{st}(\mathbf{0}, 0) \geq 0$  recebe o nome de Variância a priori. Para tanto:

$$2\gamma_{st}((\mathbf{s}_i, t_i), (\mathbf{s}_j, t_j)) = \text{Var}[Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)] = E\left[\left(Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)\right)^2\right] = 2\gamma_s \quad (4)$$

Então:

$$\begin{aligned} 2\gamma_{st}(\mathbf{h}, u) &= 2\gamma_{st}((\mathbf{s}_i, t_i), (\mathbf{s}_j, t_j)) = \text{Var}[Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)] = \text{Var}[Z(\mathbf{s}_i, t_i)] + \quad (5) \\ &\text{Var}[Z(\mathbf{s}_j, t_j)] - 2\text{Cov}[Z(\mathbf{s}_i, t_i), Z(\mathbf{s}_j, t_j)] = 2\text{Cov}_{st}(\mathbf{0}, \mathbf{0}) - 2\text{Cov}_{st}(\mathbf{s}_i - \mathbf{s}_j, t_i - t_j) \\ &= 2\text{Cov}_{st}(\mathbf{0}, \mathbf{0}) - 2\text{Cov}_{st}(\mathbf{h}, u). \end{aligned}$$

Em que  $\gamma_{st}(\mathbf{h}, u)$  é a semivariância espaço-temporal, que mede a variabilidade entre dois pontos no espaço  $(\mathbf{s}_i, \mathbf{s}_j)$  e no tempo  $(t_i, t_j)$ ; e  $\text{Cov}[Z(\mathbf{s}_i, t_i), Z(\mathbf{s}_j, t_j)]$  é a covariância entre  $Z(\mathbf{s}_i, t_i)$  e  $Z(\mathbf{s}_j, t_j)$ , que mede a interdependência entre as duas observações nos pontos  $(\mathbf{s}_i, t_i)$  e  $(\mathbf{s}_j, t_j)$ .

Assim como na Geoestatística Espacial, a pressuposição de estacionariedade da hipótese intrínseca, na Geoestatística Espaço-temporal, é considerada suficiente para a inferência de algumas estatísticas oriundas de processos de medição de fenômenos. Um campo aleatório,  $\{Z(\mathbf{s}, t) : \mathbf{s} \in D, t \in T\}$ , pode ser considerado intrinsecamente estacionário quando para quaisquer duas coordenadas espaço-temporais  $(\mathbf{s}_i, t_i)$ ,  $(\mathbf{s}_j, t_j)$  em  $D \times T$ , a variável aleatória  $Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)$  é estacionária de segunda ordem, ou seja (Eq.6 e Eq.7; Cressie; Huang, 1999):

$$E[Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)] = 0 \quad (6)$$

E

$$\text{Var}[Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)] = E\left\{[Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)]^2\right\} = 2\gamma_{st}(\mathbf{h}, u). \quad (7)$$

A complexidade da análise espaço-temporal está diretamente relacionada com a presença, ou não, de algumas características importantes, como a estacionariedade, a separabilidade e a simetria completa (Gneiting; Raftery, 2007). Somente após o estudo dessas características possível é possível avaliar a complexidade da modelagem.

De acordo com Montero; Aviles; Mateu (2015), uma Função Aleatória Espaço-temporal  $Z(\mathbf{s}, t)$  é vista com uma função de covariância separável se existir uma função de covariância puramente espacial,  $\text{Cov}_s(\mathbf{s}_i, \mathbf{s}_j)$ , e uma função de covariância puramente temporal,  $\text{Cov}_t(t_i, t_j)$ , de modo que:

$$Cov_{st}((s_i, t_i), (s_j, t_j)) = Cov_s(s_i, s_j)Cov_t(t_i, t_j), \forall ((s_i, t_i), (s_j, t_j)) \in \{Z(s, t): s \in D, t \in T\}. \quad (8)$$

A separabilidade garante que, ao dividir a covariância espaço-temporal em produto puramente espacial e puramente temporal, sejam realizadas inferências mais eficientes em termos computacionais, sendo esse um dos motivos pelo qual modelos desse tipo sejam muito utilizados em aplicações na Geoestatística. Se a separação em puramente espacial e em puramente temporal não for possível, então a função de covariância será chamada de Não-separável (Montero; Aviles; Mateu, 2015).

Para verificar a separabilidade, podem ser empregadas diversas técnicas. Fuentes (2006) testa essa hipótese ajustando modelos de covariância separáveis e não-separáveis, comparando-os por meio de uma Análise Espectral. Outra abordagem é o uso do Critério de Informação de Akaike (AIC) para escolher entre os modelos, como visto em Bevilacqua *et al.* (2010), que aplicam testes de máxima verossimilhança ponderada e *bootstrap*.

Já Constantinou *et al.* (2015) sugerem o uso da distância de *Frobenius* entre a covariância espaço-temporal e sua aproximação separável. Além disso, gráficos de contorno de covariância podem indicar interações espaço-temporais, como discutido por Gneiting *et al.* (2007), que argumentam que modelos não separáveis frequentemente melhoram as previsões.

As funções de covariância espaço-temporais separáveis podem ser definidas com base nas propriedades de aditividade (Eq.9) e multiplicabilidade (Eq.10). dessa forma, a função de covariância pode ser decomposta entre uma função de covariância puramente espacial e outra puramente temporal (Silva; Ribeiro Jr; Elmatzoglou, 2007).

No caso aditivo ela pode ser descrita como:

$$Cov[Z(s_i, t_i), Z(s_j, t_j)] = Cov(Z(s_i, s_j)) + Cov(Z(t_i, t_j)) \quad (9)$$

E no caso multiplicativo:

$$Cov[Z(s_i, t_i), Z(s_j, t_j)] = Cov(Z(s_i, s_j)) Cov(Z(t_i, t_j)) \quad (10)$$

Essa classe de modelos, embora simplista por não considerar a interação entre espaço e o tempo, é muito utilizada por ser computacionalmente tratável e de simples obtenção (Silva; Ribeiro Jr; Elmatzoglou, 2007).

Ademais, uma função aleatória espaço-temporal possui simetria completa se a sua função de covariância for definida como (Eq. 11, Montero; Aviles; Mateu, 2015):

$$Cov[(s_i, t_i), (s_j, t_j)] = Cov[(s_i, t_j), (s_j, t_i)] \quad \forall ((s_i, t_i), (s_j, t_j) \in \{Z(s, t): s \in D, t \in T\}). \quad (11)$$

De acordo com Montero; Aviles; Mateu (2015), nos casos em que há estacionariedade, a condição de simetria completa pode ser expressa por:

$$Cov(\mathbf{h}, u) = Cov(\mathbf{h}, -u) = Cov(-\mathbf{h}, u) = Cov(-\mathbf{h}, -u) = C[||\mathbf{h}||, |u|], \quad (\mathbf{h}, u) \in D \times T. \quad (12)$$

Verifica-se que a separabilidade é um caso particular de simetria completa, pois uma função de covariância separável é sempre totalmente simétrica, mas não vice-versa, ocasionando implicações no teste e no ajuste do modelo. Em particular, para rejeitar a separabilidade, basta rejeitar a simetria total, portanto, as estruturas de covariância que não são completamente simétricas são consideradas não-separáveis (Gneiting *et al.*, 2006).

De acordo com Montero; Aviles; Mateu (2015), expressar a estrutura da dependência espaço-temporal presente na realização observada por meio de uma função (de covariância ou de semivariância) é a questão chave no processo da *krigagem* espaço-temporal. Essa estrutura pode ser deduzida a partir das realizações observadas na prática e, assim, é possível construir a função de covariância ou semivariograma.

De acordo com Gneiting; Genton; Guttorp (2007), funções de semivariâncias também podem ser usadas no lugar de funções de covariância para modelar a estrutura de segunda ordem de uma função aleatória espaço-temporal. Assim, a semivariância é dada conforme como:

$$\gamma_{st}((s_i, t_i), (s_j, t_j)) = \frac{1}{2} E \left\{ \left( Z(s_i, t_i) - Z(s_j, t_j) \right)^2 \right\} \quad (13)$$

Também, é necessário, sempre que for possível, definir a função de covariância (Eq.14) e o semivariograma (Eq.15):

$$\gamma_{st}((s_i, t_i), (s_j, t_j)) = \frac{1}{2} \text{Var}[Z(s_i, t_i)] + \frac{1}{2} \text{Var}[Z(s_j, t_j)] - \text{Cov}[Z(s_i, t_i), Z(s_j, t_j)] \quad (14)$$

Disso, tem-se que:

$$\gamma_{st}(\mathbf{h}, u) = \text{Cov}_{st}(\mathbf{0}, 0) - \text{Cov}_{st}(\mathbf{h}, u) \quad (15)$$

A expressão vista na Eq. 15, mostra a relação da semivariância com a função de covariância, sob estacionariedade. Entretanto, o caminho inverso geralmente não é garantido, pois essa relação só é verificada se a semivariância,  $\gamma_{st}(\mathbf{h}, \mu)$ , for limitada, o que não é necessariamente o caso intrinsecamente estacionários. Nessa condição, a propriedade de separabilidade não faz sentido para a semivariância espaço-temporal, pois o seu produto não garante uma semivariância válida. Entretanto, é possível generalizar outras propriedades, como a simetria total (Montero; Aviles; Mateu, 2015).

Portanto, um campo aleatório espaço-temporal contém uma semivariância intrinsecamente estacionária no espaço se para qualquer par de  $(s_i, t_i)$ ,  $(s_j, t_j)$ , em  $D \times T$ , a função semivariância  $\gamma_{st}((s_i, t_i), (s_j, t_j))$  somente depende do *lag* espacial,  $\mathbf{h} = s_i - s_j$ , e dos tempos,  $t_i$  e  $t_j$ . Esse mesmo campo aleatório é visto como intrinsecamente estacionário no tempo, se para qualquer par de  $(s_i, t_i)$ ,  $(s_j, t_j)$  a função semivariância somente depende do *lag* temporal,  $u = t_i - t_j$ , e dos pontos  $s_i$  e  $s_j$ . Se a função aleatória espaço-temporal vista como intrinsecamente estacionária em ambos – o espaço e tempo –, então como é uma função semivariância intrinsecamente estacionária, que pode ser expressa como:  $\gamma_{st}((s_i, t_i), (s_j, t_j)) = \gamma(\mathbf{h}, u)$  (Varouchakis, 2019).

A função semivariância  $\gamma_{st}(\mathbf{h}, \mu)$  pode ser expressa por meio de uma generalização do estimador clássico de Matheron (1989), dado pela Eq.16 (Montero; Aviles; Mateu, 2015):

$$\gamma_{st}(\mathbf{h}, u) = \frac{1}{N(\mathbf{h}, u)} \sum_{i=1}^{N(\mathbf{h}, u)} [Z(s_i, t_i) - Z(s_j, t_j)]^2 \quad (16)$$

Em que:  $Z(s_i, t_i)$  e  $Z(s_j, t_j)$  são pares de observações da função aleatória espaço-temporal  $Z(s, t)$ , separadas por um lag espacial  $\mathbf{h} = s_i - s_j$  e um lag temporal  $u = t_i - t_j$ ; e  $N(\mathbf{h}, u)$  como o número de pares de observações separadas pelo lag espaço-temporal  $(\mathbf{h}, u)$ .

Entretanto, as funções de semivariância por si só não cumprem os requisitos necessários para que uma função seja um modelo válido, o que exige que uma coleção de modelos válidos seja necessária (quanto maior, melhor) para ajustar um deles à contraparte empírica (Montero; Aviles; Mateu, 2015).

### 3.4 Modelos espaço-temporais

Segundo De Iaco; Palma; Posa (2016), é possível ajustar um modelo de covariância espaço-temporal a partir de uma superfície empírica, como um semivariograma. Para modelar funções de covariância espaço-temporal a fim de garantir que o modelo seja definido como positivo, é necessário conhecer as características da superfície da covariância espaço-temporal empírica, uma vez que essas podem ajudar a selecionar uma função que melhor se ajuste.

De acordo com Montero; Aviles; Mateu (2015), diversos modelos com características diferentes foram criados em distintas classes de funções. Já o ajuste a um semivariograma ou um covariograma pode ser feito manualmente, ou utilizando processos automatizados ou, ainda, ambos.

O objetivo principal é que o modelo escolhido capture o tipo de continuidade assumida pela variável regionalizada. Dessa forma, apresenta-se, a seguir, alguns dos principais modelos de covariância e semivariância espaço-temporais.

#### 3.4.1 Modelo métrico

Nesse modelo, são combinadas as distâncias espacial, temporal e espaço-temporal por uma correção de anisotropia espaço-temporal,  $c > 0$  (número de unidades espaciais equivalentes a uma unidade temporal), e resulta em um único modelo de covariância conjunto,  $Cov_{st}$ , para as covariâncias espacial e temporal, com possíveis mudanças no alcance. O modelo métrico em estacionariedade é expresso pela Eq.17 (Montero; Aviles; Mateu, 2015):

$$Cov(\mathbf{h}, u) = Cov(\|\mathbf{h}\| + c|u|) \quad (\mathbf{h}, u) \in D X T, \quad c > 0 \quad (17)$$

Em que  $\|\mathbf{h}\|$  e  $c|u|$  são distâncias no  $D X T$  e  $c$  é uma constante positiva.

Uma alternativa para o modelo métrico é utilizar a métrica equivalente,  $\|\mathbf{h}\|^2 + c|u|^2$ , ou a métrica  $\sqrt{c_1^2\|\mathbf{h}\|^2 + c_2^2|u|^2}$  no lugar de  $\|\mathbf{h}\| + c|u|$  (Eq.18 e Eq.19), respectivamente:

$$Cov(\mathbf{h}, u) = Cov(\|\mathbf{h}\|^2 + c|u|^2) \quad (\mathbf{h}, u) \in D X T, \quad c > 0 \quad (18)$$

Ou

$$Cov(\mathbf{h}, u) = Cov\left(\sqrt{c_1^2\|\mathbf{h}\|^2 + c_2^2|u|^2}\right) \quad (\mathbf{h}, u) \in D X T \quad (19)$$

Assim, mesmo que tenham alcances diferentes, as funções de covariância marginal espacial e marginal temporal seguem a um mesmo tipo de modelo, independentemente das métricas utilizadas. Quanto a função semivariância, quando em estado estacionário, o modelo métrico pode ser expresso conforme apresentado na Eq.20 (Montero; Aviles; Mateu, 2015):

$$\begin{aligned} \gamma(\mathbf{h}, u) &= \gamma\left(\sqrt{c_1^2\|\mathbf{h}\|^2 + c_2^2|u|^2}\right) \\ &= Cov(\mathbf{0}, \mathbf{0}) - Cov\left(\sqrt{c_1^2\|\mathbf{h}\|^2 + c_2^2|u|^2}\right) \quad (\mathbf{h}, u) \in D X T \end{aligned} \quad (20)$$

Na tipologia em questão,  $c$  (nos primeiros dois tipos) e  $c_1$  e  $c_2$  (no terceiro) são constantes que definem as métricas espaço-temporais e nada mais são do que os fatores anisotrópicos (anisotropia geométrica ou elíptica) entre os eixos de distância espacial e desfaseamento de tempo, que determinam as diferentes gamas espaciais e temporais (Montero; Aviles; Mateu, 2015).

### 3.4.2 Modelo soma

O modelo de soma consiste em decompor a covariância espaço-temporal na soma de uma função de covariância puramente espacial e uma função de covariância puramente temporal. Por essa razão, é conhecido como um modelo linear zonal, no qual a anisotropia zonal é tratada pela soma de funções de covariância (Montero; Avilés; Mateu, 2015).

Considerando-se duas funções de covariância estacionárias,  $Cov_s$  (covariância espacial) e  $Cov_t$  (covariância temporal), como exposto na Eq. 21:

$$Cov(\mathbf{h}, u) = Cov_s(\mathbf{h}) + Cov_t(u), \quad (\mathbf{h}, u) \in D \times T. \quad (21)$$

A versão da função semivariância desse tipo de modelo é dada, no caso estacionário, pela Eq.22:

$$\gamma_{st}(\mathbf{h}, u) = \gamma_s(\mathbf{h}) + \gamma_t(u), \quad (\mathbf{h}, u) \in D \times T. \quad (22)$$

### 3.4.3 Modelo soma-métrico

O modelo de covariância soma-métrico,  $Cov_{sm}$ , é uma combinação do modelo soma e do modelo métrico, com todas as componentes configuradas independentemente. No caso estacionário, ao utilizar a métrica  $\sqrt{\|\mathbf{h}\|^2 + c^2|\mu|^2}$ , a função covariância é dada, conforme consta na Eq.23 (Viana *et al.*, 2019):

$$Cov_{sm}(\mathbf{h}, u) = Cov_s(\mathbf{h}) + Cov_t(u) + Cov_{st}\left(\sqrt{\|\mathbf{h}\|^2 + c^2|\mu|^2}\right), \quad (\mathbf{h}, \mu) \in D \times T \quad (23)$$

Já a função semivariância é dada pela Eq.24:

$$\gamma_{sm}(\mathbf{h}, u) = \gamma_s(\mathbf{h}) + \gamma_t(u) + \gamma\left(\sqrt{\|\mathbf{h}\|^2 + c^2|\mu|^2}\right), \quad (\mathbf{h}, \mu) \in D \times T \quad (24)$$

Em que  $\gamma_s(\cdot)$ ,  $\gamma_t(\cdot)$  e  $\gamma_{st}(\cdot)$  são, respectivamente, as funções semivariâncias puramente espacial, puramente temporal e função semivariância, cada qual com seus parâmetros configurados independentes (Viana *et al.*, 2019).

### 3.4.4 Modelo soma-produto

O modelo soma-produto é uma generalização do modelo produto e do modelo soma (De Cesare *et al.*, 2002). É definido pela Eq.25 como:

$$Cov_{st}(\mathbf{h}, \mu) = k_1 Cov_s(\mathbf{h}) Cov_t(\mu) + k_2 Cov_s(\mathbf{h}) + k_3 Cov_t(\mu), \quad (h, \mu) \in D \times T \quad (25)$$

Ou equivalentemente em termos de semivariograma:

$$\begin{aligned} \gamma_{st}(\mathbf{h}, \mu) = & (k_2 + k_1 Cov_t(0)) \gamma_s(\mathbf{h}) + (k_3 + k_1 Cov_s(0)) \gamma_t(u) \\ & - k_1 \gamma_s(\mathbf{h}) \gamma_t(u), \quad (h, u) \in D \times T \end{aligned} \quad (26)$$

Em que:  $Cov_s$  e  $Cov_t$  são funções de covariância;  $\gamma_s$  e  $\gamma_t$  são os semivariogramas correspondentes; e  $k_1 > 0$ ,  $k_2 > 0$ ,  $k_3 > 0$  são constantes que garantem a validade. Assim,  $Cov_{st}(\mathbf{0}, \mathbf{0})$  é o patamar de  $\gamma_{st}$ , denominado patamar global;  $Cov_s(\mathbf{0})$  é o patamar de  $\gamma_s$ ; e  $Cov_t(0)$  é o patamar de  $\gamma_t$  (patamares parciais).

Há, ainda, uma diversidade de outros modelos que formam a covariância espaço-temporal, como Produto Integrado (De Iaco; Myers; Posa, 2002), Função Distribuição Espectral da Covariância (Cressie; Huang, 1999), Funções de Média Quase-aritméticas (Porcu; Mateu; Christakos, 2009), além de modelos específicos para dados não-estacionários (Porcu; Mateu, 2007), para capturar e estudar a anisotropia (Porcu; Gregori; Mateu, 2006), para dados não-inteiramente simétricos (Gneiting; Genton; Guttorp, 2007), entre outros.

### 3.5 Krigagem espaço-temporal

Uma vez construído e ajustado o semivariograma por meio do conjunto de dados, é realizada a predição por meio da *Krigagem* Espaço-temporal. Esse tipo de *krigagem* tem como objetivo predizer valores de locais não amostrados,  $\hat{Z}(s_0, t_0)$ . Para isso, todas as informações disponíveis sobre a variável regionalizada são utilizadas, seja em pontos de todo o domínio seja em um subconjunto denominado vizinhança (Montero; Aviles; Mateu, 2015).

A estimação geoestatística espaço-temporal é, então, alcançada usando a *Krigagem* Ordinária Espaço-temporal (Christakos, 1991). O estimador é dado conforme a Eq.27:

$$\hat{Z}(s_0, t_0) = \sum_{i=1}^n \lambda_i Z(s_i, t_i) \quad (27)$$

Em que:  $\sum_{i=1}^n \lambda_i = 1$ ,  $0 \leq \lambda_i \leq 1$  e  $s_0$  é o conjunto de pontos de amostragem na vizinhança de pesquisa do ponto de predição;  $\hat{Z}(s_0, t_0)$  são os pontos no espaço-tempo não amostrado;  $Z(s_i, t_i)$  são os pontos no espaço-tempo amostrados; e  $\lambda_i$  são os pesos correspondentes a *krigagem* espaço-temporal.

As equações para *krigagem* no domínio espaço-temporal são semelhantes as equações da *Krigagem* Ordinária Espacial, cujos detalhes podem ser encontrados nos estudos de Montero; Aviles e Mateu (2015).

### 3.6 Funções Ortogonais Empíricas (EOFs)

Desde que as EOFs foram introduzidas na ciência atmosférica por Lorenz (1956), tornaram-se uma ferramenta estatística de importância fundamental nos estudos de atmosfera, oceanos e ciência climática para análises exploratórias de dados e redução de modos dinâmicos.

A técnica de EOF busca encontrar um novo conjunto de variáveis que capturem a maior parte da variância observada dos dados por meio de uma combinação linear das variáveis originais. Ademais, a EOF se caracteriza pela de compressão de dados e pela redução de dimensionalidade (Baldwin; Stephenson; Jolliffe, 2009) nas quais dados espaço-temporais em modos espaciais são classificados por suas variâncias temporais.

As EOFs são obtidas ao calcular autovalores e autovetores de uma matriz de covariância ponderada. A técnica comprime a variabilidade espacial dos dados em alguns autovetores, resultando em modos espaciais e funções de amplitude temporal. Os modos espaciais fornecem informações sobre padrões espaciais, enquanto as funções de amplitude temporal descrevem a dinâmica (Debnath; Sinha, 2022).

O componente principal associado a cada EOF fornece a variação temporal do sinal e a amplitude geral da EOF. Isso significa que, ao calcular o componente principal, entende-se como a força (amplitude) e a forma (sinal) do padrão de variabilidade representado pelo EOF mudam ao longo do tempo.

Esse procedimento simplifica a representação do conjunto de dados em um determinado momento. Para tanto, utilizando uma base ortogonal, as EOFs permitem

decompor a complexa variabilidade de um conjunto de dados em componentes mais simples.

Cada componente representa um padrão espacial distinto e suas variações temporais. Em outras palavras, as EOFs não alteram a estrutura do conjunto de dados, mas organizam as informações de maneira que facilite a visualização e a análise das principais tendências de variabilidade. Esse método é utilizado para descrever a variabilidade de conjuntos de dados em termos de padrões espaciais e suas mudanças temporais (Debnath; Sinha, 2022).

Os padrões obtidos podem ser representados graficamente em mapas espaciais destinados a várias utilidades, entre elas, identificar teleconexões e padrões de variabilidade climática, como a Oscilação Decadal do Pacífico ou a Oscilação Ártica (Zhang; Moore, 2015). Além disso, os mapas espaciais derivados das EOFs permitem a compressão eficiente de dados, facilitando a identificação de padrões homogêneos em séries temporais complexas (Rao; Hsieh, 1991; Petitgas *et al.*, 2014).

Essas funções são especialmente úteis na análise de variabilidade espacial e temporal em dados agrícolas e do solo, nas quais a identificação de padrões ocultos pode fornecer informações valiosas para gestão e tomada de decisões (Kim *et al.*, 2020). Por exemplo, em um estudo sobre a umidade do solo, as EOFs podem revelar padrões sazonais e tendências espaciais que seriam difíceis de identificar com análises tradicionais (Jawson; Niemann, 2007).

Outro exemplo é dado por Kim *et al.* (2020), no qual EOFs foram usadas para analisar os padrões espaciais e temporais dos rendimentos de milho (*Zea mays L.*) em três campos hidrologicamente delimitados. Os campos receberam diferentes tipos de fertilizantes (orgânico e químico) e a análise revelou que o primeiro modo de EOF explicou entre 52% e 56% da variabilidade interanual dos rendimentos. Assim, destacou-se que aplicação precisa de fertilizantes nitrogenados minimizou a variabilidade dos rendimentos associada aos padrões de fluxo preferenciais do subsolo.

#### 4. METODOLOGIA GERAL

A partir do objetivo de analisar o padrão de distribuição espaço-temporal de atributos químicos do solo utilizando diferentes técnicas, foram elaborados dois artigos que utilizaram dados de atributos químicos do solo, coletados antes do plantio e do desenvolvimento da soja em nove safras, entre 2010 e 2022, em uma área de 167,35ha em Cascavel, Paraná.

O solo analisado classifica-se como Latossolo Vermelho Distroférico típico (Santos *et al.*, 2018), de textura argilosa, e a área tem altitude média de 650m. O clima é classificado como Cfa, com temperatura média anual de 21°C (Aparecido *et al.*, 2016).

Foram determinados 102 pontos amostrais utilizando a técnica *lattice plus close pairs*, que distribui uniformemente os pontos de amostragem (Maltauro *et al.*, 2023). Não houve coleta de dados em 2011, 2017, 2018 e 2020, portanto, não há informações sobre os valores das variáveis estudadas para estes anos.

No primeiro artigo, aplicou-se as técnicas da Geoestatística Espaço-temporal, com as quais foram geradas semivariogramas experimentais que foram, posteriormente, e ajustadas a um modelo. Mesmo com a falta de dados para alguns anos-safras, foi possível realizar a análise mediante essa abordagem I, pois, de acordo com Kyriakidis; Journel (1999), essa ferramenta não requer regularidade de amostragem no espaço ou no tempo.

Os modelos espaço-temporais utilizados foram disponibilizados pelo pacote *gstat* do *Software R* (Pebesma, 2004), sendo esses os modelos de: soma, soma-produto, métrico, soma-métrico e soma-métrico simples. Dessa forma, foram analisados os semivariogramas e os parâmetros geoestatísticos espaço-temporais disponibilizados por cada modelo para caracterizar os diferentes componentes (puramente espacial, puramente temporal e espaço-temporal conjunta).

Para verificar a correlação entre a variabilidade temporal e os fatores climáticos, como temperatura e precipitação, foi utilizada a Análise de Correspondência Canônica. Por fim, foram gerados mapas temáticos de cada atributo químico do solo por meio da *Krigagem Ordinária Espaço-temporal*, sendo a caracterização desses, conjuntamente com os resultados obtidos anteriormente, utilizados para caracterizar a variabilidade espaço-temporal desses atributos.

No segundo artigo, utilizou-se das EOFs para avaliar a variabilidade espaço-temporal, sendo essas são autovetores resultantes da decomposição espectral de

uma matriz de covariância. Em sua forma discreta, a análise EOF é análoga à Análise de Componentes Principais (PCA). Nesse sentido, as EOFs foram aplicadas a fim identificar as principais estruturas espaciais e suas variações temporais, bem como para reduzir a dimensão e o ruído em grandes conjuntos de dados espaço-temporais (Cressie; Wikle, 2015).

Devido à ausência de coletas em alguns anos safra (2011, 2017, 2018, 2020), os dados do estudo são irregulares, dificultando a aplicação direta das EOFs. A principal dificuldade é com relação ao cálculo da matriz de covariância.

Para contornar isso, utilizou-se a Transformada Discreta de *Fourier de Lomb-Scargle* (LSDFT), que avalia precisamente os elementos da matriz de covariância no espaço espectral, usando todos os dados disponíveis e gerenciando grandes lacunas sem necessidade de interpolação, preservando assim a informação original (Scargle, 1989). Assim, a matriz de covariância foi calculada no espaço espectral utilizando a LSDFT, permitindo, assim, o uso de todas as observações disponíveis. Esse cálculo envolve transformar dois conjuntos de dados, multiplicando um pelo conjugado complexo do outro e aplicando a transformada inversa.

Por fim, foi realizada a análise dos espectros de potência, sendo essa útil para se entender a variabilidade temporal em dados não-equiespaçados. Essa técnica é utilizada para identificar e estudar periodicidades e é gerada por meio do cálculo da densidade de potência espectral da LSDFT (Pytharouli; Stiros, 2007; Dupuis; Schumacher, 2018). Para tanto, aponta-se que maiores detalhes sobre as metodologias aplicadas podem ser encontrados na quinta seção deste trabalho, na qual estão expostos os artigos para a metodologia corresponde ao artigo 1 e na seção 7.2 para a metodologia correspondente ao artigo 2.

## 5. ARTIGOS

### 5.1 Artigo 1: Análise Geoestatístico Espaço-Temporal De Atributos Químicos Do Solo Em Uma Área Agrícola Produtora De Soja

#### ANÁLISE GEOESTATÍSTICO ESPAÇO-TEMPORAL DE ATRIBUTOS QUÍMICOS DO SOLO EM UMA ÁREA AGRÍCOLA PRODUTORA DE SOJA

**Resumo:** Este estudo teve como objetivo principal compreender como os atributos químicos do solo variam ao longo do tempo e do espaço, fornecendo informações valiosas para a gestão agrícola sustentável. Para isso, investigou-se a variabilidade espaço-temporal dos atributos químicos do solo em uma área comercial de cultivo de soja entre os anos safra de 2010 e 2022 por meio da geoestatística espaço-temporal. Diferentes modelos geoestatísticos de funções semivariâncias espaço-temporal foram considerados, destacando-se os modelos soma-métrico e soma-métrico simples. Foram utilizados também diversos modelos geoestatísticos para caracterizar cada uma das componentes que formam a estrutura espaço-temporal (puramente espacial, puramente temporal e espaço-temporal conjunto), com destaque para o modelo wave para a componente puramente temporal e o modelo da família Matérn com parâmetro de suavização  $k=0,3$  para a componente espaço-temporal. Espacialmente, os atributos químicos do solo apresentaram moderada dependência, com alcance restrito a pequenas regiões, e aparente estabilização da variabilidade ao longo do tempo. Temporalmente, esses atributos demonstraram de moderada a forte dependência, com alcance variando de um a seis anos, além de uma importante relação com variáveis climáticas medidas por meio da análise de correlação canônica. A variabilidade espaço-temporal conjunta evidenciou dependência de fraca a moderada, indicando uma pequena interação entre os componentes espacial e temporal. Em geral, o estudo sugere que a variabilidade dos atributos químicos do solo é mais sensível a influências temporais, enquanto espacialmente há uma estabilização aparente da variabilidade. Cabe destacar a importância da geoestatística espaço-temporal ao possibilitar uma análise mais abrangente e dos atributos químicos do solo em ambientes agrícolas, permitindo uma melhor compreensão das variações ao longo do tempo e espaço, e fornecendo informações valiosas para a gestão agrícola sustentável.

**Palavras-chave:** Função Semivariância; Geoestatística; Modelos Geoestatísticos; Variabilidade Espacial e Temporal.

#### 5.1.1 Introdução

A produção agrícola no oeste do Paraná se destaca pela predominância de culturas como soja e milho, que são favorecidas pelas condições climáticas e características do solo da região. A soja é amplamente cultivada, principalmente pela alta demanda internacional e pelo seu valor para exportação. O milho, por sua vez, é frequentemente cultivado em rotação com a soja, o que contribui para a manutenção da fertilidade do solo e controle de praga (Dabessa; Debala, 2023; Wang *et al.*, 2023).

Considerando a relevância da fertilidade do solo para a produtividade da soja, a análise do solo é fundamental para um manejo agrônomo eficiente (Bernardi *et al.*,

2017). Os atributos químicos do solo, variam no espaço e no tempo, afetando a produtividade agrícola (Resende; Coelho, 2014).

Assim, compreender a variabilidade espaço-temporal é crucial para otimizar a aplicação de fertilizantes e aumentar a produtividade, especialmente em culturas como a soja (Noetzold *et al.*, 2019). A caracterização dessa variabilidade pode ser realizada pela geoestatística espaço-temporal que é uma abordagem estatística que analisa de forma integrada padrões de variação do solo no espaço e no tempo (Viana *et al.*, 2019).

A modelagem Geoestatística Espaço-temporal é uma abordagem empírica onde o modelo é especificado e seus parâmetros são estimados a partir de dados observados. Modelos espaço-temporais surgem quando os dados são coletados ao longo do tempo, bem como do espaço (De Bastiani *et al.*, 2017). Essa abordagem identifica correlações entre observações em diferentes locais e momentos. Isso é vantajoso para identificar padrões espaço-temporais complexos, geralmente negligenciados em análises univariadas (Montero; Aviles; Mateu, 2015).

Trabalhos que consideram conjuntamente a relação espaço-temporal no estudo dos atributos químicos do solo não são comuns de se encontrar, quando levado em conta a questão temporal é mais comum encontrar trabalhos que comparam sua evolução por meio de análises espaciais tomadas em diferentes anos, como por exemplo Yang *et al.* (2021) que realizou o estudo de atributos do solo (carbono e nitrogênio) por meio de Geoestatística Clássica para os anos de 1980 e 2010 para explorar os possíveis fatores de influência e seus efeitos nas variações temporais e espaciais do solo.

De forma semelhante, a Geoestatística Espacial, tomada em diferentes anos também, foi usada por Zhuo *et al.* (2019) para caracterizar a evolução espaço-temporal dos atributos químicos do solo. De acordo com esses autores, como o conhecimento dos fatores que influenciam os micronutrientes disponíveis no solo em escalas de longo prazo é limitado.

Para tanto, o estudo de Zhuo *et al.* (2019) analisou amostras de solo de cinco sub-bacias em Pequim, China, entre os anos de 2007 e 2017, com o objetivo de avaliar as características de distribuição temporal e espacial dos micronutrientes disponíveis no solo (Cu, Zn, Fe e Mn) e suas relações com os atributos químicos do solo. No entanto, segundo Viana *et al.* (2019), o estudo da análise espaço-temporal vem crescendo, assim como a diversificação das temáticas abordadas com aplicações em ampla variedade de ramos da ciência.

Diante disso, a Geoestatística Espaço-temporal se destaca como uma ferramenta crucial na análise dos atributos químicos do solo em ambientes agrícolas, pois incorpora parâmetros espaciais e temporais. Essa abordagem permite uma perspectiva mais completa das variações nos atributos do solo ao longo do tempo e do espaço.

Ao integrar a dimensão temporal, a Geoestatística Espaço-temporal possibilita a compreensão das mudanças sazonais e tendências ao longo dos anos, oferecendo informações para a gestão agrícola sustentável. Assim, o objetivo deste trabalho é investigar a variabilidade espaço-temporal dos atributos químicos do solo em uma área comercial de cultivo de soja entre 2010 e 2022.

Para isso, utiliza-se de diferentes modelos geoestatísticos para caracterizar as componentes espacial, temporal e espaço-temporal da variabilidade. O estudo buscou compreender como esses atributos variam ao longo do tempo e do espaço, visando fornecer informações valiosas para a gestão agrícola sustentável.

## 5.1.2 Metodologia

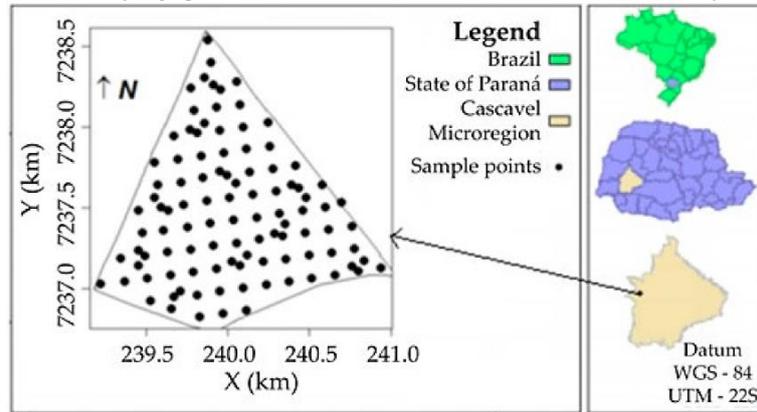
### 5.1.2.1 Área de Estudo

O estudo foi realizado com dados dos atributos químicos do solo: teor de cálcio (Ca) ( $\text{cmolc dm}^{-3}$ ), teor de fósforo (P) ( $\text{mg dm}^{-3}$ ), teor de matéria orgânica (MO) ( $\text{g dm}^{-3}$ ), pH ( $\text{CaCl}_2$ ) e teor de magnésio (Mg) ( $\text{cmolc dm}^{-3}$ ), coletados anteriormente ao plantio e desenvolvimento da soja, em nove anos safras, do período de 2010 até 2022, em uma área agrícola comercial de produção de grãos com 167,35ha (Figura 1) localizada no município de Cascavel, Paraná – Brasil, nas coordenadas 24.95° S 53.37° W.

A altitude média nessa área é de 650 m. O solo é classificado como Latossolo Vermelho Distroférrico típico (Santos *et al.*, 2018) ou Oxisols (Taxonomia do Solo), com textura argilosa. O clima da região é classificado como mesotérmico e temperado superúmido, do tipo climático Cfa (sistema de classificação de Köppen), e a temperatura média anual é de 21 °C (Aparecido *et al.*, 2016).

Nessa área, foram determinados 102 pontos amostrais utilizando a amostragem *lattice plus close pairs* (Figura 1), que possibilita uma distribuição uniforme de pontos de amostragem em toda a área de estudo (Uribe-Opazo *et al.*, 2021; Maltauro *et al.*, 2023). Nos anos de 2011, 2017, 2018 e 2020 não foram realizadas as coletas de dados, portanto, não há informações sobre os valores dos atributos químicos do solo estudados para esses anos.

Figura 1. Representação do gráfico com os pontos de amostragem (Sistema de coordenadas planas, projeção UTM, zona 22 Sul, datum SIRGAS 2000).



Fonte: Os Autores (2024).

### 5.1.2.2 Análise Geoestatística Espaço-Temporal

O estudo da variabilidade espaço-temporal dos atributos químicos do solo foi realizado por meio da análise do semivariograma espaço-temporal gerado pela Eq.1 e dos modelos geoestatísticos ajustados a ele (Eq.2, Eq.3, Eq.4, Eq.5 e Eq.6). A função de semivariância estimada,  $\hat{\gamma}_{st}(\mathbf{h}, \mu)$ , é expressa por meio de uma generalização do estimador clássico de Matheron (1989) puramente espacial (Eq. 1; Montero; Aviles; Mateu, 2015):

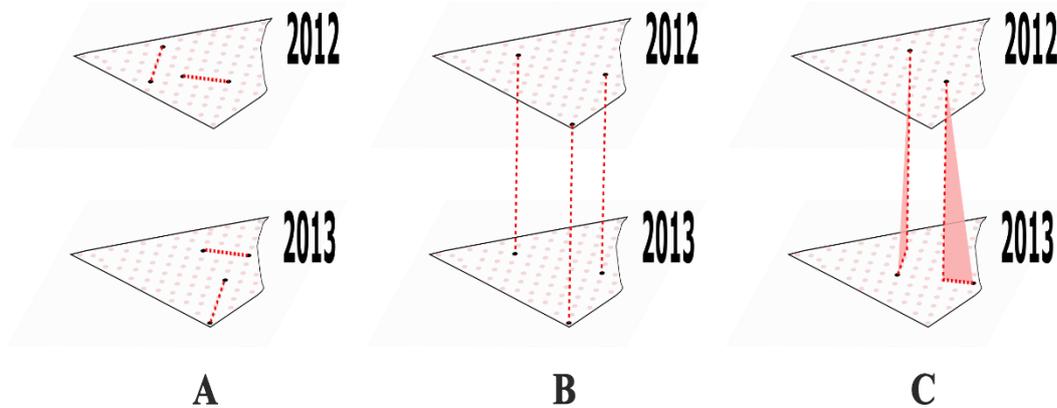
$$\hat{\gamma}_{st}(\mathbf{h}, \mu) = \frac{1}{N(\mathbf{h}, u)} \sum_{i=1}^{N(\mathbf{h}, u)} [Z(\mathbf{s}_i, t_i) - Z(\mathbf{s}_j, t_j)]^2, \quad (1)$$

Em que:  $Z(\mathbf{s}_i, t_i)$  e  $Z(\mathbf{s}_j, t_j)$  são pares de valores amostrais das variáveis georreferenciadas, observados de forma espaço-temporal, separados por um *lag* espacial omnidirecional,  $\mathbf{h} = \mathbf{s}_i - \mathbf{s}_j$ , com  $\mathbf{s}_i, \mathbf{s}_j \in \mathbf{D} \subset \mathbf{R}^2$ , e um *lag* temporal  $u = t_i - t_j$  com  $t_i, t_j \in T \subset \mathbf{R}$ , e  $N(\mathbf{h}, u)$ , correspondente ao número de pares de valores amostrais das variáveis georreferenciadas separadas pelo *lag* espaço-temporal,  $(\mathbf{h}, u)$ .

Nessa abordagem, são considerados os semivariogramas em diversos intervalos de tempo, no qual a estimação do semivariograma espaço-temporal (Eq. 1) é obtida combinando as distâncias no espaço e no tempo (Matheron, 1989). Por tanto, são considerados puramente espacial, quando as distâncias no tempo forem iguais a zero  $(\mathbf{h}, 0)$ , tal como disposto na Figura 2<sup>a</sup>, e puramente temporal, quando as distâncias no espaço forem iguais a zero  $(0, u)$ , como apresentado na Figura 2B. Quando ambas as combinações das distâncias no espaço e no tempo forem

diferentes de zero, será considerada a distância espaço-temporal, conforme mostra a Figura 2C (Montero; Aviles; Mateu, 2015).

Figura 2. Combinação de distâncias espaço-temporais; nos exemplos, foram consideradas as seguintes combinações: (A) puramente espacial: considerando a distância espacial com  $X$  e a distância temporal com 0 anos ( $X, 0$ ); (B) puramente temporal: considerando a distância espacial com 0 e a distância temporal com  $T$  ( $0, T$ ); (C) espaço-temporal: considerando a distância espacial com  $X$  e a distância temporal com  $T$  ( $X, T$ ).



Fonte: Os Autores (2024).

Para modelar a dependência espaço-temporal, foram considerados cinco modelos de funções semivariâncias. Inicialmente, tem-se o modelo soma,  $\gamma_{so}(\mathbf{h}, u)$ , (Eq. 2) e o modelo soma-produto,  $\gamma_{sp}(\mathbf{h}, u)$  (Eq. 3), que podem ser representados como soma ou produto de uma componente puramente espacial  $\gamma_s(\mathbf{h})$  e outra puramente temporal  $\gamma_t(u)$ .

Em seguida, há o modelo métrico,  $\gamma_m(\mathbf{h}, u)$ , (Eq. 4), que combina as distâncias espacial, temporal e espaço-temporal por uma correção de anisotropia que torna equivalente a unidade espacial e temporal que, no caso estacionário, utiliza-se a métrica  $\sqrt{\|\mathbf{h}\|^2 + c^2|\mu|^2}$ , em que  $c$  é o fator de correção de anisotropia. Por fim, há os modelos soma-métrico,  $\gamma_{sm}(\mathbf{h}, u)$ , (Eq. 5) e soma-métrico simples,  $\gamma_{ssm}(\mathbf{h}, u)$ , (Eq. 6), que são uma combinação dos modelos soma e métrico.

A diferença entre os modelos soma-métrico e soma-métrico simples é a atribuição de um mesmo valor para o efeito pepita (nug) em todos os componentes (espacial, temporal e espaço-temporal) durante o ajuste do modelo (Montero; Aviles; Mateu, 2015; Viana *et al.*, 2019).

$$\gamma_{so}(\mathbf{h}, u) = \gamma_s(\mathbf{h}) + \gamma_t(u), \quad (\mathbf{h}, \mu) \in \mathbf{D} \times T; \quad (2)$$

$$\gamma_{sp}(\mathbf{h}, u) = (k_1 \text{sill}_t + k_2) \gamma_s(\mathbf{h}) + (k_1 \text{sill}_s + k_3) \gamma_t(u) - k_1 \gamma_s(\mathbf{h}) \gamma_t(u), \quad (3)$$

$$(\mathbf{h}, \mu) \in \mathbf{D} \times T;$$

$$\gamma_m(\mathbf{h}, u) = \gamma_{st} \left( \sqrt{\|\mathbf{h}\|^2 + c^2 |u|^2} \right), \quad (\mathbf{h}, \mu) \in \mathbf{D} \times T; \quad (4)$$

$$\gamma_{sm}(\mathbf{h}, u) = \gamma_s(\mathbf{h}) + \gamma_t(u) + \gamma_{st} \left( \sqrt{\|\mathbf{h}\|^2 + c^2 |u|^2} \right), \quad (\mathbf{h}, \mu) \in \mathbf{D} \times T; \quad (5)$$

$$\gamma_{ssm}(\mathbf{h}, u) = \text{nug} + \gamma_s(\mathbf{h}) + \gamma_t(u) + \gamma_{st} \left( \sqrt{\|\mathbf{h}\|^2 + c^2 |u|^2} \right) \quad (\mathbf{h}, \mu) \in \mathbf{D} \times T; \quad (6)$$

Em que:  $\gamma_s(\cdot)$ ,  $\gamma_t(\cdot)$  e  $\gamma_{st}(\cdot)$  são, respectivamente, as funções semivariância puramente espacial, puramente temporal e conjunta;  $\text{sill}_s$  é o parâmetro patamar de  $\gamma_s(\cdot)$  e  $\text{sill}_t$  é o parâmetro patamar de  $\gamma_t(\cdot)$ ; e  $k$  é o coeficiente de proporcionalidade entre as funções de semivariância, em que  $k_1 \geq 0$ ,  $k_2 \geq 0$  e  $k_3 \geq 0$  são constantes que asseguram a validade de  $\gamma_{sp}$ , sendo que a estimação de seus valores é descrita por Viana *et al.* (2019). O fator de correção de anisotropia espaço-temporal  $c$  é utilizado para mesclar a distância no espaço com a distância no tempo. O parâmetro  $\text{nug}$  é o valor para o efeito pepita que será considerado em todos os componentes (espacial, temporal e espaço-temporal) do modelo soma-métrico simples.

Foi utilizado o método de mínimos quadrados ordinários (OLS) para estimar os parâmetros dos modelos geoestatísticos (Pelletier *et al.*, 2004). Para validar o melhor modelo ajustado, utilizou-se a estatística de erro médio quadrático (MSE) e selecionou-se o modelo com o menor MSE (Weiss, 1988). Esse método é frequentemente utilizado para avaliar a precisão das previsões por meio da interpolação, no qual quanto menor o valor apresentado mais acurado é o modelo utilizado (Viana *et al.*, 2019).

Os componentes puramente espacial, puramente temporal ou espaço-temporal de cada modelo de função semivariância espaço-temporal foram ajustados a partir de modelos de semivariogramas isotrópicos unidimensional (Viana *et al.*, 2019). Os modelos utilizados foram o exponencial, o gaussiano, a família Matérn ( $k= 0.3, 1.5$  e  $2$ ) e o modelo *wave* (Isaaks; Srivastava, 1989; Uribe-Opazo *et al.*, 2012; Cressie, 2015).

Para um melhor entendimento do comportamento dos diferentes atributos químicos do solo utilizados neste trabalho, construiu-se mapas temáticos para todos os anos em estudo. De acordo com Uribe-Opazo *et al.* (2023), os mapas são úteis

para um melhor gerenciamento da área de estudo permitindo criar zonas de gerenciamento, aplicar insumos localizados, entre outras aplicações.

Para a interpolação dos dados e geração dos mapas foi empregado o método de *Krigagem* Ordinária Espaço-temporal (STOK), conforme visto na Eq. 7, sendo que as equações para *Krigagem* no Domínio Espaço-temporal são semelhantes às equações utilizadas na *Krigagem* Padrão (Viana *et al.*, 2019).

$$\hat{Z}'(\mathbf{s}_0, t_0) = \sum_{\{i: \mathbf{s}_i, t_i \in S_0\}} \lambda_i Z'(\mathbf{s}_i, t_i), \quad (7)$$

Em que:  $S_0$  é o conjunto de pontos de amostragem na vizinhança de busca do ponto de predição;  $\hat{Z}'(\mathbf{s}_0, t_0)$  é o valor a ser predito na localização/tempo não amostrado;  $Z'(\mathbf{s}_i, t_i)$  são os vizinhos de localização/tempo amostrados; e  $\lambda_i$  são os pesos correspondentes de *Krigagem* Espaço-temporal (Varouchakis, 2018).

Com essa técnica foi possível construir mapas temáticos inclusive para os anos em que não foram realizados coleta de dados. Utilizou-se o *Software R* (R Core Team, 2024), juntamente com os pacotes *gstat* (Pebesma, 2004) e *spacetime* (Pebesma, 2012), para realizar os ajustes dos modelos espaço-temporais.

### 5. 1.2.3 Análise da Relação das Variáveis Climáticas e dos Atributos Químicos do Solo

A fim de examinar as relações lineares e os graus de associação entre as variáveis climáticas e os atributos químicos do solo, conduziu-se uma análise de correlação canônica. A correlação canônica é uma técnica estatística utilizada para avaliar a relação entre dois conjuntos de variáveis multivariadas que busca encontrar combinações lineares das variáveis em cada conjunto que maximizam a correlação entre essas combinações.

Em outras palavras, a correlação canônica identifica padrões de associação entre dois conjuntos de variáveis, permitindo compreender como eles se relacionam de maneira global (Hair *et. al.*, 2009). Assim, com essa análise, investigou-se as associações presentes entre o conjunto de variáveis climáticas – precipitação média diária (mm) e temperatura média diária (°C) – e o conjunto de atributos químicos do solo – teor de cálcio (Ca, cmolc dm<sup>-3</sup>), teor de fósforo (P, mg dm<sup>-3</sup>), teor de matéria orgânica (MO, g dm<sup>-3</sup>), pH (CaCl<sub>2</sub>) e teor de magnésio (Mg, (cmolc dm<sup>-3</sup>)).

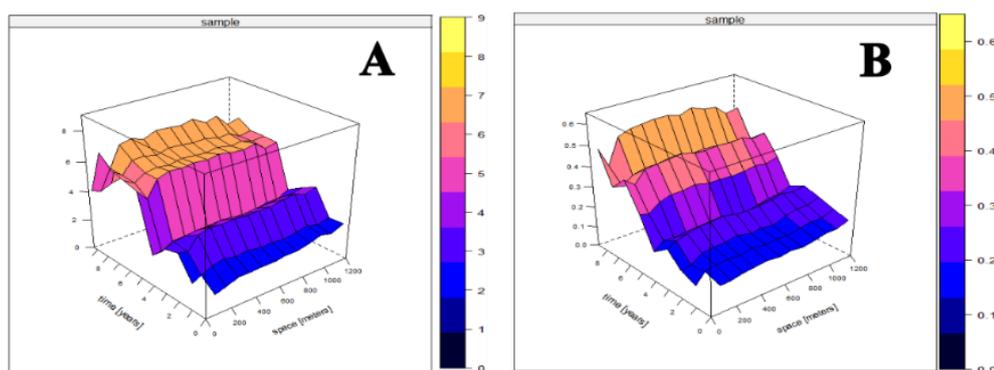
Os dados climáticos foram obtidos por meio do Projeto POWER do Centro de Pesquisa Langley da NASA (LaRC), financiado pelo Programa NASA Earth Science/Applied Science, disponibilizado gratuitamente na sua página web.

### 5.1.3 Resultados e Discussões

#### 5.1.3.1 Análise dos semivariogramas espaço-temporais amostrais

Inicialmente, realizou-se a análise visual dos semivariogramas espaço-temporais (Figuras 3 e 4), na qual nota-se que para todos os atributos químicos do solo há pouco aumento nos *lags* espaciais, sendo eles mais evidentes nos *lags* espaciais iniciais. Isso indica um raio de dependência espacial pequeno, ou seja, somente os pontos próximos estão correlacionados espacialmente entre si enquanto para distâncias maiores a variabilidade se dá de forma aleatória o que pode ser um indicativo de estabilidade da estrutura espacial.

Figura 3 – Semivariograma espaço-temporal amostral para: (A) teor de Cálcio; (B) pH.

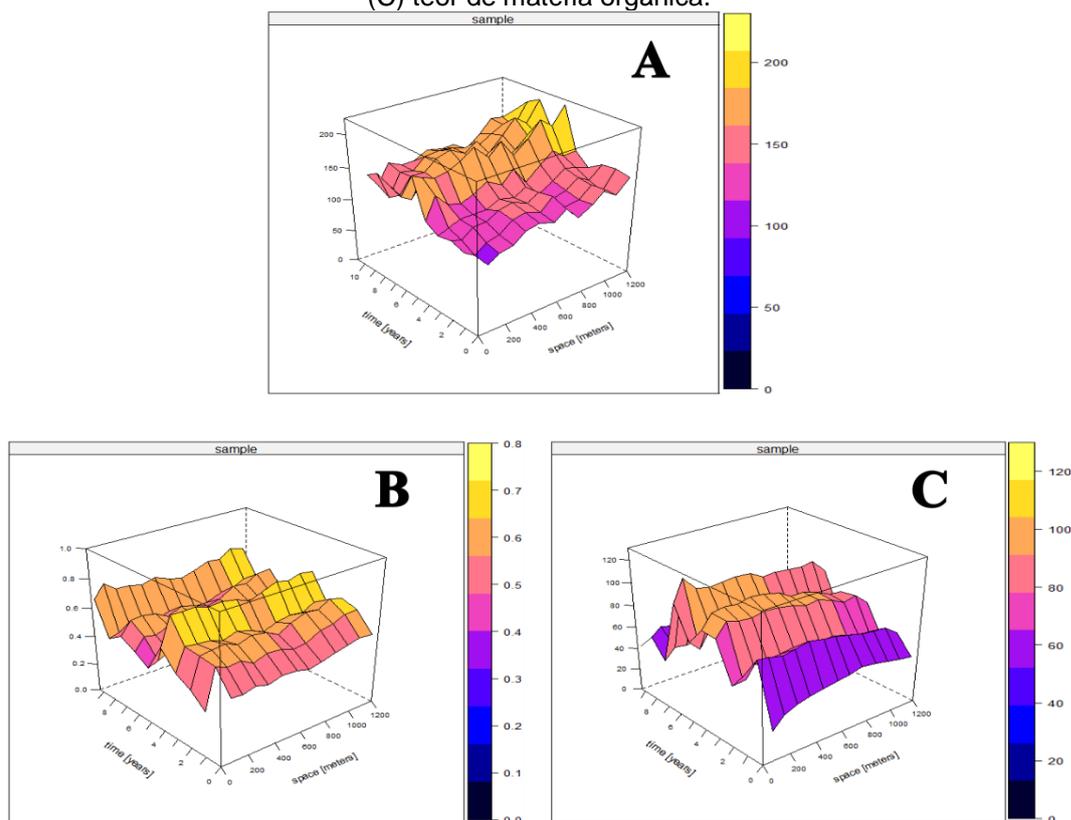


Fonte: Os Autores (2024).

Em relação à componente temporal (Figuras 3 e 4), observa-se uma tendência de aumento nos *lags* temporais indicando que os teores dos diferentes atributos químicos do solo avaliados se tornam menos similares com o aumento da distância temporal. Esse aumento é mais acentuado quando comparado ao eixo espacial sendo mais evidente nos atributos químicos do solo, teor de cálcio e pH (Figuras 3A e 3B).

O teor de fósforo apresenta um aumento gradual com estabilização temporal próximo a metade da distância temporal total (Figura 4A). Para o teor de magnésio e o teor de matéria orgânica (Figuras 4A e 4B), esse aumento é pouco pronunciado sendo mais forte nos *lags* iniciais.

Figura 4 – Semivariograma espaço-temporal amostral para: (A) teor de fósforo; (B) teor de magnésio; (C) teor de matéria orgânica.

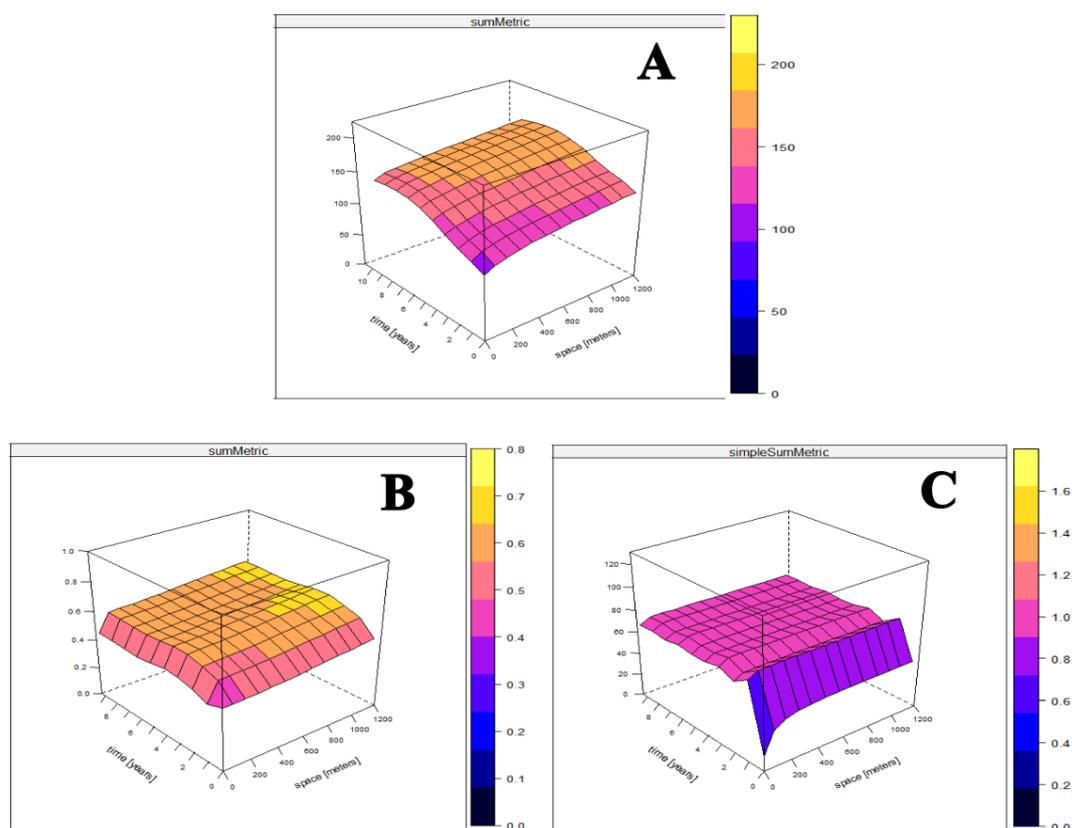


Fonte: Os Autores (2024).

### 5.1.3.2 Análise dos modelos ajustados e seus parâmetros

Os semivariogramas espaço-temporais amostrais foram então ajustados por meio de diferentes modelos geoestatísticos espaço-temporais. Os que demonstraram o melhor ajuste aos semivariogramas espaço-temporais amostrais foram o modelo soma-métrico, para os atributos químicos do solo teor de fósforo (Figura 5A) e teor de magnésio (Figura 5B), e o modelo soma-métrico simples, utilizado para os atributos químicos do solo, teor de matéria orgânica (Figura 5C), teor de cálcio (Figura 6A) e pH (Figura 6B).

Figura 5 – Representação dos modelos ajustados para as variáveis (A) teor de fósforo; (B) teor de magnésio; (C) teor de matéria orgânica.

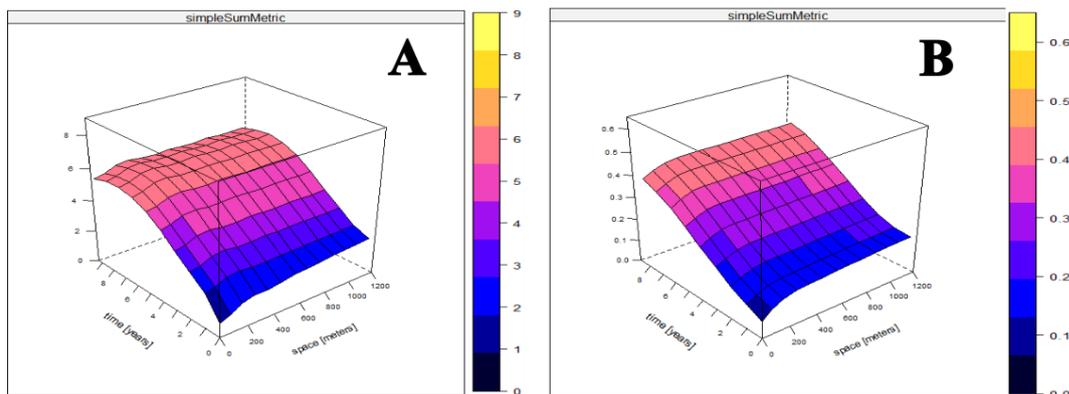


Fonte: Os Autores (2024).

De acordo com Heuvelink *et al.* (2012), esses modelos se destacam pela minimização das incertezas. Uma vantagem notável desses modelos é a capacidade de permitir a interpretação individual dos componentes espaciais, temporais e espaço-temporais, embora seja importante destacar que a estimação dos parâmetros representa um desafio considerável devido à quantidade substancial de parâmetros a serem estimados (Snepvangers; Heuvelink; Huisman, 2003).

Estudos anteriores também corroboraram a eficácia dos modelos que consideram componentes espaciais, temporais e espaço-temporais na modelagem de processos estocásticos espaço-temporais (Cesare; Myers; Posa, 2001; Snepvangers; Heuvelink; Huisman, 2003; Kilibarda *et al.*, 2015; Monteiro; Menezes; Silva, 2017).

Figura 6 – Representação dos modelos ajustados para as variáveis (A) teor de cálcio; (B) pH.



Fonte: Os Autores (2024).

Esses resultados evidenciam a importância da consideração da variabilidade espaço-temporal além dos componentes puramente espaciais e temporais para um ajuste mais preciso do modelo e, conseqüentemente, para a obtenção de resultados mais precisos. Os modelos espaço-temporais utilizando nesse estudo são formados pelas componentes puramente espacial, puramente temporal e espaço-temporal (joint). Para cada uma dessas componentes é necessário ajuste por meio de modelos geoestatísticos que melhor representem seu comportamento.

### 5.1.3.3 Análise da Componente puramente espacial

Ao ajustar a estrutura puramente espacial, observa-se que não existe um modelo específico que melhor se ajuste à componente espacial dos semivariogramas espaço-temporais para os atributos químicos do solo, sendo que foram escolhidos os modelos gaussiano, exponencial, wave, esférico e Matérn ( $k = 2$ ) (Tabela 1). Esses modelos são usualmente utilizados em estudos que descrevem a estrutura de dependência espacial em atributos químicos do solo (Dalposso *et al.*, 2019; Guedes *et al.*, 2020; Dal'Canton, *et al.*, 2023; Lorbieski *et al.*, 2023, Maltauro *et al.*, 2023). Portanto, era esperado essa variação entre os modelos que melhor se ajustou a componente espacial.

A maioria dos atributos químicos do solo apresentaram moderado grau de dependência espacial (RNE) com raio de dependência (alcance) menores do que 230 m (Tabela 1), ou seja, apresentaram raio de dependência espacial menor que um quarto da maior distância entre dois pontos amostrais na área de estudo que é de aproximadamente 1766 m, sendo isso um indicativo de como a variabilidade é restrita em regiões próximas dentro do campo. A exceção é em relação ao teor de magnésio

que apresenta um alcance de 590m, sendo, portanto, o atributo químico com maior alcance espacial.

Tabela 1 – Parâmetros geoestatísticos para o componente puramente espacial.

	Fósforo	Magnésio	Cálcio	pH	Matéria Orgânica
Modelo	Gaussiano	Matérn k=2	Wave	Esférico	Exponencial
Efeito pepita ( $\hat{\varphi}_1$ )	5,0	0,13	0,93	0,08	13,95
Contribuição ( $\hat{\varphi}_2$ )	4,01	0,14	0,44	0,05	5,01
Patamar ( $\hat{\varphi}_1 + \hat{\varphi}_2$ )	9,01	0,27	1,37	0,13	18,96
Alcance (m)	178	580	158	229	30
RNE	0,55 (gm)	0,48 (gm)	0,68 (gm)	0,61 (gm)	0,74 (gm)

RNE: ( $\hat{\varphi}_1/(\hat{\varphi}_1 + \hat{\varphi}_2)$ ) efeito pepita relativo; gm: grau moderado.

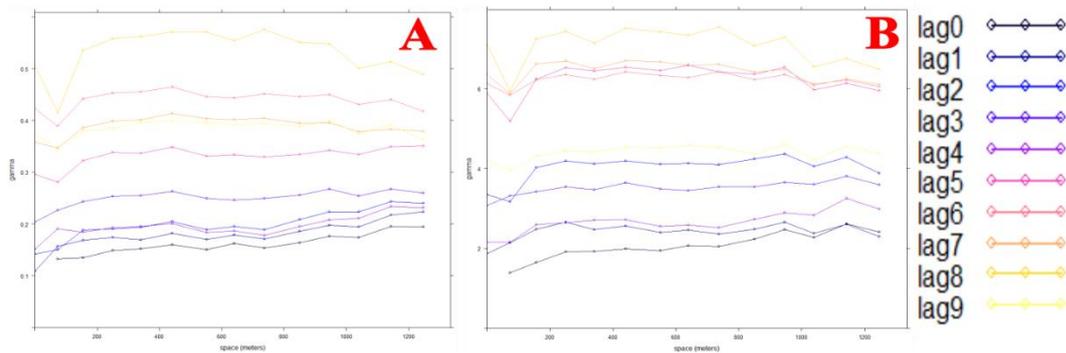
Fonte: Os Autores (2024).

Outro aspecto a ser considerado em relação à variabilidade espacial é seu padrão ao longo do tempo. Ao examinar o comportamento espacial em diferentes *lags* temporais (Figuras 7 e 8) dos distintos atributos químicos do solo, observou-se uma certa estabilidade na variabilidade espacial ao longo do tempo.

No geral os semivariogramas exibem padrões semelhantes independentemente da distância temporal entre eles. Em outras palavras, verifica-se um crescimento inicial rápido desses semivariogramas, alcançando rapidamente um patamar, o que indica um raio de dependência espacial reduzido, independentemente da distância temporal entre as amostras.

Apesar dessas semelhanças nota-se que para o pH e o teor de cálcio no solo (Figuras 7A e 7B) os *lags* com maior distância temporal, representados nos gráficos com cores próximas ao amarelo, apresentam maior contribuição, indicando um aumento na variabilidade das amostras separadas por distâncias maiores no tempo. Esse comportamento indica um aumento na variabilidade espacial ao longo dos anos, causadas por diferenças nos valores amostrais no decorrer do tempo, entretanto, como o alcance pouco mudou nos diferentes *lags* temporais, o aumento na variabilidade ficou restrita a regiões próximas aos pontos amostrais.

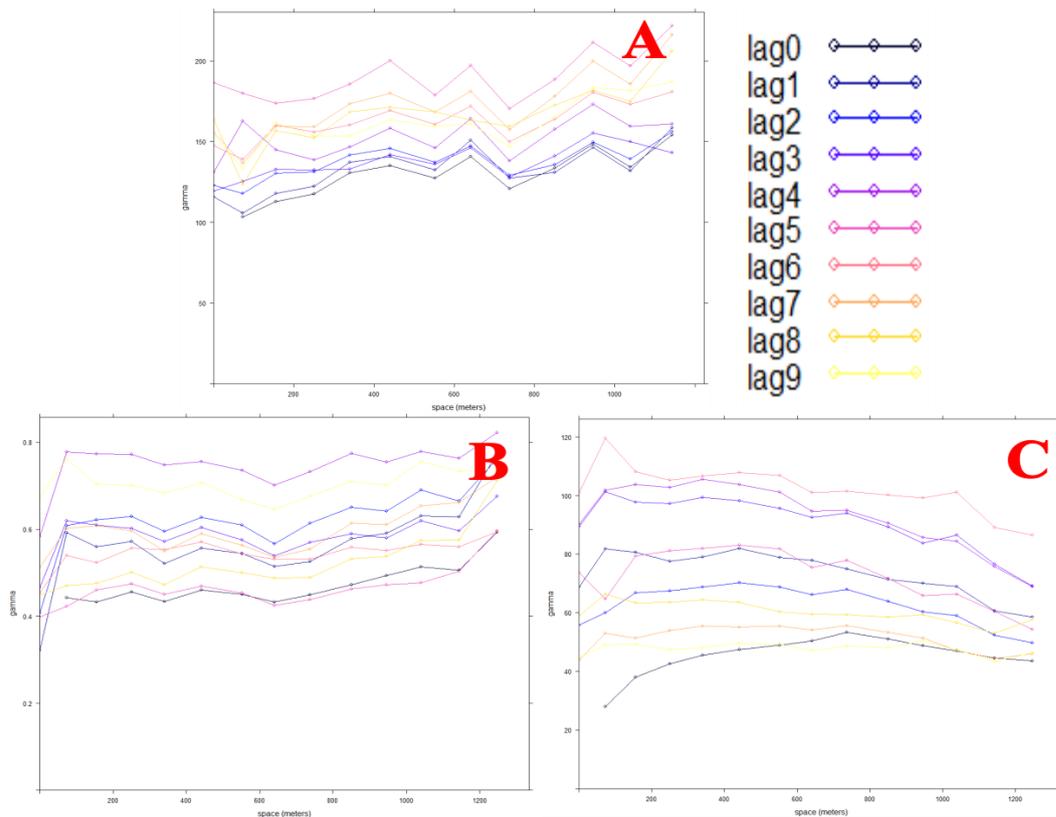
Figura 7 – Semivariogramas amostrais separados por defasagens temporais; A) pH, B) teor de cálcio.



Fonte: Os Autores (2024).

Já para o teor de fósforo, o teor de magnésio e o teor de matéria orgânica (Figuras 8A, 8B e 8C), não é percebido esse aumento na contribuição para *lags* temporais maiores, o que indica estabilidade ou pouca variação ao longo do tempo.

Figura 8– Semivariogramas amostrais separados por defasagens temporais; A) teor de fósforo, B) teor de magnésio; C) teor de matéria orgânica.



Fonte: Os Autores (2024).

No geral, os atributos químicos do solo apresentaram comportamento semelhante, ou seja, possuem dependência espacial mais restrita a regiões próximas

caracterizando variações mais localizadas. Esse comportamento revela uma aparente aleatoriedade nos padrões de variabilidade espacial nessa área que pode estar associada a eventos com efeitos localizados dentro do campo que afeta a distribuição espacial desses atributos em escala local.

Estudo semelhante foi realizado anteriormente por Lorbieski *et al.* (2023), nessa mesma área, o qual relatou que embora houvesse variabilidade nos atributos químicos do solo eles eram restritos a um determinado intervalo espacial que não chegava a afetar a produtividade. Esse comportamento pode estar relacionado à gestão e ao manejo da área onde foi realizado o estudo, já que se trata de uma área agrícola comercial com acompanhamento técnico e aplicação localizada.

Conforme destacado por Kayad *et al.* (2021), tanto a gestão do campo quanto os fatores ambientais desempenham papéis cruciais na geração de variabilidade espacial e temporal. Já Freddi *et al.* (2006) ressaltam que o manejo do solo é o principal influenciador de sua variabilidade, enquanto Khan *et al.* (2020) afirmam que práticas de manejo bem aplicadas constituem uma abordagem eficaz para mitigar essa variabilidade.

Outros estudos também apontam para esses resultados, como o realizado por Kilic *et al.* (2012) no qual mostraram que em áreas cultivadas os atributos químicos do solo mudaram devido ao seu preparo, com tendência de homogeneização delas quando comparadas as áreas sem cultivo. Esses resultados também estão de acordo com os apresentados por Liu *et al.* (2009) que verificaram a diminuição da variabilidade espacial dos atributos químicos do solo em uma área de arroz irrigado, após adoção de práticas de manejo adequadas em um período de 20 anos.

Em resumo, estes resultados estão em consonância com a teoria proposta por Carvalho *et al.* (2003), que sugere que a variabilidade espacial dos atributos químicos do solo pode ser moldada por fatores intrínsecos, como o material de origem e texturas, além de fatores extrínsecos relacionados às práticas de manejo, como adubação e calagem.

#### 5.1.3.4 Análise da Componente puramente temporal

Quanto à componente temporal, fica evidente que o modelo *wave* é o que melhor se ajustou ao comportamento da sua estrutura (Tabela 2). Uma explicação plausível para esse fenômeno reside na análise dos semivariogramas espaço-temporais amostrais nas Figuras 3 e 4, na qual nota-se um comportamento periódico desses semivariogramas no sentido do eixo temporal.

O modelo *wave*, por sua vez, exibe essa característica, conforme descrito por Andriotti (2009) e Chilès e Delfiner (2012), apresentando variações periódicas que indicam um crescimento não monotônico. Além disso, esse modelo é comumente empregado para descrever a variabilidade de dados climáticos por refletir um comportamento semelhante ao desses dados (Isaaks; Srivastava, 1989; Cressie, 2015; Gamero *et al.*, 2020).

Sabe-se que a variabilidade temporal é predominantemente influenciada por fatores climáticos (Heuvelink; Egmond, 2010; Basso *et al.*, 2012; Liu *et al.*, 2016). Logo, esses elementos podem estar desempenhando um papel crucial na escolha do modelo geoestatístico que melhor se adapta à componente temporal.

Os comportamentos dos semivariogramas experimentais (Figuras 3 e 4) e dos modelos ajustados (Figuras 5 e 6), em relação a direção temporal, são refletidos nos valores dos parâmetros dos modelos ajustados (Tabela 2), na qual é possível notar que a componente puramente temporal exibe valores de grau de dependência que variam de moderado a forte, com valores estimados de alcances temporais variando entre 1 e 6 anos. Os atributos químicos que mais se destacaram foram o teor de fósforo, o teor de cálcio e o pH que apresentaram os maiores valores de grau de dependência e alcance temporais, ou seja, o teor desses atributos químicos no solo está correlacionado fortemente ao longo do tempo, especificamente estimado em 6 anos no caso do pH e 5 anos no caso do teor de fósforo e teor de cálcio, ou seja, as alterações nos valores desses atributos no solo podem ser sentidas ao longo de alguns anos. Os demais atributos químicos do solo apresentaram menores valores de grau de dependência e alcance temporal indicando que os valores estavam menos correlacionados ao longo dos anos e, portanto, com variações mais aleatórias.

Esse comportamento em relação a variabilidade temporal já era esperado pois de acordo com Gavioli *et al.* (2016) e Cammarano *et al.* (2020) os atributos químicos do solo não são considerados temporalmente estáveis. Além disso alguns estudos apontam para a ocorrência de variabilidade temporal nos atributos químicos do solo, como, por exemplo, em Ferraz *et al.* (2012), no qual os autores verificaram variações entre os valores do teor de fósforo e de potássio no solo nos diferentes anos de estudo.

Assim como Cox *et al.* (2003), que observaram que a variabilidade na fertilidade do solo variou ano a ano nos diferentes campos estudados, Liu *et al.* (2009) verificaram mudanças temporais significativas com aumento no carbono orgânico, nitrogênio total, teor de fósforo disponível e diminuição acentuada do teor de potássio

disponível resultantes do desequilíbrio da aplicação de fertilizantes à base de nitrogênio, teor de fósforo e potássio.

Tabela 2 – Parâmetros geoestatísticos para o componente puramente temporal.

	Fósforo	Magnésio	Cálcio	pH	Matéria Orgânica
Modelo	Wave	Wave	Wave	Wave	Wave
Efeito pepita ( $\hat{\varphi}_1$ )	7,0	0,08	0,93	0,08	13,95
Contribuição ( $\hat{\varphi}_2$ )	30,73	0,08	2,78	0,23	28,41
Patamar ( $\hat{\varphi}_1 + \hat{\varphi}_2$ )	37,73	0,16	3,71	0,31	42,36
Alcance (anos)	5	2	5	6	1
RNE	0,18 (gft)	0,50 (gm)	0,25 (gft)	0,25 (gft)	0,33 (gm)

RNE: ( $\hat{\varphi}_1/(\hat{\varphi}_1 + \hat{\varphi}_2)$ ) efeito pepita relativo; gm: grau moderado; gft: grau forte.

Fonte: Os Autores (2024).

Uma das principais causas para a variabilidade temporal, de acordo com Liu *et al.* (2016) são os efeitos climáticos. Para Heuvelink; Egmond (2010), eventos climáticos como a chuva pode fazer com que a variação no tempo seja maior do que no espaço, pois ela provavelmente ocorrerá em toda a extensão do campo, mas pode variar muito ao longo do tempo.

Assim, analisou-se os efeitos associados entre as variáveis climáticas e os atributos químicos do solo por meio da análise da correlação canônica. Essa análise (Tabela 3) mostra que a quantidade de variância explicada, ou seja, o percentual de variância na variável estatística canônica dependente que pode ser explicada pela variável estatística canônica independente, e vice-versa, foi elevado para o primeiro par de variáveis canônicas (U1V1) (99,5%) o que representa aproximadamente 63% da variância global da análise.

O segundo par de variáveis canônicas (U2V2) também apresentou quantidade considerável de variância (0,585) com percentual de aproximadamente 37% da variância global. A força da relação linear entre as funções canônicas (combinações lineares dos conjuntos de variáveis), expressa pela correlação canônica é alta (0,997) para o primeiro par de variáveis canônicas indica uma associação forte entre as combinações lineares dessas variáveis (Tabela 3). O segundo par também apresentou uma correlação forte, porém ligeiramente inferior ao primeiro.

Tabela 3 – Variâncias dos pares canônicos U e V e a correlação entre eles.

Pares Canônicos	Variância	% Variância	% Variância Acumulada	Correlação Canônica
-----------------	-----------	-------------	-----------------------	---------------------

U1V1	0,995	62,97	62,97	0,997
U2V2	0,585	37,02	100,00	0,765

Fonte: Os Autores (2024).

De acordo com o teste de significância realizado (Tabela 4) apenas o par canônico U1V1 mostrou-se significativa ( $p$ -valor  $<0,05$ ), além disso o valor de  $\lambda$  de Wilk é baixo para o par canônico (U1V1), o que indica que as variações do grupo (atributos químicos do solo), nesse par, são pouco explicadas por fatores aleatórios ou erros de amostragem, e mais pelas variações do grupo (variáveis climáticas). O valor de  $\lambda$  de Wilk é maior para o segundo par canônico (U2V2), o que evidencia que o resultado pode ser mais acidental do que real quando usamos tal modelo de correlação. Portanto, o par canônico (U1V1) é o que atende os critérios para ser interpretado e somente ele será utilizado na interpretação dos resultados.

Tabela 4 – Teste de significância dos pares canônicos.

Função Canônica	Pares Canônicos	$\lambda$ de Wilks	Chi-Square	chi-square density	df	p-Valor
1	(U1V1)	0,002	24,678	18,307	10	0,006*
2	(U2V2)	0,415	3,517	9,487	4	0,475

\*Significativo ao nível de 5% de probabilidades.

Fonte: Os Autores (2024).

A Tabela 5 apresenta os valores para a carga canônica, onde se verifica que a precipitação média diária apresenta uma carga mais alta dentre as variáveis independentes para a primeira função canônica (U1V1) o que sugere uma contribuição mais forte dessa variável na relação canônica. Além disso ela apresenta um valor negativo o que indica uma relação inversa, ou seja, à medida que a precipitação média diária aumenta os atributos químicos tendem a diminuir.

Esse fato pode estar relacionado a lixiviação, ou seja, a chuva removendo os nutrientes do solo (Rashmi *et al.*, 2017). Também pode estar relacionado ao desenvolvimento dos cultivares, já que em anos com menor quantidade de chuva pode resultar em menor desenvolvimento desses cultivares diminuindo assim a quantidade de nutrientes exportados do solo (Wang *et al.*, 2011). Já a temperatura média diária apresenta valor positivo, portanto, uma relação direta com as variáveis do outro grupo, entretanto o seu valor é menor em comparação com o da precipitação, indicando uma contribuição mais fraca nessa relação canônica, ou seja, a temperatura média diária tem menor influência sobre os atributos químicos do solo.

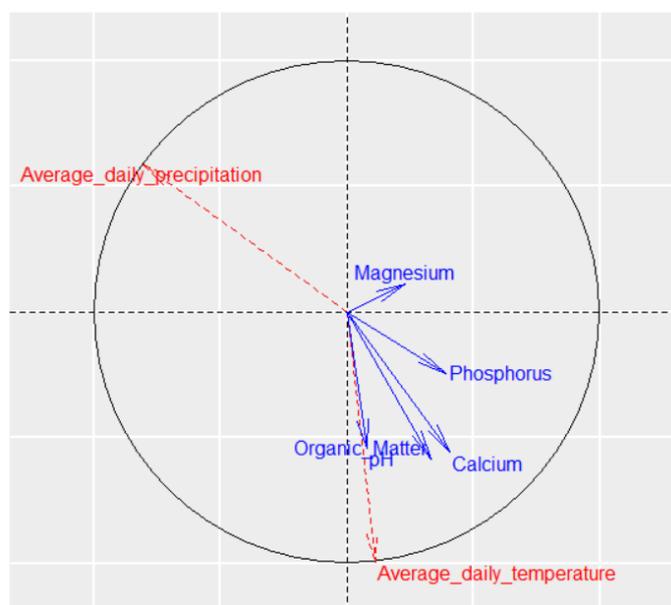
Tabela 5 – Carga Canônica para a Primeira Função Canônica (U1V1).

<b>Variáveis Independentes</b>	
Variáveis	Cargas Canônicas
Precipitação média diária	-0,80
Temperatura média diária	0,11
<b>Variáveis Dependentes</b>	
Variáveis	Cargas Canônicas
Teor de fósforo	0,39
Matéria Orgânica	0,33
Cálcio	0,41
pH	0,08
Magnésio	0,23

Fonte: Os Autores (2024).

Os atributos químicos do solo que possuem mais relação com a precipitação média diária são o teor de cálcio, o teor de fósforo e o teor de matéria orgânica (Tabela 5), ou seja, o aumento nos valores da precipitação está mais fortemente associado a diminuição nos valores desses atributos químicos do solo. Os valores da temperatura também influenciam, só que em menor grau, os atributos químicos do solo, ou seja, o aumento da temperatura média diária pode fazer com que os valores dos atributos químicos também aumentem, entretanto, em menor grau.

Figura 9– Biplot da correlação canônica entre variáveis climáticas e atributos químicos do solo.



Fonte: Os Autores (2024).

Esses resultados podem ser visualizados no Gráfico Biplot (Figura 9), em que é possível ver a relação inversa da variável precipitação média diária com os atributos químicos do solo. Além disso, vê-se também uma associação direta desses atributos com a variável temperatura média diária, entretanto, essa associação é mais fraca, e pode estar relacionada a efeitos aleatórios ou acidentais.

Em síntese, verifica-se que as variáveis climáticas explicam boa parte da variação dos atributos químicos do solo, entretanto, cabe ressaltar que nem toda a variação dos atributos químicos do solo foi explicada pela variação das variáveis climáticas, ou seja, parte dessa variação pode ser explicada por outros fatores, como o manejo do solo, ou características próprias do cultivar, por exemplo. Esses resultados estão de acordo com o preconizado por Basso *et al.* (2012) na qual a variabilidade temporal deve-se especialmente a fatores não estáveis como o clima ou aos tipos de culturas cultivadas a cada ano.

#### 5.1.3.5 Componente espaço-temporal (joint)

Por fim, destaca-se que a componente espaço-temporal (joint) obtiveram-se melhores ajustes com os modelos da família Matérn, com parâmetro de suavização  $k = 0,3$  para a maioria dos atributos químicos do solo (Tabela 6). Observa-se que o valor do parâmetro  $k$  do modelo Matérn é pequeno ( $k = 0.3$ ), o que implica que o processo é irregular (mudanças rápidas na variação em pequenos *lags*) (Minasny; McBratney, 2007).

De acordo com os parâmetros dos modelos ajustados para a componente espaço-temporal (Tabela 6), nota-se de fraco a moderado grau de dependência (RNE) nos diferentes atributos químicos do solo analisados o que indica existência de interação entre os componentes espacial e temporal. Os atributos que apresentaram os maiores graus de interação entre os fatores espacial e temporal foram o teor de fósforo e o pH com moderado grau de dependência, além de apresentar alcances relativamente grandes quando comparados com os demais atributos.

Tabela 6 – Parâmetros geoestatísticos para a componente conjunta espaço-temporal (joint).

	Fósforo	Magnésio	Cálcio	pH	Matéria Orgânica
Modelo	Matérn $k=0,3$	Exponencial	Exponencial	Matérn $k=0,3$	Matérn $k=0,3$
Efeito pepita ( $\hat{\varphi}_1$ )	95,66	0,30	0,93	0,08	13,95
Contribuição ( $\hat{\varphi}_2$ )	73,91	0,01	1,49	0,08	25,76
Patamar ( $\hat{\varphi}_1 + \hat{\varphi}_2$ )	169,57	0,31	2,42	0,16	39,71
Alcance (m)	3915	1962	964	1447	149
RNE	0,56 (gm)	0,96 (gf)	0,38 (gm)	0,50 (gm)	0,35 (gm)
StAnis	0,10	0,11	3,66	0,63	3,38

RNE: ( $\hat{\varphi}_1/(\hat{\varphi}_1 + \hat{\varphi}_2)$ ) efeito pepita relativo; gm: grau moderado; gf: grau fraco; StAni: anisotropia espaço-temporal.

Fonte: Os Autores (2024).

Outro aspecto relevante referente à variabilidade conjunta reside na anisotropia espaço-temporal (Tabela 6). Os valores inferiores a 1 atribuídos ao teor de fósforo, teor de magnésio e pH sugerem, uma correlação temporal mais robusta na interação entre os níveis desses atributos químicos do solo. Por outro lado, o teor de cálcio e o teor de matéria orgânica exibem valores superiores a 1, indicando uma correlação espacial mais acentuada nesse contexto de interação (Gasch *et al.*, 2015).

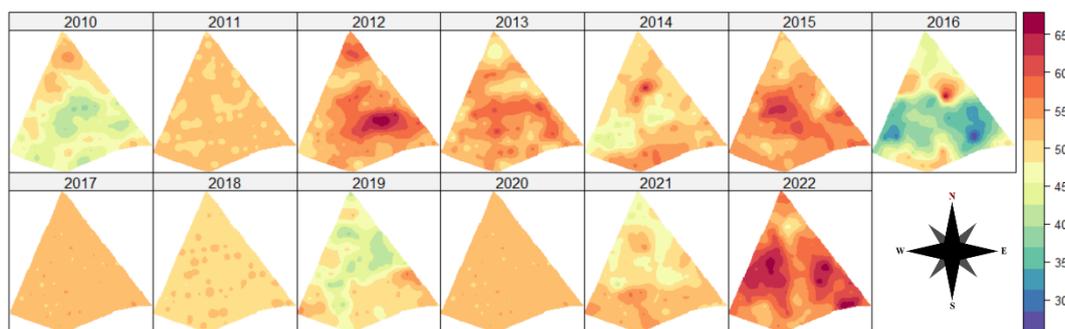
#### 5.1.3.6 Análise dos diferentes atributos químicos do solo

Ao conduzir uma análise específica para cada atributo químico do solo em estudo, constatou-se que o teor de matéria orgânica, embora tenha exibido uma dependência moderada em relação a todos as componentes avaliadas, também apresentou alcances limitados em todos elas (Tabelas 1, 2 e 6). Em outras palavras, a autocorrelação entre os valores observados está restrita a regiões próximas e ao ano de observação, dada a limitação temporal de apenas um ano. Isso sugere que, de maneira geral, a variabilidade desse atributo químico do solo se manifesta de maneira praticamente aleatória na área de estudo, especialmente no que diz respeito à componente temporal.

Este comportamento é mais evidente nos mapas gerados para esse atributo (Figura 10), nos quais os mapas apresentam diferenças mais bruscas entre os diferentes anos, ou seja, as mudanças parecem menos graduais quando comparados como os outros atributos químicos analisados nesse estudo. Em resumo, os valores parecem estar mais vinculados a eventos que impactaram esse atributo químico em cada ano individualmente.

De acordo com Liu *et al.* (2020) a variação no teor de matéria orgânica no solo pode estar intimamente relacionada a fatores humanos, como uso da terra pelos agricultores e comportamentos, incluindo a aplicação de fertilizantes químicos e orgânicos, tipos de culturas, entre outros. Para Hu *et al.* (2018), fatores naturais, como clima e topografia, e atividades humanas, como uso da terra e adubação, influenciam a distribuição espacial do teor de matéria orgânica do solo. Já para Shi *et al.* (2019), atividades humanas dinâmicas em curtos períodos, como por exemplo, uso da terra, adubação, preparo do solo, sistema de cultivo, têm um impacto profundo na dinâmica do teor de matéria orgânica do solo.

Figura 10 – Mapa do teor de matéria orgânica do solo entre os anos de 2010 e 2022.

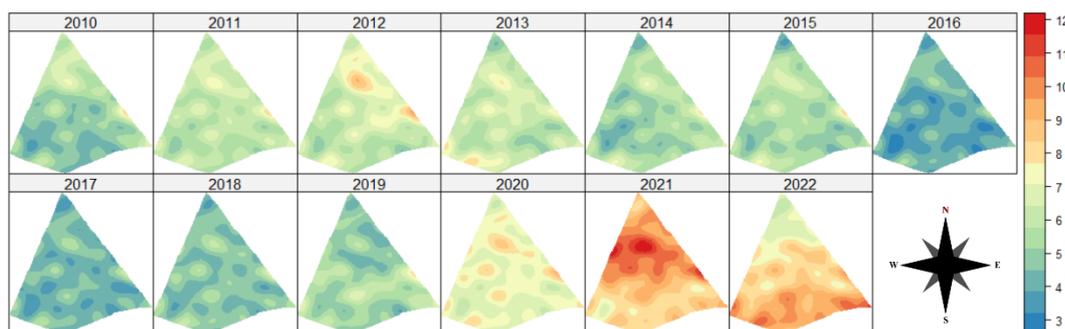


Fonte: Os Autores (2024).

O teor de cálcio, teor de fósforo e o pH foram os atributos químicos do solo que apresentaram os maiores graus de dependência temporal, além de, moderado grau de dependência espacial e pouca influência da variabilidade conjunta entre componentes espacial e temporal nos diferentes atributos químicos do solo (Tabelas 1, 2 e 6). Alguns estudos indicam que o pH normalmente possui pouca variabilidade (Amado *et al.*, 2009; Ou *et al.*, 2017).

Entretanto, em nosso estudo observou-se um efeito contrário. Uma das causas prováveis para esse comportamento é a sua relação com o teor de cálcio. Sabe-se que existe uma relação direta entre o teor de cálcio e o pH, pois adicionar cálcio ao solo, por meio de corretivos como calcário, pode neutralizar a acidez, elevando o pH, ou seja, o aumento no teor de cálcio leva a um aumento no valor do pH (Pauletti *et al.*, 2014).

Figura 11– Mapa do teor de cálcio no solo entre os anos de 2010 e 2022.

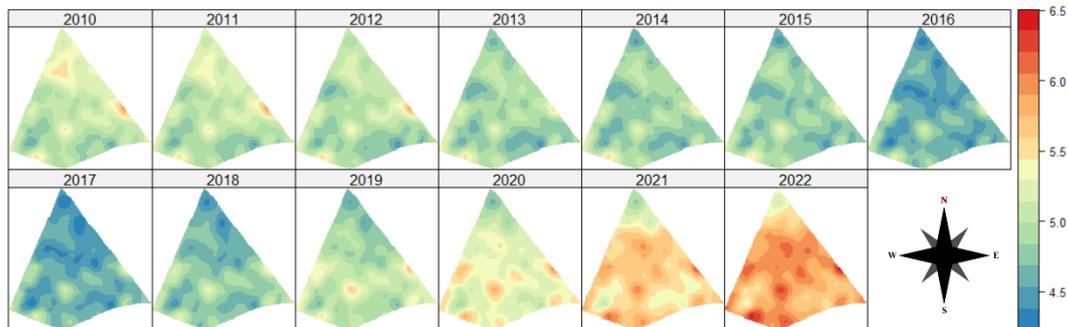


Fonte: Os Autores (2024).

Essa relação entre esses dois atributos dos solos pode ser facilmente visualizada quando observamos os mapas gerados para ambos (Figuras 11 e 12) nos quais é possível ver valores mais baixos tanto para o teor de cálcio quanto para o pH entre os anos de 2015 e 2017 e altos valores para esses mesmos atributos para os anos de 2020 a 2022. Vale ressaltar que esse comportamento semelhante entre esses

dois atributos também foi apontado quando analisamos os semivariogramas amostrais e ajustados (Figuras 3 e 6) e os parâmetros dos modelos ajustados (Tabelas 1, 2 e 6).

Figura 12 – Mapa do pH do solo entre os anos de 2010 e 2022.

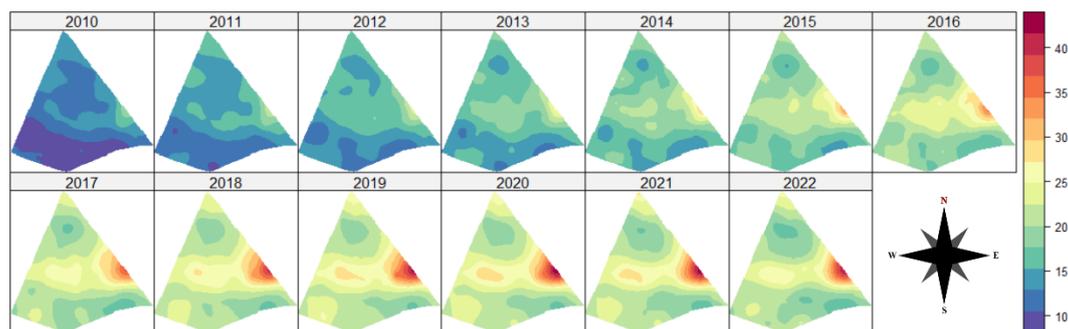


Fonte: Os Autores (2024).

Em relação ao teor de fósforo, uma característica singular desse atributo químico apontada Shen *et al.* (2011), é sua baixa solubilidade e mobilidade no solo. A forte dependência temporal observada pode estar sendo influenciada por essa característica que esse atributo químico apresenta, indicando uma dispersão lenta ao longo do tempo.

Esse efeito é evidenciado na Figura 13, que representa a disponibilidade do teor de fósforo ao longo dos diversos anos de estudo. Nota-se uma região com maior concentração desse atributo na região centro-oeste do mapa, persistindo ao longo dos anos, com um leve aumento gradual com o passar do tempo.

Figura 13 – Mapa do teor de fósforo no solo entre os anos de 2010 e 2022.

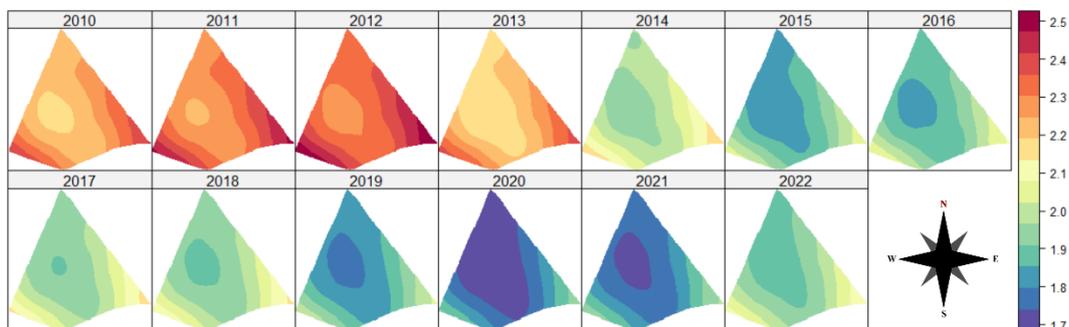


Fonte: Os Autores (2024).

O teor de magnésio no solo apresentou grau moderado de dependência tanto espacial quanto temporal, entretanto espacialmente o teor de magnésio apresentou grande raio de dependência, sendo o maior entre todos os atributos analisados. No mapa gerado para esse atributo (Figura 14), nota-se uma diminuição gradativa do seu

teor no solo entre os anos de estudo, sendo que a partir de 2015 esse comportamento fica mais evidenciado vindo do Norte para o Sul da área.

Figura 14 – Mapa do teor de magnésio no solo entre os anos de 2010 e 2022.



Fonte: Os Autores (2024).

Resultados semelhantes em relação ao comportamento desse atributo químico é encontrado na literatura, como por exemplo, o estudo conduzido por Stipek *et al.* (2004) que destacam a variação espacial e temporal no teor de magnésio disponíveis no solo. Neste estudo, constatou-se que o teor de magnésio possui baixa variabilidade espacial, mas apresenta uma dependência espacial moderada a forte, com pouca variação temporal. Deste modo, apesar das mudanças na variabilidade espacial, as médias e medianas dos dados permanecem consistentes, indicando estabilidade nos níveis de nutrientes do solo ao longo do tempo.

#### 5.1.4 Conclusão

Com relação aos atributos químicos do solo estudados, no geral eles apresentaram maior variação no tempo do que no espaço. Esse comportamento é observado nos semivariogramas e modelos espaço-temporais ajustados, assim como nos valores dos parâmetros geoestatísticos obtidos dos modelos ajustados, nos quais o componente temporal apresentou maiores valores de contribuição, alcance e grau de dependência do que as componentes espacial e espaço-temporal. Portanto, a variabilidade nesses atributos químicos do solo parece ser mais sensível às influências temporais causadas por fatores climáticos e manejo de solo, por exemplo. Dentre os fatores climáticos, a análise da correlação canônica deixou clara a influência da precipitação na variabilidade temporal desses atributos.

Do ponto de vista espacial, a estrutura de dependência está limitada a regiões mais próximas, o que sugere variações mais localizadas no campo, com variações

mais aleatórias à medida que as distâncias aumentam. Outro aspecto a ser enfatizado é a interação, ainda que pequena, entre as componentes espacial e temporal, evidenciando que a variabilidade total não é completamente explicada quando se consideram apenas as componentes espacial e temporal de forma isolada, ou seja, o modelo é mais bem ajustado quando se considera esse componente.

Os resultados deste estudo reforçam a eficácia do uso da Geoestatística Espaço-temporal como uma ferramenta na análise da variabilidade em uma determinada área de estudo. A abordagem adotada proporcionou uma avaliação abrangente, considerando não apenas a dimensão espacial, mas também incorporando aspectos temporais e espaço-temporais.

A capacidade de descrever e compreender a variabilidade em diferentes componentes torna essa metodologia muito útil para a tomada de decisões e para a gestão do campo. Este estudo ressalta a importância de explorar e aplicar abordagens, como a Geoestatística Espaço-temporal, no avanço do entendimento das dinâmicas complexas em ambientes agrícolas.

Para futuros trabalhos, sugere-se explorar novos modelos geoestatísticos espaço-temporais, além de investigar técnicas que lidem com dados com falta de normalidade e muitos outliers. Também é relevante buscar formas de simplificar o ajuste dos modelos e aprimorar os métodos de verificação dos erros nesses ajustes.

**Agradecimentos:** Agradecimentos ao apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior- CAPES, código de financiamento 001, CNPq e Laboratórios de Estatística Aplicada (LEA) e de Estatística Espacial (LEE), UNIOESTE.

## Referências

AMADO TJC, PES LZ, LEMAINSKI CL, SCHENATO RB. Atributos químicos e físicos de Latossolos e sua relação com os rendimentos de milho e feijão irrigados. **Rev Bras Cienc Solo**. 2009; 33:831-843.

ANDRIOTTI JLS. Fundamentos de Estatística e Geoestatística. v.3. **Unisinos**, São Leopoldo; 2009.

APARECIDO LEO, ROLIM GS, RICHETTI J, SOUZA PS, JOHANN JA. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Cienc Agrotec**. 2016; 40:405-417. <https://doi.org/10.1590/1413-70542016404003916>

- BASSO B, FIORENTINO C, CAMMARANO D, CAFIERO G, DARDANELLI J. Analysis of rainfall distribution on spatial and temporal patterns of wheat yield in Mediterranean environment. **Eur J Agron.** 2012; 41:52-65.
- BERNARDI AC, BETTIOL GM, GREGO CR, ANDRADE RG, RABELLO LM, INAMASU RY. Ferramentas de agricultura de precisão como auxílio ao manejo da fertilidade do solo. **Cadernos de Ciência & Tecnologia.** 2017; 32(1/2):211-227.
- DABESSA, A.; DEBALA, C. Long-term soybean–maize rotation experiments in cereal-based farming systems at Bako, Western Ethiopia. **Food and Energy Security**, v. 12, n. 5, p. e496, 2023.
- CAMMARANO D, ZHA H, WILSON L, LI Y, BATCHELOR WD, MIAO Y. A remote sensing-based approach to management zone delineation in small scale farming systems. **Agronomy.** 2020; 10(11):1767.
- CARVALHO MP, TAKEDA EY, FREDDI OS. Variabilidade espacial de atributos de um solo sob videira em Vitória Brasil (SP). **Rev Bras Cienc Solo.** 2003; 27:695-703.
- CESARE L, MYERS DE, POSA D. Estimating and modeling space–time correlation structures. **Stat Prob Lett.** 2001; 51(1):9-14.
- CHILÈS JP, DELFINER P. Geostatistics: modeling spatial uncertainty. Vol. 713. **John Wiley & Sons;** 2012.
- COX MS, GERARD PD, WARDLAW MC, ABSHIRE MJ. Variability of selected soil properties and their relationships with soybean yield. **Soil Sci Soc Am J.** 2003; 67(4):1296-1302.
- CRESSIE NAC. Statistics for Spatial Data. rev. ed. New York: John Wiley & Sons; 2015.
- DALPOSSO GH, URIBE-OPAZO MA, JOHANN JA, BASTIANI FD, GALEA M. Geostatistical modeling of soybean yield and soil chemical attributes using spatial bootstrap. **Engenharia Agrícola.** 2019; 39:350-357.
- DAL'CANTON LE, MALTAURO TC, GUEDES LPC, URIBE-OPAZO MA, CIMA EG. Bivariate spatial correlation between soil attributes and soybean productivity in an agricultural area with Dystroferric Red Latosol. **Aust J Crop Sci.** 2023; 17(1):20-ii.
- DE BASTIANI F, GALEA M, CYSNEIROS AHMA, URIBE-OPAZO MA. Gaussian spatial linear models with repetitions: An application to soybean productivity. **Spat Stat.** 2017; 21:319-335.
- FERRAZ GAS, SILVA FMD, CARVALHO LC, ALVES MDC, FRANCO BC. Variabilidade espacial e temporal do teor de fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola.** 2012; 32:140-150.
- FREDDI OS, CARVALHO MP, VERONESI JÚNIOR V, CARVALHO GJ. Produtividade do milho relacionada com a resistência mecânica à penetração do solo sob preparo convencional. **Engenharia Agrícola.** 2006; 26:113-121.

- GAMERO P, URIBE-OPAZO MA, DE BASTIANI F, JOHANN JA, GUEDES LPC. Variabilidade espacial da precipitação no cultivo de milho segunda safra no Paraná utilizando o modelo Wave. **Irriga**. 2020; 25(3):521-536.
- GASCH CK, HENGL T, GRÄLER B, MEYER H, MAGNEY TS, BROWN DJ. Spatio-temporal interpolation of soil water, temperature, and electrical conductivity in 3D+ T: The Cook Agronomy Farm data set. **Spatial Statistics**. 2015; 14:70-90.
- GAVIOLI A, DE SOUZA EG, BAZZI CL, GUEDES LPC, SCHENATTO K. Optimization of management zone delineation by using spatial principal components. **Comput Electron Agric**. 2016; 127:302-310.
- GUEDES LP, BACH RT, URIBE-OPAZO MA. Nugget effect influence on spatial variability of agricultural data. **Engenharia Agrícola**. 2020; 40:96-104.
- HAIR JF, BLACK WC, BABIN BJ, ANDERSON RE, TATHAM RL. Análise multivariada de dados. **Bookman editora**; 2009.
- HEUVELINK GBM, VAN EGMOND FM. Geostatistical Applications for Precision Agriculture. 2010.
- HEUVELINK GB, GRIFFITH DA, HENGL T, MELLES SJ. Sampling Design Optimization for Space-Time Kriging. In: **Spatio-Temporal Design: Advances in Efficient Data Acquisition**. 2012. pp. 207-230.
- HU PL, LIU SJ, YE YY, ZHANG W, WANG KL, SU YR. Effects of environmental factors on soil organic carbon under natural or managed vegetation restoration. **Land Degrad Dev**. 2018; 29(3):387-397.
- ISAAKS EH, SRIVASTAVA RM. Applied geostatistics. Oxford University Press; 1989.
- LIU X, ZHANG W, ZHANG M, FICKLIN DL, WANG F. Spatio-temporal variations of soil nutrients influenced by an altered land tenure system in China. **Geoderma**. 2009; 152(1-2):23-34.
- LIU XL, FU XQ, LI Y, SHEN JL, WANG Y, ZOU GH, *et al*. Spatio-temporal variability in N<sub>2</sub>O emissions from a tea-planted soil in subtropical central China. **Geosci Model Dev Discuss**. 2016: 1-45.
- LIU H, LI S, ZHOU Y. Spatial-temporal variability of soil organic matter in urban fringe over 30 years: a case study in Northeast China. **Int J Environ Res Public Health**. 2020; 17(1):292.
- LORBIESKI R, GUEDES LPC, URIBE-OPAZO MA, KESTRING FBF. Regionalization of an agricultural area by means of multivariate data and their relationship with soybean productivity. **Aust J Crop Sci**. 2023; 17(7):570-580.
- KAYAD A, SOZZI M, GATTO S, WHELAN B, SARTORI L, MARINELLO F. Ten years of corn yield dynamics at field scale under digital agriculture solutions: A case study from North Italy. **Comput Electron Agric**. 2021; 185:106126.
- KHAN H, ACHARYA B, FAROOQUE AA, ABBAS F, ZAMAN QU, ESAU T. Soil and crop variability induced management zones to optimize potato tuber yield. **Appl Eng Agric**. 2020; 36(4):499-510.

KILIBARDA M, TADIĆ MP, HENGL T, LUKOVIĆ J, BAJAT B. Global geographic and feature space coverage of temperature data in the context of spatio-temporal interpolation. **Spatial Statistics**. 2015; 14:22-38.

KILIC K, KILIC S, KOCYIGIT R. Assessment of spatial variability of soil properties in areas under different land use. **Bulgarian Journal of Agricultural Science**. 2012.

MALTAURO TC, GUEDES LP, URIBE-OPAZO MA, CANTON LE. Multivariate spatial sample reduction of soil chemical attributes by means of application zones. **Span J Agric Res**. 2023;21(2): e0205-e0205.

MATHERON G. Choice and Hierarchy of Models. In: Estimating and Choosing. **Springer**, Berlin, Heidelberg; 1989.

MINASNY B, MCBRATNEY AB. Spatial prediction of soil properties using EBLUP with the Matérn covariance function. **Geoderma**. 2007; 140(4):324-336.

MONTERO JM, FERNÁNDEZ-AVILÉS G, MATEU J. Spatial and spatio-temporal geostatistical modeling and kriging. **John Wiley & Sons**; 2015.

MONTEIRO A, MENEZES R, SILVA ME. Modelling spatio-temporal data with multiple seasonalities: The NO<sub>2</sub> Portuguese case. **Spatial Statistics**. 2017; 22:371-387.

NOETZOLD R, DE CARVALHO ALVES M, MARCOS GOUSSAIN JÚNIOR M, DE CÁSSIA SANTOS GOUSSAIN R. Variabilidade Espacial Da Eficiência Do Uso De Potássio E Teor de fósforo Na Cultura Da Soja. **Engenharia na Agricultura**. 2019; 27(6).

OU Y, ROUSSEAU AN, WANG L, YAN B. Spatio-temporal patterns of soil organic carbon and pH in relation to environmental factors—A case study of the Black Soil Region of Northeastern China. **Agric Ecosyst Environ**. 2017; 245:22-31.

PAULETTI V, PIERRI LD, RANZAN T, BARTH G, MOTTA ACV. Efeitos em longo prazo da aplicação de gesso e calcário no sistema de plantio direto. **Rev Bras Cienc Solo**. 2014; 38:495-505.

PEBESMA EJ. Multivariable geostatistics in S: the gstat package. **Comput Geosci**. 2004; 30(7): 683-691.

PEBESMA E. spacetime: Spatio-temporal data in R. *J Stat Softw*. 2012; 51:1-30.  
 PELLETIER, B.; DUTILLEUL, P.; LAROCQUE, G.; FYLES, J. W. Fitting the linear model of coregionalization by generalized least squares. *Mathematical Geology*, 36, 323-343. 2004.

R DEVELOPMENT CORE TEAM. R: a language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Áustria. ISBN 3-900051 07-0. 2024. Available online: <http://www.R-project.org/>.

RASHMI, I.; SHIRALE, A.; KARTIKHA, K. S.; SHINOI, K. C.; MEENA B. P.; KALA, S. Leaching of plant nutrients from agricultural lands. **Essential Plant Nutrients: Uptake, Use Efficiency, and Management**, 465-489. 2017.

RESENDE AV, COELHO AM. Muestreo para mapeo y manejo de la fertilidad del suelo. In: Mantovani EC, MAGDALENA C, MAGDALENA C, editors. **Manual de agricultura de precisión**. 2014

RIBEIRO JUNIOR PJ, DIGGLE PJ. geoR: A package for geostatistic analysis. **Rnews**, New York. 2001; 1(2):15-18.

SANTOS HG, JACOMINE PKT, ANJOS LHC, OLIVEIRA VA, LUMBRERAS JF, COELHO MR, *et al.* Sistema brasileiro de classificação de solos. 5. ed. **rev. ampl.** Brasília, DF: Embrapa; 2018.

SHEN J, YUAN L, ZHANG J, LI H, BAI Z, CHEN X, *et al.* Phosphorus dynamics: from soil to plant. **Plant physiology**. 2011; 156 (3): 997-1005.

SHI P, ZHANG Y, LI P, LI Z, YU K, REN Z, *et al.* Distribution of soil organic carbon impacted by land-use changes in a hilly watershed of the Loess Plateau, China. **Sci Total Environ**. 2019; 652: 505-512.

SNEPVANGERS JJJ, HEUVELINK GBM, HUISMAN JA. Soil water content interpolation using spatio-temporal kriging with external drift. **Geoderma**. 2003; 112(3-4): 253-271.

ŠTÍPEK K, VANĚK V, SZÁKOVÁ J, ČERNÝ J, ŠILHA J. Temporal variability of available phosphorus, potassium and magnesium in arable soil. **Plant Soil Environ**. 2004; 50(12): 547-551.

URIBE-OPAZO MA, BORSSOI J, GALEA M. Influence diagnostics in Gaussian spatial linear models. **Journal of Applied Statistics**. 2012. 39(3): 615–630.

URIBE-OPAZO, M. A.; DE BASTIANI, F.; GALEA, M.; SCHEMMER, R. C.; ASSUMPÇÃO, R. A. B. Influence diagnostics on a reparameterized t-Student spatial linear model. **Spatial Statistics**, 41, 100481. 2021.

URIBE-OPAZO MA, DALPOSSO GH, GALEA M, JOHANN JA, DE BASTIANI F, CAMBILLO MOYANO EN, GRZEGOZEWSKI DM. Spatial variability of wheat yield using the gaussian spatial linear model. **Aust J Crop Sci**. 2023; 17(2): 179-189.

VAROUCHAKIS EA. Spatiotemporal geostatistical modelling of groundwater level variations at basin scale: a case study at Crete's Mires Basin. **Hydrol Res**. 2018; 49(4): 1131–1142.

VIANA RSM, DOS SANTOS GR, MOREIRA DS, LOUZADA JM, ROSA LMF. O Uso da Geoestatística Espaço-Temporal na Predição da Temperatura Máxima do Ar. **Rev Bras Geogr Fís**. 2019; 12: 96-111.

YANG H, SONG X, ZHAO Y, WANG W, CHENG Z, ZHANG Q, *et al.* Temporal and spatial variations of soil C, N contents and C: N stoichiometry in the major grain-producing region of the North China Plain. **Plos One**. 2021; 16(6): e0253160.

WANG, Q.; LI, Y.; KLASSEN, W.; ALVA, A. High retention of NP nutrients, soil organic carbon, and fine particles by cover crops under tropical climate. **Agronomy for sustainable development**, 32, 781-790. 2012.

WANG, Y.; ZHANG, L.; MENG, F.; LOU, Z.; AN, X.; JIANG, X.; ZHANG, W. Responses of Soil Microbial Communities in Soybean–Maize Rotation to Different Fertilization Treatments. **Agronomy**, 13(6), 1590. 2023.

WEISS, A. A. A comparison of ordinary least squares and least absolute error estimation. **Econometric Theory**, v. 4, n. 3, p. 517-527, 1988.

ZHUO Z, XING A, LI Y, HUANG Y, NIE C. Spatio-temporal variability and the factors influencing soil-available heavy metal micronutrients in different agricultural sub-catchments. **Sustainability**. 2019; 11(21): 5912.

## 5.2 Artigo 2 – Funções Ortogonais Empíricas Com Irregularidade Temporal: Análise Da Variabilidade Espacial E Temporal Dos Atributos Químicos Do Solo Em Uma Área Produtora De Soja

### FUNÇÕES ORTOGONAIS EMPÍRICAS COM IRREGULARIDADE TEMPORAL: ANÁLISE DA VARIABILIDADE ESPACIAL E TEMPORAL DOS ATRIBUTOS QUÍMICOS DO SOLO EM UMA ÁREA PRODUTORA DE SOJA

**Resumo:** O objetivo desse estudo foi investigar a variabilidade espaço-temporal dos atributos químicos do solo (teor de cálcio, teor de fósforo, teor de matéria orgânica e pH) em uma área de 167,35 hectares produtora de soja em Cascavel, Paraná, Brasil, utilizando Funções Ortogonais Empíricas (EOFs) e a Transformada de Fourier de Lomb-Scargle (LSDFT) para analisar dados distribuídos de forma irregular no tempo, coletados entre 2010 e 2022. As EOFs foram utilizadas para decompor os dados em modos que capturam os padrões dominantes de variabilidade. A variabilidade espaço-temporal foi explicada por duas EOFs para teor de cálcio, três EOFs para pH e teor de matéria orgânica e quatro EOFs para teor de fósforo, indicando uma distribuição mais simples e uniforme para o teor de cálcio e mais complexa para o teor de fósforo. Os mapas das EOFs revelam padrões específicos para cada atributo químico: a EOF-1 mostrou diferenças centrais para teor de cálcio, distinções norte-sudeste para pH, variações leste-oeste para o teor de fósforo e padrões centrais para o teor de matéria orgânica, enquanto as outras EOFs destacaram variações norte-sul como características secundárias. Os anos de 2010, 2016, 2021 e 2022 foram especialmente relevantes na variabilidade dos atributos químicos. Os espectros de potência foram úteis para identificar eventos sazonais que podem estar atuando sobre esses atributos. A análise da variabilidade dos atributos químicos do solo por meio das EOFs revelou padrões importantes de variação espacial e temporal, sendo que essa técnica associada à análise dos espectros de potência da LSDFT, permitiu identificar e caracterizar padrões que afetaram a variabilidade dos atributos químicos do solo, que de outra forma, seriam difíceis de detectar.

**Palavras-chave:** Agricultura de Precisão, Análise multivariada espaço-temporal, Transformada de Fourier de Lomb-Scargle

#### 5.2.1 Introdução

Os rápidos avanços nas tecnologias de agricultura de precisão (AP) abriram novos caminhos para otimizar as práticas agrícolas e aumentar a produtividade das culturas, como a da soja (Sharma, 2023). A produção de soja é uma atividade agrícola de grande relevância econômica e social em diversos países, incluindo o Brasil, que é um dos maiores produtores e exportadores mundiais dessa oleaginosa (Toloi *et al.*, 2021).

Estudos apontam que os atributos químicos do solo impactam o desenvolvimento da soja e, conseqüentemente, sua produtividade (Takamoto *et al.*, 2020). Isso ressalta a importância de um melhor entendimento das características químicas do solo, como sua variabilidade, para auxiliar pesquisadores e produtores a

melhorar a qualidade do solo, possibilitando aumentar a produtividade da soja (Zhuo *et al.*, 2019).

Um aspecto crucial da AP é a capacidade de reconhecer e gerenciar a variabilidade espacial e temporal inerente aos campos agrícolas (Castrignanò *et al.*, 2020). Uma característica importante dos atributos químicos do solo é essa variabilidade, sendo ela resultado de múltiplos fatores, incluindo a heterogeneidade natural do solo, as práticas de manejo agrícola e as condições climáticas (Piotrowska-Dlugosz *et al.*, 2015). A análise dessa variabilidade é crucial para a identificação de padrões e tendências que possam influenciar a produtividade, permitindo a adoção de estratégias de manejo específicas para diferentes áreas e períodos (Gomes *et al.*, 2021; Leuthold *et al.*, 2024).

Nesse contexto, a utilização da análise de funções ortogonais empíricas (EOFs) para examinar a variabilidade espaço-temporal dos atributos químicos do solo pode ser uma ferramenta valiosa para a AP. A EOF é uma técnica estatística que pode ser empregada para decompor conjuntos de dados espaciais e temporais complexos em um conjunto de funções de bases ortogonais, ou modos, que capturam os padrões dominantes de variabilidade (Neha; Pasari, 2021). Esta análise é considerada uma abordagem exploratória espaço-temporal que, por meio da redução da dimensionalidade dos dados, possibilita a visualização de tendências na variabilidade espacial e temporal (Finkenstädt; Held; Isham, 2006).

Entretanto, essa técnica possui uma importante limitação que é a necessidade de dados completos (Dupuis; Schumacher, 2018). Esse fato se torna um desafio para a análise de dados agrícolas, pois, dados faltantes e incompletos são comuns em pesquisas agrícolas.

Estudos mostram que a falta de dados pode ocorrer devido a erros de manuseio de amostras, erros de medição ou simplesmente por falta de análise (Ispirova *et al.*, 2020). Em sistemas de monitoramento agrícola, dados ausentes, distorcidos ou imprecisos podem levar a erros nos modelos de previsão e gestão (Şentop *et al.*, 2023).

Nesse contexto, a utilização da Transformada de Fourier de Lomb-Scargle Discreta (LSDFT) se mostra como uma alternativa para a análise de dados temporais não equiespaçados, permitindo a criação de matrizes de covariância mais precisas. Essa técnica é particularmente eficaz na detecção de padrões temporais em séries temporais irregulares, o que é crucial para a avaliação de variabilidade em sistemas agrícolas (Seilmayer; Gonzalez; Wondrack, 2020). A análise do espectro de potência

facilita a identificação e avaliação de eventos sazonais que podem influenciar a variabilidade dos atributos químicos do solo (Pytharouli; Stiros, 2007).

Portanto, incorporar a EOF ao estudo da variabilidade dos atributos químicos do solo conjuntamente com a LSDFT oferece vantagens, ao permitir identificar padrões importantes e adaptar as estratégias de manejo às condições específicas de diferentes áreas. Assim, o objetivo do trabalho foi avaliar as características dos padrões de variabilidade espaço-temporal de atributos químicos do solo em um conjunto de dados distribuído de forma irregular no tempo utilizando para isso as EOFs obtidas usando LSDFTs e assim contribuir para um melhor entendimento dos fatores que afetam as características químicas do solo e que podem afetar a produtividade.

## 5.2.2 Metodologia

### 5.2.2.1 Coleta de Dados e Área de Estudo

A pesquisa utilizou dados dos seguintes atributos químicos do solo: teor de cálcio (Ca) ( $\text{cmolc dm}^{-3}$ ), teor de fósforo (P) ( $\text{mg dm}^{-3}$ ), teor de matéria orgânica (MO) ( $\text{g dm}^{-3}$ ) e pH ( $\text{CaCl}_2$ ). Os dados amostrais foram obtidos por meio de análises químicas no laboratório de análise de solos da COODETEC (Cooperativa Central de Pesquisa Agrícola). Amostras representativas de cada parcela, pesando aproximadamente 500 g, foram coletadas em cada ponto demarcado (Figura 1) (Ribeiro *et al.*, 2024). As análises químicas foram realizadas utilizando o método de Walkley–Black (1934).

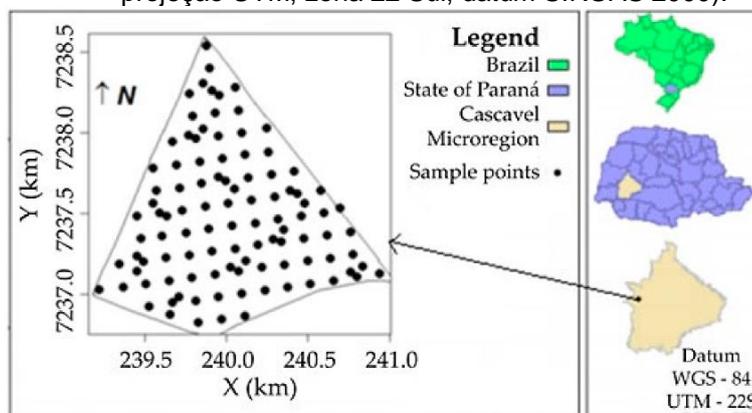
As amostras foram coletadas antes do plantio e desenvolvimento da soja, em nove safras entre 2010 e 2022. Trabalhar com dados de vários anos-safra permite capturar a variabilidade temporal dos atributos químicos do solo, identificando tendências e mudanças ao longo do tempo. Isso aumenta a robustez e a confiabilidade dos resultados, minimizando o impacto de eventos atípicos ou sazonais.

As coletas foram feitas em uma área agrícola de 167,35 hectares no município de Cascavel, Paraná, Brasil (Figura 1) com altitude média da área é de 650 metros. O solo é classificado como Latossolo Vermelho Distroférrico típico (Santos *et al.*, 2018), ou Oxisols (Taxonomia do Solo), com textura argilosa. O clima é classificado como mesotérmico e temperado superúmido, do tipo Cfa (classificação de Köppen), com temperatura média anual de 21 °C (Aparecido *et al.*, 2016).

Foram determinados 102 pontos de amostragem utilizando a técnica *lattice plus close pairs*, que permite uma distribuição uniforme dos pontos de amostragem na área de estudo (Uribe Opazo *et al.*, 2021; Maltauro *et al.*, 2023). Nos anos de 2011, 2017,

2018 e 2020, não houve coleta de dados, portanto, não há informações sobre os atributos químicos do solo estudadas nesses anos.

Figura 1 – Representação do mapa com os pontos de amostragem (sistema de coordenadas planas, projeção UTM, zona 22 Sul, datum SIRGAS 2000).



Fonte: Os Autores (2024).

#### 5.2.2.2 Funções Ortogonais Empíricas (EOF)

Os atributos químicos do solo foram analisados em relação à sua estrutura de dependência espaço-temporal por meio da Função Ortogonal Empírica (EOF). As EOFs são autovetores obtidos da decomposição em autovalores/autovetores de uma matriz de covariância ou correlação. Na forma discreta, a análise da EOF é semelhante à Análise de Componentes Principais (PCA).

As EOFs são usadas para identificar estruturas espaciais principais e sua variação temporal, assim como reduzir a dimensão e o ruído em grandes conjuntos de dados espaço-temporais (Cressie; Wike, 2015). Pode-se dizer então que as EOFs buscam determinar um novo conjunto de variáveis que capturam a maior parte da variabilidade dos dados, utilizando-se de combinações lineares das variáveis originais permitindo reduzir a dimensionalidade (Hannachi, 2007).

O estudo das EOFs relaciona-se à PCA, pois podem ser extraídas dos dados usando uma decomposição espectral de uma matriz de covariância espacial empírica ou uma decomposição em valores singulares (SVD) de uma matriz centrada (Cressie; Wike, 2015). No entanto, os traços do vetor de dados multivariados são indexados espacialmente e as amostras são coletadas ao longo do tempo (Wike *et al.*, 2019).

A decomposição em valores singulares (SVD) de uma matriz centrada apresenta vantagens sobre a decomposição espectral da matriz de covariância espacial empírica, especialmente em termos computacionais e de tratamento de dados de alta dimensionalidade. Hannachi *et al.* (2007) destacam que o SVD é mais

eficiente porque atua diretamente na matriz de dados, evitando a necessidade de calcular a matriz de covariância, o que pode ser intensivo em recursos para grandes conjuntos de dados espaciais.

De fato, para avançar na compreensão científica, é essencial ter uma visão das relações que conectam várias variáveis em diferentes lugares. A matriz de covariância é o objeto estatístico que pode descrever tais relações (Navarra; Simoncini, 2010). A partir da matriz de covariância, calculam-se, então, as EOFs por meio da sua decomposição espectral (SVD) (Eq. 1) (Wike *et al.*, 2019).

$$\mathbf{C}_z^{(0)} = \mathbf{\Psi}\mathbf{\Lambda}\mathbf{\Psi}' \quad (1)$$

Em que:  $\mathbf{C}_z^{(0)}$  é a matriz de covariância na defasagem zero, de dimensão  $m \times m$ , sendo  $m$  o número de pontos espaciais amostrados;  $\mathbf{\Psi} \equiv (\boldsymbol{\psi}_1, \dots, \boldsymbol{\psi}_m)$  é uma matriz  $m \times m$  de autovetores de  $\mathbf{C}_z^{(0)}$ , indexados espacialmente e cujo  $k$ -ésimo autovetor,  $\boldsymbol{\psi}_k \equiv (\psi_k(\mathbf{s}_1), \dots, \psi_k(\mathbf{s}_m))'$ , é chamado de  $k$ -ésima EOF, para  $k = 1, \dots, m$ ; e  $\mathbf{\Lambda} \equiv \text{diag}(\lambda_1, \dots, \lambda_m)$  é uma matriz diagonal,  $m \times m$ , de autovalores não negativos (decrecendo ao longo da diagonal) de  $\mathbf{C}_z^{(0)}$ . As EOFs são frequentemente representadas como mapas espaciais, pois estão indexadas espacialmente, permitindo a identificação de padrões de variabilidade (Wike *et al.*, 2019).

Para gerar mapas espaciais das EOFs, utilizou-se a técnica *Thin Plate Spline Generalized Linear Model* (TPS-GLM) (Ibacache-Pulgar *et al.*, 2024). O mapa resultante representou o padrão de variação espacial das EOFs para os diferentes anos analisados. Esses mapas foram analisados em relação aos coeficientes temporais de cada EOF. As séries temporais oriundas das EOFs são obtidas por meio da Eq. 2.

$$\mathbf{A}_{T \times m} = (\sqrt{T-1})\tilde{\mathbf{Z}}_{T \times m}\mathbf{\Psi}_{m \times m} \quad (2)$$

$$\tilde{\mathbf{Z}}_{T \times m} \equiv \frac{1}{\sqrt{T-1}}(\mathbf{Z}_{T \times m} - \mathbf{1}_T \hat{\boldsymbol{\mu}}'_{z,s}) \quad (3)$$

Em que:  $\mathbf{Z}$  é a matriz ( $T \times m$ ) de dados originais (espaço-temporal), onde  $T$  é a quantidade de tempos observados e  $m$  é a quantidade de pontos amostrais espaciais.  $\mathbf{1}_T$  é um vetor  $T$ -dimensional de uns, ou seja,  $T \times 1$  e  $\hat{\boldsymbol{\mu}}'_{z,s}$  ( $1 \times m$ ) é um vetor de médias espaciais de cada localização em todos os tempos. A  $k$ -ésima coluna

de  $\mathbf{A}_{T \times m}$  gera a série temporal da  $k$ -ésima EOF, para  $k = 1, \dots, m$ , sendo então cada elemento dessa série temporal calculado para o tempo  $t_j$ , com  $j = 1, \dots, T$ , é dado por  $a_k(t_j) \equiv \tilde{\mathbf{z}}_{t_j} \boldsymbol{\psi}_k$  (Wikle *et al.*, 2019).

As séries temporais das EOFs podem ser normalizadas por  $\mathbf{A}_{\text{norm}} \equiv \mathbf{A} \boldsymbol{\Lambda}^{-1/2}$ . Isso significa que as séries temporais das EOFs são divididas por seu desvio padrão, de modo que a variância temporal da série temporal normalizada seja igual a um. Isso permite que as séries temporais de cada EOF sejam plotadas na mesma escala, deixando que sua importância relativa seja capturada por seus autovalores correspondentes (Wike *et al.*, 2019).

Assim como na PCA, as EOFs possuem duas propriedades vantajosas: (a) as EOFs constituem uma base ortonormal discreta (ou seja,  $\boldsymbol{\Psi}' \boldsymbol{\Psi} = \boldsymbol{\Psi} \boldsymbol{\Psi}' = \mathbf{I}$ ), e (b) as primeiras EOFs capturam a maior parte da informação contida nos dados, considerando a variância total empírica espacial com defasagem temporal zero, que é representada pela soma dos elementos da diagonal de  $\mathbf{C}_z^{(0)}$  (Wike *et al.*, 2019).

A variância total é dada pela soma de todos os autovalores individuais (traço de  $\boldsymbol{\Lambda}$ ), assim uma medida da contribuição individual (%) de cada EOF na explicação da variação total do conjunto de dados pode ser dado por  $r_k$  (Eq. 4, Neha; Pasari, 2022)

$$r_k = \frac{\lambda_k}{\text{traço } \boldsymbol{\Lambda}} 100\% \quad (4)$$

A literatura não apresenta uma abordagem clara para selecionar o número de EOFs significativas. Wikle *et al.* (2019) sugerem que uma abordagem simples é considerar o número de EOFs que representam uma proporção desejada da variância total, ou aplicar os critérios usados na PCA para esta seleção. Portanto, utilizou-se o critério que considera as primeiras EOFs (CPs) que explicam mais de 70% da variabilidade total das variáveis originais (Furtado, 1996).

Para se avaliar a proporção de contribuição de cada ano em cada EOF, utilizou-se a Equação 5. Somente os anos que apresentaram proporção maior ou igual a 0,7 foram escolhidos para explicar o comportamento da EOF.

$$M = \frac{|coef_{ano}| - |\text{mín}(EOF_i)|}{|\text{máx}(EOF_i)| - |\text{mín}(EOF_i)|} \quad (5)$$

Em que:  $coef_{ano}$  é o valor do coeficiente de cada ano em cada EOF avaliada,  $mín(EOF_i)$  e  $máx(EOF_i)$  são respectivamente o menor e o maior valor na  $i$ -ésima EOF.

### 5.2.2.3 Transformação de Fourier de Lomb-Scargle

Devido à ausência de coletas em alguns anos (2011, 2017, 2018, 2020), os dados do estudo são amostrados de forma irregular no tempo, sendo considerados dados não equiespaçados ou "gappy". Ou seja, isso se refere a séries temporais com intervalos irregulares, o que dificulta a aplicação direta de EOFs.

Resolver o problema de EOF com dados uniformemente amostrados é simples e semelhante a PCA, mas com dados desiguais esse processo é complexo. A dificuldade principal está no cálculo da matriz de covariância, essencial para a análise de EOF. Métodos aproximados, como "pairwise-complete observation" e técnicas de interpolação, geralmente resultam em perda de precisão dos dados obtidos (Dupuis; Schumacher, 2018).

Para contornar esse problema utilizou-se a Transformada Discreta de *Fourier de Lomb-Scargle* (LSDFT) que é essencial para esse tipo de análise, pois, permite uma avaliação precisa dos elementos da matriz de covariância no espaço espectral, utilizando todos os dados disponíveis e gerenciando grandes lacunas nos tempos de amostragem dados (Dupuis; Schumacher, 2018). Com essa técnica não é necessário o uso de interpolação dos dados, preservando assim a informação original e minimizando a distorção dos resultados (Scargle, 1989).

A LSDFT é uma extensão da transformada discreta de Fourier, adaptada para séries temporais irregularmente espaçadas. A LSDFT é dada pela Eq. 6 (Press; Rybicki 1989) e consiste numa função de  $\omega$ , ou seja,  $\tilde{S}(\omega)$ , onde  $\omega$  é a frequência angular.

$$\tilde{S}(\omega) = \frac{1}{\sqrt{2\sigma^2}} \sum_j \left[ \frac{(S_j - \bar{S}) \cos[\omega(t_j - \tau)]}{\sqrt{\sum_j \cos^2[\omega(t_j - \tau)]}} + i \frac{(S_j - \bar{S}) \text{sen}[\omega(t_j - \tau)]}{\sqrt{\sum_j \text{sen}^2[\omega(t_j - \tau)]}} \right] \quad (6)$$

Em que:  $\omega = 2\pi f$ , sendo  $f$  a frequência, que é dada em um intervalo de mil pontos iniciando em  $f_{min} = \frac{1}{T}$  até  $f_{máx} = \frac{1}{\Delta T}$ , chamada de frequência de Nyquist (Press; Rybicki, 1989; Scargle, 1989; Tang, 2022). Dado um conjunto de  $T$  observações no tempo,  $t_j$  é o  $j$ -ésimo tempo observado ( $j = 1, \dots, T$ ),  $S_j$  é o valor observado no  $j$ -ésimo

tempo,  $\bar{S}$  é a média dos valores observados,  $\sigma^2 = \frac{1}{N-1} \sum_j (S_j - \bar{S})^2$  e  $\tau$  é um fator de correção definido pela Eq. 7.

$$\tau = \frac{1}{2\omega} \arctan \left( \frac{\sum_j \text{sen}(2\omega t_j)}{\sum_j \text{cos}(2\omega t_j)} \right) \quad (7)$$

#### 5.2.2.4 Geração da Matriz de Covariância usando LSDFT

A matriz de covariância, essencial para a análise de EOF, pode ser calculada no espaço espectral usando a LSDFT (Eq. 6), o que permite utilizar todas as observações disponíveis. Essa matriz é obtida ao transformar dois conjuntos de dados, multiplicando um pelo conjugado complexo do outro e aplicando a transformada inversa (Eq. 8). Esse método permite que os tempos de amostragem das duas séries sejam arbitrários, desde que se sobreponham no espaço de fase (Scargle, 1989).

$$\sigma_{xy}(t_{lag}) = \frac{1}{nk} \sum_{k=1}^{nk} \tilde{X}(\omega_k) \tilde{Y}^*(\omega_k) e^{i\omega_k t_{lag}} \quad (8)$$

Em que:  $\tilde{X}(\omega_k)$  e  $\tilde{Y}^*(\omega_k)$  são as LSDFTs (Eq. 6) das séries temporais X e Y, respectivamente,  $\omega_k$  são as frequências angulares nas  $k$  frequências consideradas para o cálculo da LSDFT,  $nk$  é a quantidade de frequências consideradas para o cálculo da LSDFT e \* denota o conjugado complexo. Utilizou-se  $t_{lag} = 0$ , pois as EOFs são calculadas diretamente da decomposição espectral da matriz de covariância empírica com lag-0 (Wike *et al.*, 2019). Com a matriz de covariância conhecida, é possível resolver o problema EOF (Dupuis; Schumacher, 2018).

#### 5.2.2.5 Análise dos Espectros de Potência

A análise dos espectros de frequência pode ser útil para se entender a variabilidade temporal em dados não equiespaçados temporalmente. A análise espectral é uma técnica comum para identificar e estudar periodicidades em dados de medições (Pytharouli; Stiros, 2007).

Os espectros foram gerados por meio do cálculo da densidade de potência espectral  $P(\omega)$  da LSDFT (Eq. 9), que é particularmente adequado para séries temporais desiguais (Dupuis; Schumacher, 2018).

$$P(\omega) = \frac{|\tilde{S}(\omega)|^2}{T} \quad (9)$$

Em que:  $\tilde{S}(\omega)$  são as LSDFTs calculadas e  $T$  é o número de amostras temporais.

O cálculo da densidade de potência espectral  $P(\omega)$  é comparável a um espectro de potência obtido pela Transformada de Fourier (FT), onde picos em determinadas frequências indicam uma possível presença de componentes periódicos. Os picos mais altos identificam as frequências mais importantes na série temporal, ou seja, representam as frequências com maior impacto no comportamento dos dados, indicando a importância de um determinado padrão ou repetição na série. Quanto mais elevado o pico, mais relevante é o componente periódico correspondente (Zhou; Sornette, 2002).

Esse método estima o espectro de potência da série temporal, representando as contribuições de diferentes frequências à variância total dos dados ao longo do tempo, cuja interpretação é crucial para compreender os fenômenos subjacentes (Delsole; Tippett, 2022).

### 5.2.3 Resultados e Discussões

#### 5.2.3.1 Teor de Cálcio

As duas primeiras EOFs explicam a maior parte da variância no teor de cálcio no solo (Tabela 1), com 62% e 15%, respectivamente. Isso indica que os principais padrões de variação são capturados por essas duas EOFs, que juntas explicam mais de 70% da variância total, atendendo ao critério de corte (Shaharudin; Ahmad, 2017).

As EOFs subsequentes contribuem com pequenas quantidades adicionais de variância, refletindo variabilidade menor. Portanto, somente as duas primeiras EOFs serão consideradas para análises posteriores, pois são representativas dos padrões dominantes de variação no teor de cálcio ao longo do período estudado.

Tabela 1. Variância das EOFs para teor de Cálcio.

EOF	Variância	%	% acumulada
<b>1</b>	<b>37</b>	<b>62</b>	<b>62</b>
<b>2</b>	<b>9</b>	<b>15</b>	<b>77</b>
3	3	6	83
4	3	5	88
⋮	⋮	⋮	⋮

101	6,03E <sup>-16</sup>	1,02E <sup>-15</sup>	100
Soma	59,35	100	-

Fonte: Os Autores (2024).

A Tabela 2 evidencia a importância dos diferentes anos na explicação dos padrões de variabilidade expressos nos mapas das EOFs. Para EOF-1, os anos 2016, 2021 e 2022 se destacam, com proporções de 0,70, 1,00 e 0,75, respectivamente, indicando que esses anos contribuem de maneira relevante para a variabilidade capturada por EOF-1. Já para EOF-2, os anos 2021 e 2022 são cruciais, com proporções de 0,72 e 1,00, respectivamente, revelando que esses anos têm uma contribuição substancial na explicação da variabilidade representada por EOF-2.

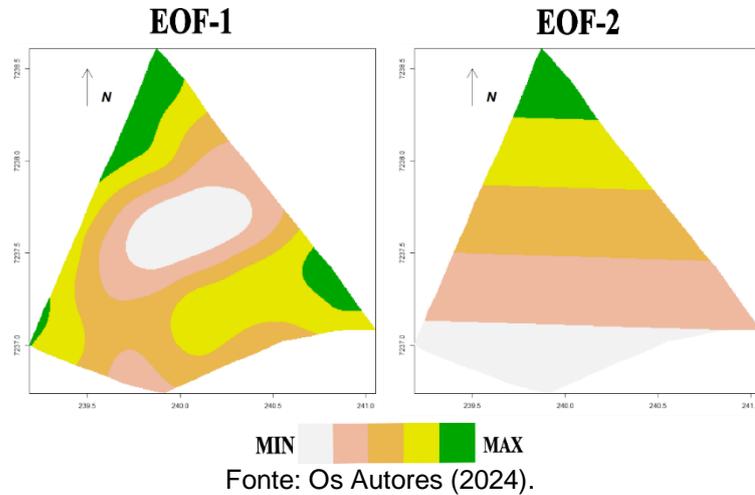
Tabela 2. Proporção da importância de cada ano para explicação dos padrões de variabilidade do teor de cálcio para cada EOF selecionada. Em vermelho se destacam os maiores coeficiente.

Ano	EOF-1	PROP	EOF-2	PROP
2010	1,72	0,33	1,87	0,39
2012	-0,51	0,08	1,89	0,40
2013	-0,12	0,00	-0,97	0,20
2014	1,36	0,25	-0,60	0,12
2015	1,14	0,21	-0,03	0,00
2016	3,54	0,70	0,20	0,04
2019	1,64	0,31	-1,05	0,22
2021	-4,99	1,00	3,39	0,72
2022	-3,78	0,75	-4,69	1,00

Fonte: Os Autores (2024).

O mapa da EOF-1 (Figura 2) destaca padrões distintos de variabilidade, principalmente entre a região central e os extremos do mapa. Os anos que mais contribuíram para essa variabilidade foram 2021, 2022 e 2016 (Tabela 2), com coeficientes de -4,99, -3,78 e 3,54, respectivamente (Tabela 2 e Eq. 10, em negrito). Os coeficientes negativos para 2021 e 2022 indicam uma relação inversa com o mapa da EOF-1, em que as maiores concentrações de teor de cálcio no solo estão na região central e os menores valores estão nas extremidades nesses respectivos anos. Em contraste, o coeficiente positivo para 2016 sugere uma relação direta, com menores concentrações de teor de cálcio na região central e maiores nas extremidades em 2016.

Figura 2. Mapa das duas primeiras EOFs do teor de Cálcio no solo, considerando todos os anos-safra entre os anos de 2010 e 2022.



O mapa da EOF-2 captura padrões de variação menos dominantes que a EOF-1, mas ainda relevantes, evidenciando uma variação gradual do teor de cálcio no solo no eixo norte-sul, caracterizando uma tendência direcional nesses dados. Para a EOF-2, os anos com maior contribuição para a variabilidade foram 2021 e 2022 (Tabela 2 e Eq. 11, em negrito).

O coeficiente positivo para 2021 indica uma relação direta com o mapa da EOF-2 (Figura 2), sugerindo um aumento gradativo no teor de cálcio do sul para o norte nesse ano. Em contraste, o valor negativo para 2022 indica uma relação inversa, com um aumento gradativo do teor de cálcio do norte para o sul em 2022.

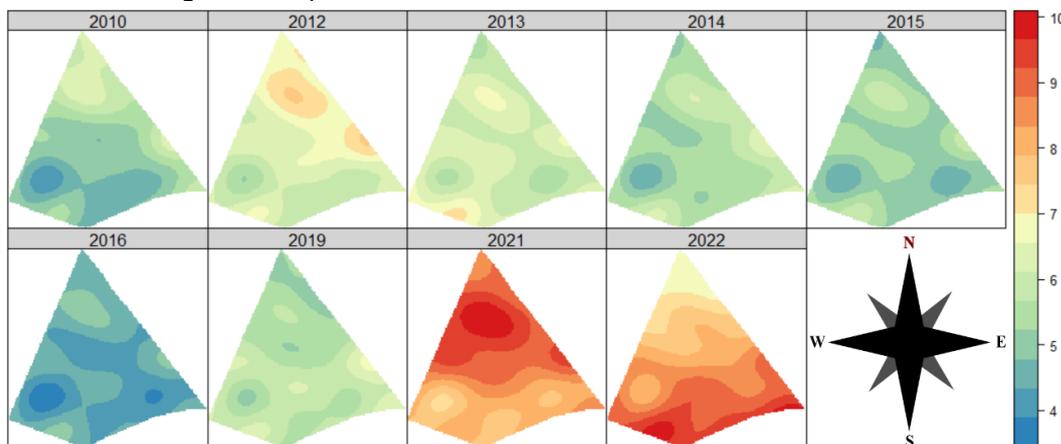
$$\begin{aligned} \text{EOF} - 1_{\text{Ca}} = & 1,72\text{Ca}_{2010} - 0,51\text{Ca}_{2012} - 0,12\text{Ca}_{2013} + 1,36\text{Ca}_{2014} \\ & + 1,14\text{Ca}_{2015} + \mathbf{3,54\text{Ca}_{2016}} + 1,64\text{Ca}_{2019} - \mathbf{4,99\text{Ca}_{2021}} \\ & - \mathbf{3,78\text{Ca}_{2022}} \end{aligned} \quad (10)$$

$$\begin{aligned} \text{EOF} - 2_{\text{Ca}} = & 1,87\text{Ca}_{2010} + 1,89\text{Ca}_{2012} - 0,97\text{Ca}_{2013} - 0,60\text{Ca}_{2014} \\ & - 0,03\text{Ca}_{2015} + 0,20\text{Ca}_{2016} - 1,05\text{Ca}_{2019} + \mathbf{3,39\text{Ca}_{2021}} \\ & - \mathbf{4,69\text{Ca}_{2022}} \end{aligned} \quad (11)$$

Os resultados apresentados também podem ser vistos nos mapas temáticos (Figura 3). Em relação à EOF-1, observa-se concentrações mais altas de Ca em 2021 e 2022 e mais baixas em 2016, se destacando altos valores de Ca a região central, principalmente em 2021. Para a EOF-2, os mapas temáticos mostram que em 2021 há valores mais baixos de teor de cálcio na região Sul e mais altos na região Norte, enquanto em 2022 ocorre o contrário, com maiores concentrações no Sul e menores

no Norte, caracterizando a tendência direcional mostrado no mapa da EOF-2 (Figura 2). As EOFs facilitaram a identificação desses padrões, como a tendência direcional na EOF-2, por exemplo, que seria difícil de destacar sem essa análise.

Figura 3. Mapa do teor de cálcio no solo entre os anos de 2010 e 2022.



Fonte: Os Autores (2024).

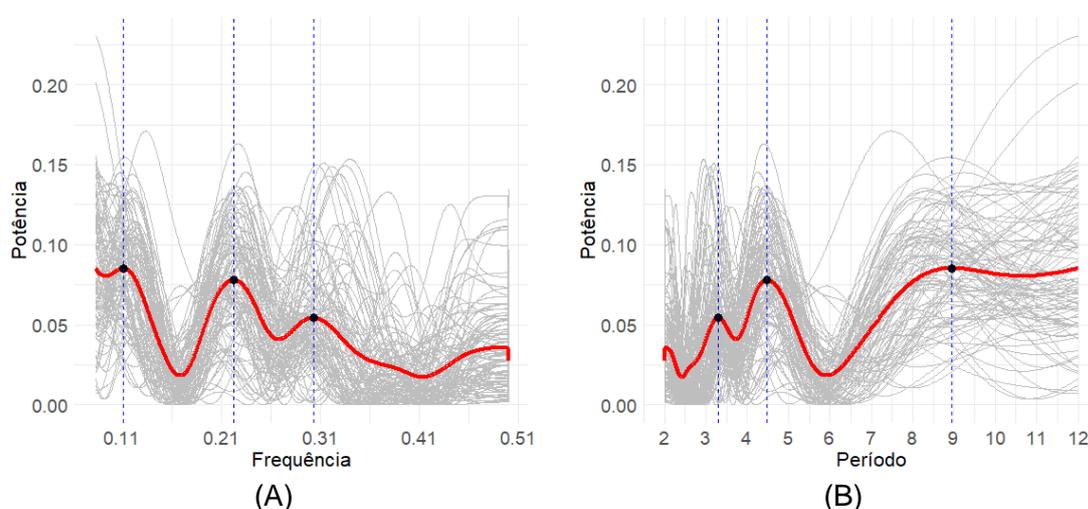
A análise dos espectros de potência para o teor de cálcio no solo permite identificar variações cíclicas em intervalos de tempo específicos, fornecendo insights sobre os padrões temporais de variação desse nutriente na área estudada. Os principais picos de frequência identificados foram próximos a 0,1, 0,2 e 0,3, (Figura 4A) correspondendo a ciclos de aproximadamente 9, 4,5 e 3 anos, respectivamente (Figura 4B). Esses ciclos podem ser indicativos de práticas agrícolas regulares, como a correção da acidez do solo por meio da aplicação de calcário, ou de eventos climáticos que afetam a disponibilidade e concentração de teor de cálcio no solo, conforme sugerido por estudos anteriores (Wheeler, 1997; Okolie *et al.*, 2023; Nastis *et al.*, 2012; Han *et al.*, 2019).

Ao associar esses resultados aos espectros de potência, nota-se que a análise revela não apenas a presença desses ciclos, mas também sua variabilidade espacial, representada pela dispersão dos espectros em torno da média (linhas cinzas no gráfico, Figura 4). Essa dispersão indica que os ciclos observados não ocorrem de maneira uniforme em toda a área amostral, sugerindo que diferentes regiões podem apresentar diferentes intensidades ou frequências de variação espacial do teor de cálcio ao longo do tempo. Isso reflete a influência de fatores locais, como as características edáficas (do solo) e práticas de manejo específicas que afetam cada ponto de amostragem. Portanto, a variação no comportamento dos diferentes espectros (linhas cinzas no gráfico, Figura 4) é uma indicação de que os eventos cíclicos não afetam todas as regiões da área agrícola da mesma maneira.

O ciclo mais longo de 9 anos, pode estar relacionado a mudanças gradativas no manejo do solo, possivelmente devido à aplicação de calcário ou outros insumos de longo prazo, cujos efeitos são percebidos em escalas temporais mais extensas. Essa tendência foi observada nas variações da concentração de teor de cálcio que se alterou a partir de 2021, conforme representado nos mapas temáticos discutidos previamente (Figura 3).

Já os ciclos de aproximadamente 3 e 4,5 anos, que correspondem a frequências mais altas, podem estar associados a eventos sazonais ou práticas agrícolas de curto e médio prazo, como a rotação de culturas ou eventos climáticos pontuais, que afetam a concentração de teor de cálcio em períodos mais curtos. Esses ciclos, especialmente os mais curtos são observados, com destaque para a região sudoeste da área de estudo nos anos de 2010, 2014 e 2016, conforme indicado pelos mapas temáticos, onde houve incidência de baixa concentração desse atributo.

Figura 4. Espectros de potência para o teor de cálcio no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes.



Fonte: Os Autores (2024).

De modo geral, o teor de cálcio no solo apresentou padrões importantes de variabilidade identificados pelas EOFs. Os padrões de variabilidade do teor de cálcio no solo são influenciados por diversos fatores edáficos e de manejo. O conteúdo e as formas do cálcio em diferentes tipos de solo podem variar amplamente, dependendo do material original do solo e do grau relativo de intemperismo e lixiviação (Sun *et al.*, 2021).

### 5.2.3.2 pH

De acordo com a Tabela 3 as três primeiras EOFs capturam 77% da variância total dos dados, indicando que a maioria da variabilidade dos dados é representada por essas três funções principais.

Tabela 3. Variância das EOFs para pH.

EOF	Variância	%	% acumulada
<b>1</b>	<b>30</b>	<b>54</b>	<b>54</b>
<b>2</b>	<b>7</b>	<b>12</b>	<b>66</b>
<b>3</b>	<b>6</b>	<b>10</b>	<b>77</b>
4	4	7	84
⋮	⋮	⋮	⋮
101	7,73E <sup>-16</sup>	1,41E <sup>-15</sup>	100
Soma	68,46	100	-

Fonte: Os Autores (2024).

A análise da Tabela 4 mostra que os anos com maior contribuição para explicar os padrões de variabilidade do pH são aqueles com proporções superiores a 0,7. Para o EOF-1, o ano de 2022 destacou-se como o mais influente.

No EOF-2, o ano de 2021 apresentou a maior proporção, indicando sua maior influência. Para o EOF-3, os anos de 2010 e 2012 foram os mais relevantes, com proporções de 1 e 0,77, respectivamente.

Tabela 4. Proporção da importância de cada ano para explicação dos padrões de variabilidade para o pH de cada EOF selecionada. Em vermelho se destacam os maiores coeficientes.

ANO	EOF-1	PROP	EOF-2	PROP	EOF-3	PROP
2010	-0,05	0,00	0,07	0,00	-1,15	<b>1,00</b>
2012	-0,16	0,08	0,11	0,03	-0,90	<b>0,77</b>
2013	0,40	0,26	-0,32	0,21	0,33	0,25
2014	0,46	0,30	0,17	0,09	0,34	0,26
2015	0,23	0,13	0,07	0,00	0,20	0,13
2016	0,99	0,69	-0,10	0,03	0,31	0,23
2019	0,18	0,10	0,86	0,68	0,06	0,00
2021	-0,91	0,63	-1,24	<b>1,00</b>	0,19	0,12
2022	-1,41	<b>1,00</b>	0,38	0,26	0,61	0,50

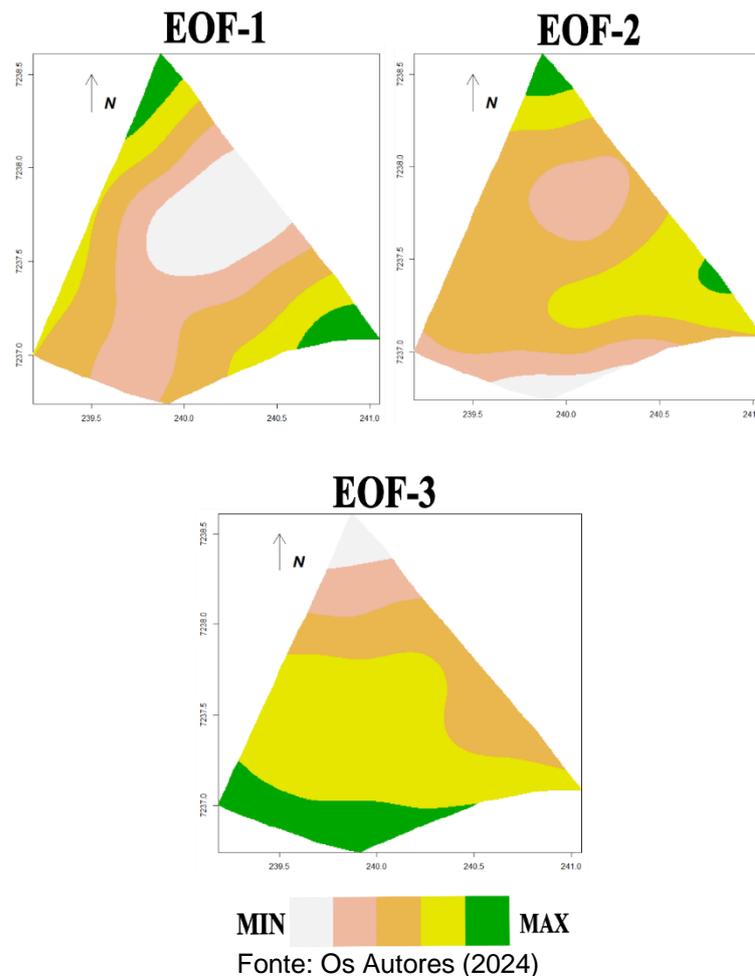
Fonte: Os Autores (2024).

O mapa de EOF-1 (Figura 5), que explica a maior parte da variabilidade espaço-temporal do pH do solo, mostra padrões distintos: as extremidades norte e sudeste apresentam um padrão (valores maiores de EOF-1), enquanto a região central mostra outro (valores menores de EOF-1).

Comparando esse mapa com o coeficiente de 2022, que teve a maior contribuição para esse padrão (Tabela 4) e um coeficiente negativo (-1,41) (Tabela 4 e Eq. 12, em negrito), verifica-se que, nesse ano, houve uma alta concentração de pH na região central e valores mais baixos nas extremidades norte e sudeste (Figura 5), que também foi identificada nos mapas do pH do ano de 2022 e 2021 (Figura 6).

As EOF-2 e EOF-3 explicam padrões secundários de variabilidade. O mapa de EOF-2 (Figura 5) apresenta maior homogeneidade comparado aos outros mapas, com valores intermediários na região central e valores extremos ao norte e sudeste da área de estudo. Comparando esse mapa com os coeficientes anuais (Tabela 4 e Eq. 13, em negrito), observa-se que se destaca 2021, com coeficiente de -1,24, sendo então que esse ano apresenta os valores de pH do solo mais baixos no norte e sudeste e intermediários na região central.

Figura 5. Mapa dos três primeiros EOFs do teor de pH no solo, considerando todos os anos-safra entre os anos de 2010 e 2022.



O mapa para EOF-3 descreve um padrão de tendência direcional norte-sul na distribuição dos valores do teor de pH do solo. Os anos de 2010 e 2012 foram os que

mais contribuíram exibindo coeficientes -1,15 e -0,90 respectivamente (Tabela 4 e Eq. 14, em negrito). Como em ambos os anos o coeficiente foi negativo, isso indica que existe uma relação inversa entre os valores desses atributos e a distribuição espacial revelada pelo mapa da EOF-3 (Figura 5). Para esses anos observa-se que as concentrações de pH são mais baixas no Sul, aumentando gradualmente até o Norte, onde os valores são mais altos.

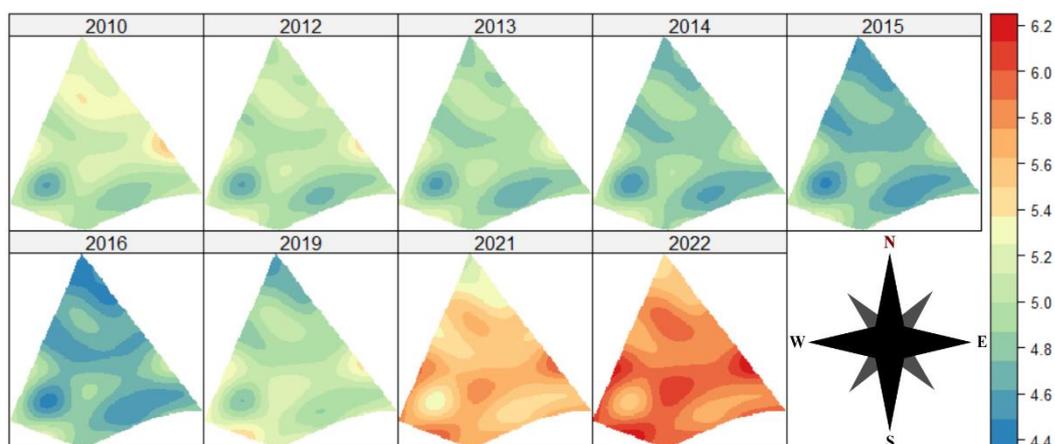
$$\begin{aligned} \text{EOF} - 1_{\text{pH}} = & -0,05\text{pH}_{2010} - 0,16\text{pH}_{2012} + 0,40\text{pH}_{2013} + 0,46\text{pH}_{2014} \\ & + 0,23\text{pH}_{2015} + 0,99\text{pH}_{2016} + 0,18\text{pH}_{2019} - 0,91\text{pH}_{2021} \\ & - \mathbf{1,41\text{pH}_{2022}} \end{aligned} \quad (12)$$

$$\begin{aligned} \text{EOF} - 2_{\text{pH}} = & 0,07\text{pH}_{2010} + 0,11\text{pH}_{2012} - 0,32\text{pH}_{2013} + 0,17\text{pH}_{2014} \\ & + 0,07\text{pH}_{2015} - 0,10\text{pH}_{2016} + 0,86\text{pH}_{2019} - \mathbf{1,24\text{pH}_{2021}} \\ & + 0,38\text{pH}_{2022} \end{aligned} \quad (13)$$

$$\begin{aligned} \text{EOF} - 3_{\text{pH}} = & -\mathbf{1,15\text{pH}_{2010}} - \mathbf{0,90\text{pH}_{2012}} + 0,33\text{pH}_{2013} + 0,34\text{pH}_{2014} \\ & + 0,20\text{pH}_{2015} + 0,31\text{pH}_{2016} + 0,06\text{pH}_{2019} + 0,19\text{pH}_{2021} \\ & + 0,61\text{pH}_{2022} \end{aligned} \quad (14)$$

Nos mapas temáticos (Figura 6) algumas das características apontadas pelos EOFs podem ser vistas, principalmente os descritos pela EOF-1 em relação ao ano de 2022 no qual apresentou concentrações altas para o teor de pH no solo na região central do mapa. Alguns outros padrões, entretanto, não são tão facilmente visualizados como, por exemplo, a tendência direcional norte-sul apontada pela EOF-3, sendo essa característica revelada principalmente pela EOF.

Figura 6. Mapa do pH do solo entre os anos de 2010 e 2022



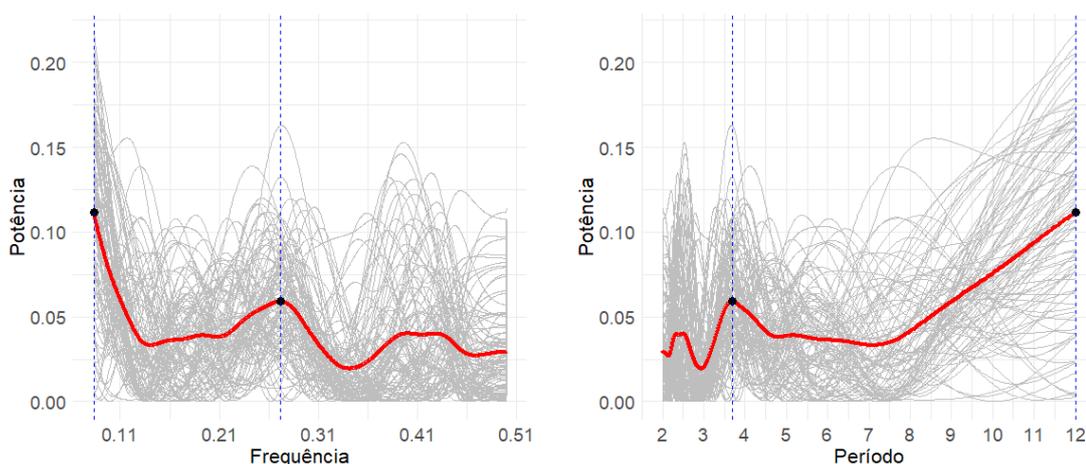
Fonte: Os Autores (2024)

O padrão de variabilidade do teor de pH no solo descrita pelas EOFs pode ser causada por diversos fatores espaciais e temporais. As características do solo é um desses fatores, de acordo com Pahlavan-Rad; Akbarimoghaddam (2018) solos com diferentes proporções de areia, silte e argila têm capacidades distintas de retenção de nutrientes e água, o que influencia o pH, já solos argilosos tendem a ter uma maior capacidade tampão, alterando menos seu pH.

O teor de matéria orgânica também contribui, ou seja, solos com maior conteúdo do teor de matéria orgânica frequentemente têm pH mais baixos devido à decomposição de resíduos orgânicos que liberam ácidos orgânicos (Xu *et al.*, 2020). Fatores climáticos como precipitação (Xie *et al.*, 2022) também influenciam principalmente em relação a variabilidade temporal. Por fim o manejo agrícola também tem forte contribuição, pois, a frequência e quantidade de aplicação de fertilizantes e corretivos influenciam as mudanças no pH do solo ao longo do tempo (Ferraz *et al.*, 2019).

A análise dos espectros de potência mostra uma dispersão relevante dos espectros individuais em comparação com o espectro médio nos gráficos da Figura 7, o que sugere que diferentes fenômenos estão acontecendo em pontos distintos da área de estudo, gerando variações nos efeitos observados. Apesar dessa variação, é possível identificar um pico de potência em baixas frequências, associado a um ciclo mais longo (12 anos), o que indica que as mudanças no pH estão ligadas principalmente a esses períodos mais amplos. Também é visível outro pico em uma frequência intermediária, sugerindo a presença de eventos periódicos, de menor intensidade, ocorrendo aproximadamente a cada 3,5 anos.

Figura 7. Espectros de potência para o pH no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes.



(A)

(B)

Fonte: Os Autores (2024).

Os picos do espectro de potência (Figura 7) podem ser analisadas em conjunto com os mapas temáticos de pH do solo (Figura 6). Observa-se um ciclo de variação aproximadamente entre 3,5 anos, refletido nas mudanças de pH entre 2010 e 2014 e entre 2016 e 2019, onde há períodos de estabilização e variação acentuada. Além disso, há um ciclo de 12 anos, associado às tendências de longo prazo do pH do solo, como a diminuição geral observada a partir de 2010 até 2021-2022, onde há um aumento considerável dos valores de pH no solo, esse efeito pode estar relacionado à correção do solo ocorrido nesses anos.

O comportamento observado nesses espectros de potência pode ser atribuído à estabilidade inerente do pH do solo, que é reforçada pela capacidade tampão do solo, resistindo a mudanças rápidas, principalmente em solos argilosos (Pahlavan-Rad; Akbarimoghaddam, 2018). Além disso, a correção do pH com calcário, pode ser aplicada em intervalos longos, o que contribui para a estabilidade do solo, pois o calcário reage gradualmente com os componentes ácidos, proporcionando uma correção duradoura e refletindo as variações de longo prazo nos espectros de potência (Rheinheimer *et al.*, 2018).

### 5.2.3.3 Teor de fósforo

Com relação ao teor de fósforo no solo, a primeira EOF explica 25% do total, enquanto a segunda EOF explica 17% do total, acumulando 42%. A terceira EOF contribui 15%, acumulando 57% (Tabela 5). A quarta EOF explica 13%, alcançando 70% de variância explicada acumulada. Assim as quatro EOFs serão utilizadas para caracterizar a variabilidade do teor de fósforo no solo.

Tabela 5. Variância das EOFs para Teor de fósforo.

EOF	Variância	%	% acumulada
<b>1</b>	<b>15,72</b>	<b>25</b>	<b>25</b>
<b>2</b>	<b>10,72</b>	<b>17</b>	<b>42</b>
<b>3</b>	<b>9,55</b>	<b>15</b>	<b>57</b>
<b>4</b>	<b>7,84</b>	<b>13</b>	<b>70</b>
⋮	⋮	⋮	⋮
101	2,81E <sup>-16</sup>	4,46E <sup>-16</sup>	100
Soma	62,96	100	-

Fonte: Os Autores (2024).

A análise da Tabela 6 mostra que os anos com maior contribuição para explicar os padrões de variabilidade do pH são os seguintes: para o EOF-1, o ano de 2010 e 2021 se destacaram. No EOF-2, o ano de 2019 foi o mais influente. Para o EOF-3, o ano de 2014 foi o mais relevante. No caso do EOF-4, os anos de 2015 e 2016 foram os mais influentes.

Tabela 6. Proporção da importância de cada ano para explicação dos padrões de variabilidade para o teor de fósforo de cada EOF selecionada. Em vermelho se destacam os maiores coeficientes.

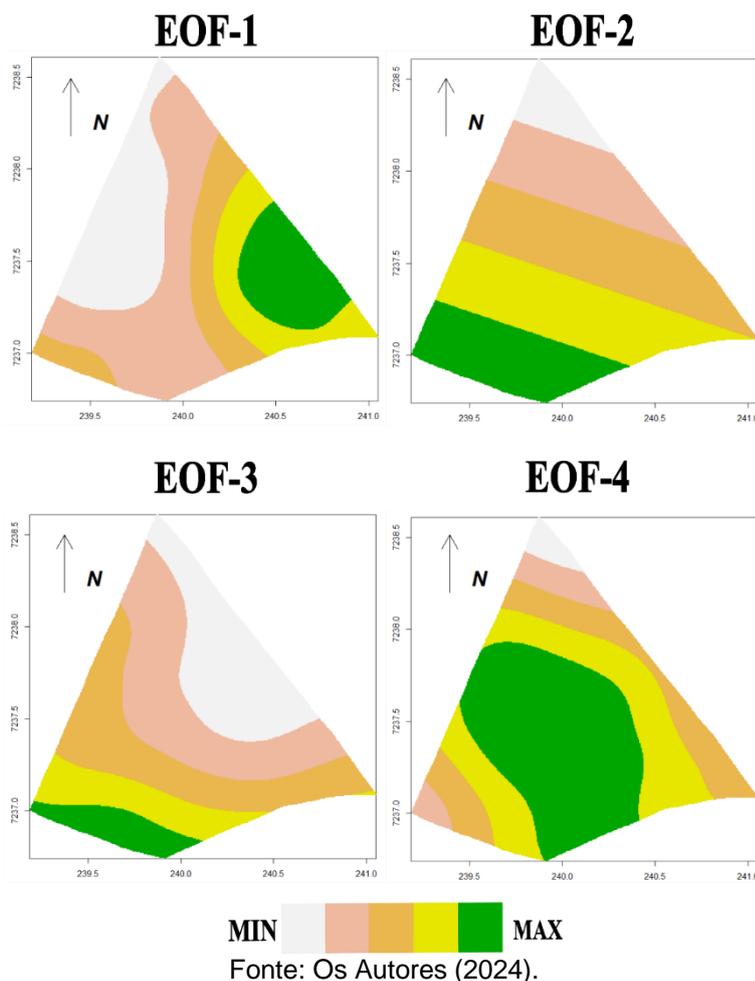
ANOS	EOF-1	PROP	EOF-2	PROP	EOF-3	PROP	EOF-4	PROP
2010	20,81	<b>0,70</b>	1,81	0,06	-4,20	0,05	1,75	0,07
2012	0,92	0,03	0,05	0,00	-2,97	0,00	5,02	0,20
2013	15,76	0,53	11,65	0,37	3,84	0,03	8,32	0,10
2014	-1,75	0,06	-3,04	0,10	28,57	<b>1,00</b>	4,52	0,18
2015	-7,22	0,24	8,37	0,27	-10,36	0,29	-24,51	<b>0,98</b>
2016	-0,59	0,02	3,32	0,11	-10,27	0,29	25,40	<b>1,00</b>
2019	1,74	0,05	<b>-31,10</b>	<b>1,00</b>	-6,36	0,13	-7,89	0,31
2021	-29,68	<b>1,00</b>	-0,50	0,01	-6,29	0,13	-5,98	0,24
2022	0,01	0,00	9,44	0,30	8,05	0,20	-6,62	0,26

Fonte: Os Autores (2024).

O mapa da EOF-1 (Figura 8) identifica padrões de variabilidade seguindo uma tendência de leste a oeste com duas áreas principais de variabilidade, sendo uma no sudeste e outra no oeste do mapa. Observa-se que para o ano de 2021 o sinal negativo do coeficiente (Tabela 6 e Eq. 15, em negrito) indica uma relação inversa com o padrão espacial desse mapa, sugerindo que a partir desse ano, há uma tendência de diminuição da concentração do teor de fósforo no solo, especialmente na região sudeste do mapa, e um aumento na parte oeste. Para 2010, o sinal do coeficiente é positivo (Tabela 6 e Eq. 15, em negrito), indicando uma relação direta com o mapa para EOF-1 (Figura 8) descrevendo um aumento na concentração do teor de fósforo no solo no sentido oeste-leste.

Os EOFs 2, 3 e 4 representam frações menores da variabilidade observada, descrevendo efeitos secundários na área estudada. No entanto, esses efeitos são importantes para o entendimento dos fenômenos que ocorrem nessa região. A EOF-2 (Figura 8) destaca também um padrão de variabilidade com tendência direcional no sentido nordeste-sudoeste. O ano de 2019, com coeficiente -31,10 (Tabela 6 e Eq. 16, em negrito) é o que melhor descreve a variação nordeste-sudoeste desse atributo químico apresentada nesse mapa, como o coeficiente é negativo indica que concentrações mais altas para o teor de fósforo no solo são vistas na região nordeste e mais baixas para a região sudoeste.

Figura 8. Mapa das quatro primeiras EOFs do teor de fósforo no solo, considerando todos os anos-safra entre os anos de 2010 e 2022.



A EOF-3 caracteriza-se pela variabilidade na região nordeste do mapa, o ano que mais contribuiu para esse padrão foi 2014 (Figura 8), com coeficiente de 28,57 (Eq. 17, em negrito). O ano de 2014 apresenta baixos valores do teor de fósforo no solo nessa região.

A EOF-4 mostra como característica principal as diferenças nas concentrações de teor de fósforo no solo predominantemente na região central do mapa. Os anos de 2016 e 2015 foram os que mais influenciaram no padrão de distribuição espacial descrita pelo EOF-4 (Figura 8) com coeficientes 25,40 e -24,51 respectivamente (Eq. 18, em negrito), evidenciando um contraste entre esses dois anos sucessivos. Em resumo, essa EOF demonstra o aumento que houve no teor de fósforo de 2015 para 2016, principalmente uma extensão de áreas centrais na área agrícola com um aumento dos valores do teor de fósforo (Figura 9).

$$\text{EOF} - 1_p = 20,81P_{2010} + 0,92P_{2012} + 15,76P_{2013} - 1,75P_{2014} - 7,22P_{2015} - 0,59P_{2016} + 1,74P_{2019} - 29,68P_{2021} + 0,01P_{2022} \quad (15)$$

$$\text{EOF} - 2_p = 1,81P_{2010} + 0,05P_{2012} + 11,65P_{2013} - 3,04P_{2014} + 8,37P_{2015} + 3,32P_{2016} - 31,10P_{2019} - 0,50P_{2021} + 9,44P_{2022} \quad (16)$$

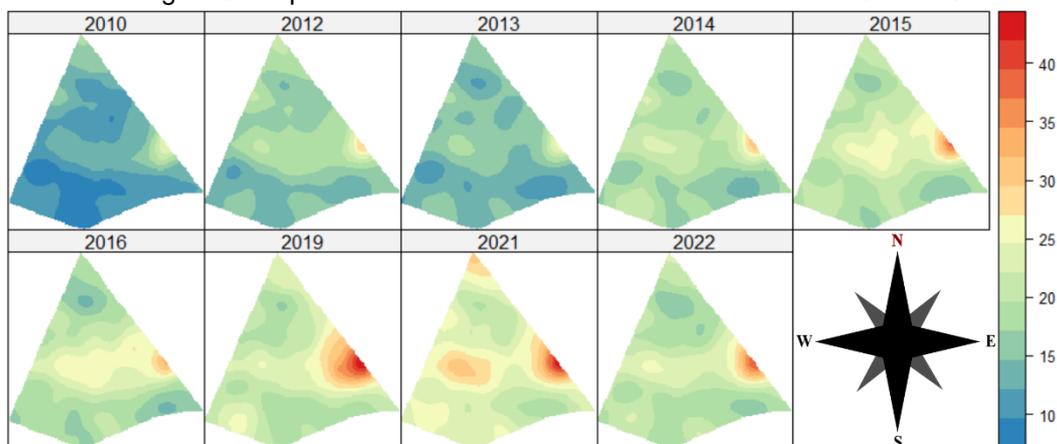
$$\text{EOF} - 3_p = -4,20P_{2010} - 2,97P_{2012} + 3,84P_{2013} + 28,57P_{2014} - 10,36P_{2015} - 10,27P_{2016} - 6,36P_{2019} - 6,29P_{2021} + 8,05P_{2022} \quad (17)$$

$$\text{EOF} - 4_p = 1,75P_{2010} + 5,02P_{2012} + 8,32P_{2013} + 4,52P_{2014} - 24,51P_{2015} + 25,40P_{2016} - 7,89P_{2019} - 5,98P_{2021} - 6,62P_{2022} \quad (18)$$

Todos esses resultados também podem ser visualizados nos mapas temáticos gerados para esses anos (Figura 9). O padrão para a EOF-1 que caracteriza principalmente o aumento da variação do teor de fósforo no solo na região sudeste pode ser visto nesses mapas temáticos nos quais o mapa para o ano de 2010 apresenta o início do aumento na concentração do teor de fósforo na região sudeste, esse aumento continua até o ano de 2021 onde atinge seu ápice e a partir do qual começa a diminuir.

Entretanto algumas características em relação aos padrões de variabilidade não são tão simples de se observar, como a tendência direcional descrita pela EOF-2. Nesse contexto, a técnica EOF foi muito útil ao revelar padrões que não são tão óbvios. Outro exemplo é a diminuição da concentração do teor de fósforo a partir de 2021 apontada pela EOF-1, que não é facilmente percebido, por ser uma mudança sutil, entretanto, foi precisamente apontada por essa técnica.

Figura 9. Mapa do teor de fósforo no solo entre os anos de 2010 e 2022.



Fonte: Os Autores (2024).

A análise dos espectros de potência para o teor de fósforo no solo (Figura 10A) mostra a presença de pequenos picos dispersos em diferentes frequências no

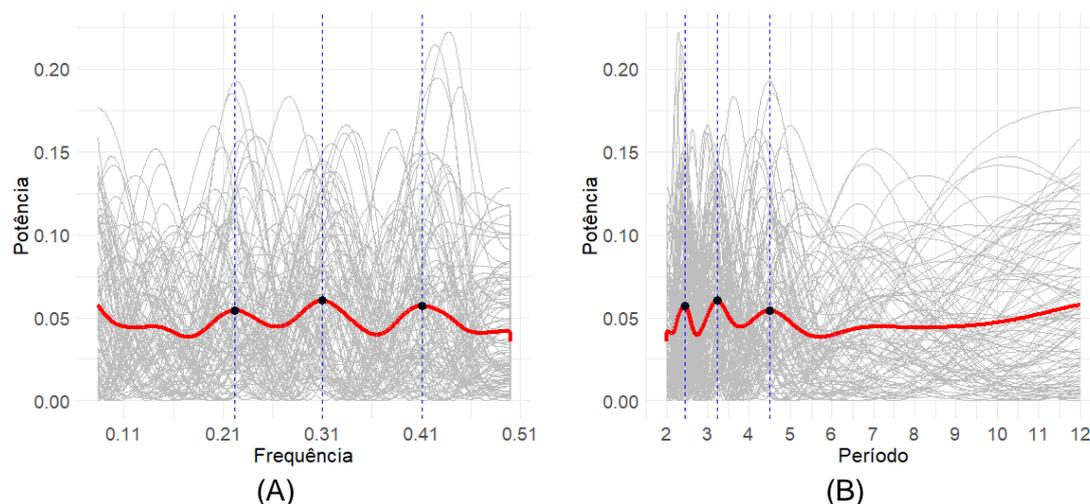
espectro médio. Esses picos indicam variações que podem estar relacionadas a fenômenos que afetam a variabilidade do teor de fósforo, porém de forma pontual e com baixa intensidade. Picos em um espectro de potência representam a presença de ciclos ou oscilações em uma determinada frequência, mas, nesse caso, eles são pequenos e espalhados, sugerindo que os fenômenos subjacentes têm pouca influência significativa sobre a variabilidade espacial total.

É possível que essas variações sejam causadas por flutuações aleatórias ou ruídos. Devido à baixa magnitude desses picos, os efeitos sazonais são difíceis de visualizar nos mapas temáticos (Figura 9), uma vez que esses fenômenos pontuais não exercem grande influência na caracterização geral dos mapas desse atributo químico.

Cabe salientar, porém, a grande dispersão entre o espectro médio e os espectros individuais (em cinza), nos quais é possível ver picos mais proeminentes, indicando um efeito mais expressivos em alguns pontos específicos dessa área de estudo, ou seja, pode haver algumas pequenas regiões que são afetadas por eventos sazonais de forma mais contundente do que outras, o que contribui para a variabilidade espacial. A Figura 10 B mostra que os picos mais altos estão presente em períodos mais curtos, ou seja, são fenômenos que ocorrem em curto período de 2,5, 3,5 e 4,5 anos aproximadamente. Essas mudanças, embora localizadas, acontecem em áreas com alterações mais frequentes durante o período analisado. Comparando com o mapa da Figura 9, é possível identificar áreas nas regiões central e norte do mapa que apresentam essas características.

Uma possível causa pode ser o manejo do solo incluindo a aplicação de fertilizantes e resíduos orgânicos (Sun *et al.*, 2021). Outra possível causa pode ser eventos climáticos periódicos que afetam essas culturas e por sua vez o consumo do teor de fósforo no solo (Angert *et al.*, 2011; Yu *et al.*, 2016).

Figura 10. Espectros de potência para o teor de fósforo no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes.



Fonte: Os Autores (2024).

As análises EOFs para o teor de fósforo no solo mostraram diferentes padrões de variabilidade agindo na área de estudo. Essas análises indicam que diferentes anos contribuíram de maneira variada para esses padrões. O comportamento espacial e temporal do teor de fósforo (P) no solo é amplamente influenciado por diferentes causas como práticas agrícolas, tipos de solo, eventos climáticos e uso de fertilizantes (Lemerrier *et al.*, 2008; Nze Memiaghe *et al.*, 2020).

#### 5.2.3.4 Teor de Matéria Orgânica

A primeira EOF explica 51% da variância total dos dados. A segunda EOF representa 12% da variância total, acumulando 63% quando somada à primeira. A terceira EOF representa 10% da variância total, resultando em 73% da variância acumulada (Tabela 7). Assim essas três primeiras EOF foram selecionadas para a análise da variabilidade espaço-temporal do teor da matéria orgânica no solo.

Tabela 7. Variância das EOFs para teor de Matéria Orgânica.

EOF	Variância	%	% acumulada
<b>1</b>	<b>35</b>	<b>51</b>	<b>51</b>
<b>2</b>	<b>8</b>	<b>12</b>	<b>63</b>
<b>3</b>	<b>7</b>	<b>10</b>	<b>73</b>
4	6	8	81
⋮	⋮	⋮	⋮
101	7,00E <sup>-16</sup>	1,02E <sup>-15</sup>	100
Soma	68,46	100	-

Fonte: Os Autores (2024).

Os anos que mais contribuíram para a variabilidade são: para o EOF-1, 2016 e 2022; para o EOF-2, 2016 e 2019; e para o EOF-3, 2010 e 2022 (Tabela 8). Esses anos destacam-se por terem as contribuições mais relevantes na variabilidade do teor de matéria orgânica conforme os mapas de EOF.

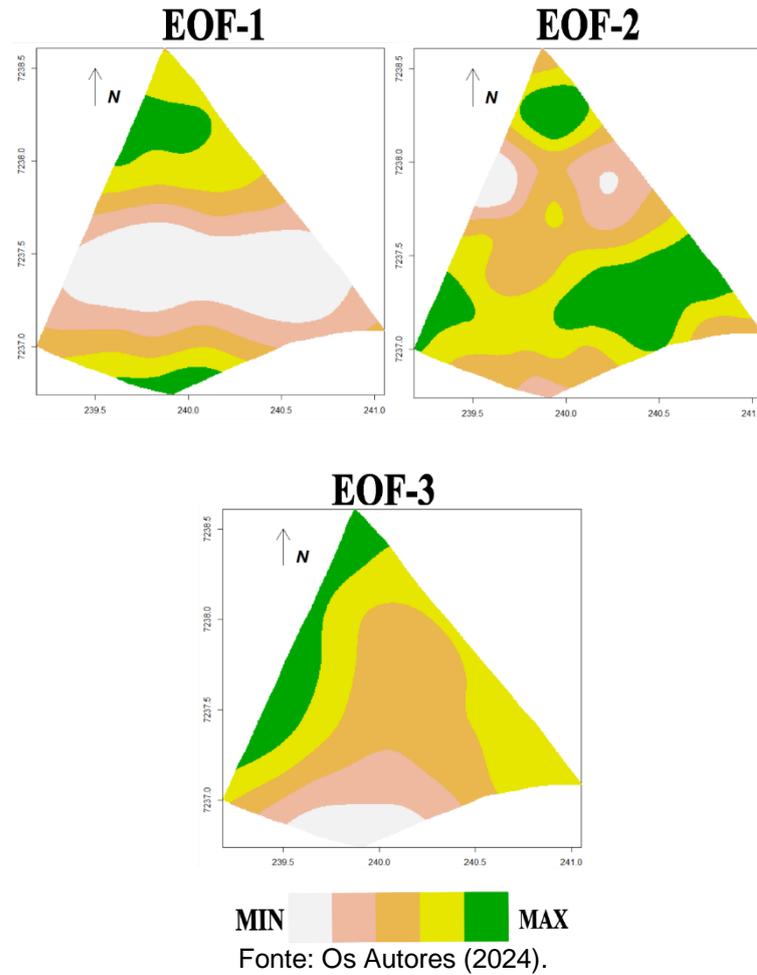
Tabela 8. Proporção da importância de cada ano para explicação dos padrões de variabilidade para o teor de matéria orgânica de cada EOF selecionada. Em vermelho se destacam os maiores coeficientes.

ANOS	EOF-1	PROP	EOF-2	PROP	EOF-3	PROP
2010	8,42	0,39	2,77	0,16	13,72	<b>0,97</b>
2012	-7,98	0,36	7,21	0,43	-5,44	0,20
2013	-6,00	0,26	-6,41	0,38	-6,15	0,26
2014	1,16	0,00	1,49	0,09	-10,06	0,63
2015	-7,74	0,36	-0,05	0,00	-3,32	0,00
2016	19,76	<b>1,00</b>	-16,79	<b>1,00</b>	-3,42	0,01
2019	5,57	0,24	11,97	<b>0,71</b>	6,91	0,33
2021	1,12	0,00	5,30	0,31	-6,31	0,28
2022	-14,31	<b>0,71</b>	-4,49	0,32	14,07	<b>1,00</b>

Fonte: Os Autores (2024).

Os mapas espaciais das diferentes EOFs (Figura 11) mostram os padrões de variabilidade do teor de matéria orgânica no solo. O primeiro mapa (EOF-1) caracteriza padrões de variabilidade principalmente na região central do mapa. Os anos de 2016, no qual 2022 apresentou um coeficiente positivo (Tabela 8 e Eq 19, em negrito), o que indica concentrações de valores mais baixos na região central e mais altos nos extremos norte e sul do mapa. Para o ano de 2022, no qual o coeficiente é negativo (Tabela 8 e Eq 19, em negrito), ocorreu comportamento inverso, ou seja, os valores mais altos se concentram na parte central do mapa e os mais baixos nos extremos norte e sul do mapa.

Figura 11 - Mapa dos três primeiros EOFs do teor de matéria orgânica no solo, considerando todos os anos-safra entre os anos de 2010 e 2022.



O mapa para a EOF-2 (Figura 11) caracteriza a variabilidade na região centro sul e norte do mapa. Os anos que melhor descrevem esse padrão foram 2016 e 2019, com coeficientes -16,79 e 11,97 respectivamente (Tabela 8 e Eq. 20, em negrito). Assim 2016 descreve concentrações mais baixas nos teores de matéria orgânica nessa região, enquanto 2019 se caracteriza por concentrações mais altas nessas mesmas regiões.

$$\text{EOF} - 1_{\text{MO}} = 8,42\text{MO}_{2010} - 7,98\text{MO}_{2012} - 6,00\text{MO}_{2013} + 1,16\text{MO}_{2014} - 7,74\text{MO}_{2015} + \mathbf{19,76\text{MO}_{2016}} + 5,57\text{MO}_{2019} + 1,12\text{MO}_{2021} - \mathbf{14,31\text{MO}_{2022}} \quad (19)$$

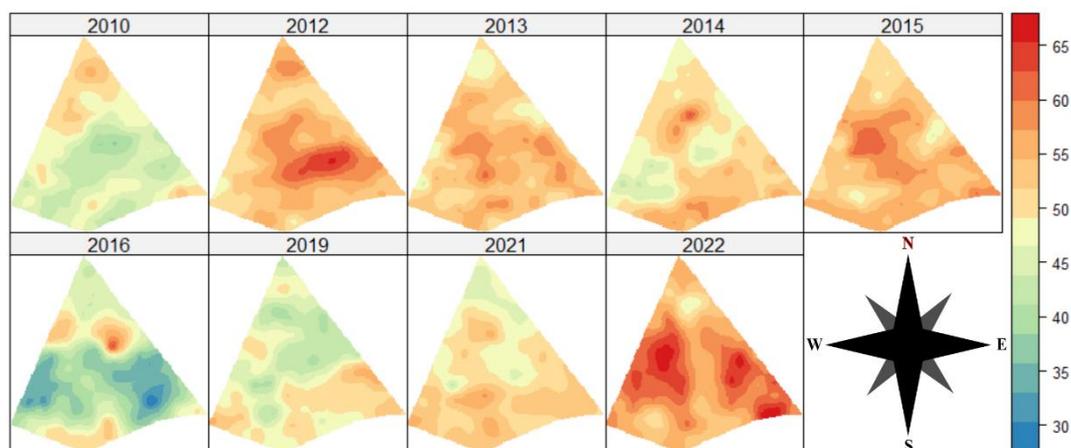
$$\text{EOF} - 2_{\text{MO}} = 2,77\text{MO}_{2010} + 7,21\text{MO}_{2012} - 6,41\text{MO}_{2013} + 1,49\text{MO}_{2014} - 0,05\text{MO}_{2015} - \mathbf{16,79\text{MO}_{2016}} + \mathbf{11,97\text{MO}_{2019}} + 5,30\text{MO}_{2021} - 4,49\text{MO}_{2022} \quad (20)$$

$$\text{EOF} - 3_{\text{MO}} = \mathbf{13,72\text{MO}_{2010}} - 5,44\text{MO}_{2012} - 6,15\text{MO}_{2013} - 10,06\text{MO}_{2014} - 3,32\text{MO}_{2015} - 3,42\text{MO}_{2016} + 6,91\text{MO}_{2019} - 6,31\text{MO}_{2021} + \mathbf{14,07\text{MO}_{2022}} \quad (21)$$

O mapa para EOF-3 descreve um padrão de variação norte-sul (Figura 11). Os anos de 2022 e 2010 que melhor caracterizaram a variabilidade para essa EOF, possuem coeficientes positivos 14,07 e 13,72 respectivamente (Tabela 8 e Eq. 21, em negrito), ou seja, possuem relação direto com o mapa para a EOF-3, portanto, concentrações do teor de matéria orgânica no solo mais baixas ao sul e mais altas no noroeste do mapa.

Esses resultados são confirmados quando se observa os mapas temáticos para o teor de matéria orgânica no solo para os diferentes anos de estudo (Figura 12). Verifica-se concentrações baixas do teor de matéria orgânica no solo na região central e alta no norte para o ano 2016 e o contrário para o ano de 2022 conforme descrito pela EOF-1. As características descritas para EOF-2 e EOF-3 também são bem evidentes nos mapas temáticos, entretanto, cabe ressaltar, que esses padrões seriam difíceis de se identificar somente olhando esses mapas e os padrões apontados pelas EOFs foram essenciais para identificar esses fatores como as principais causas da variabilidade para esse atributo químico nessa área de estudo.

Figura 12. Mapa do teor de matéria orgânica do solo entre os anos de 2010 e 2022.



Fonte: Os Autores (2024).

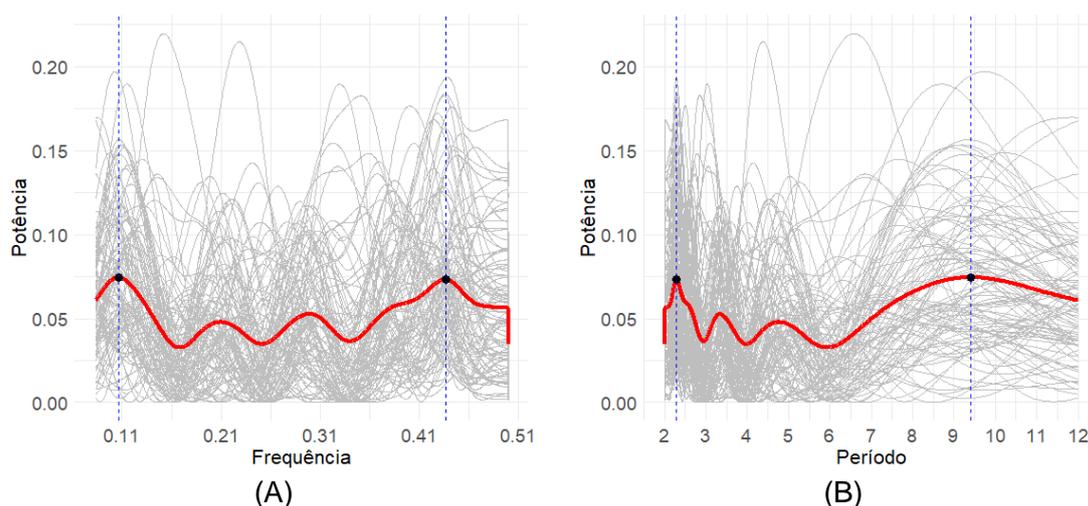
Na Figura 13A, observa-se que o espectro médio apresenta picos de potência em torno das frequências 0,1 e 0,45. Esses picos indicam que há uma concentração de variabilidade nessas frequências, sugerindo a presença de ciclos importantes nas séries temporais correspondentes a essas frequências. Na Figura 13B vemos os períodos que esses ciclos se repetem, no qual, os dois picos principais indicam que os eventos causadores desses ciclos acontecem a cada 2,5 e 9,5 anos. Esses picos

nos espectros de potência indicam os principais ciclos de variação no teor de matéria orgânica no solo ao longo do tempo, refletindo a periodicidade desses eventos.

A análise dos espectros individuais demonstra variação entre os diferentes pontos analisados, indicando que os fenômenos na área estudada apresentam comportamentos distintos em função da localização. Quando comparados com o mapa temático de concentração do atributo químico ao longo dos anos, observa-se que algumas regiões apresentam altas concentrações entre 2012 e 2022 (principalmente regiões central e sudeste), enquanto outras exibem baixas concentrações entre 2010 e 2019 (principalmente regiões norte e sudoeste).

Esses padrões podem estar associados a eventos sazonais de aproximadamente 9,5 anos, conforme indicado pelo espectro de potência. Além disso, a concentração reduzida desse atributo na região sudeste da área nos anos de 2014, 2016 e 2019 pode estar relacionada a ciclos de cerca de 2,5 anos, conforme sugerido pelos resultados da análise espectral. Dessa forma, os espectros de potência indicam a influência de ciclos temporais diferenciados que afetam a distribuição espacial do atributo químico analisado.

Figura 13. Espectros de potência para o teor de matéria orgânica no solo. A) em relação a frequência; B) em relação ao período. A linha vermelha representa o espectro médio. As linhas em cinza representam os espectros individuais de cada ponto amostral. A linha tracejada azul indica os picos mais proeminentes.



Fonte: Os Autores (2024).

Os padrões de variabilidade apontadas pelas EOFs podem ter várias causas. De acordo com Hu *et al.* (2018) tanto fatores naturais, como clima e topografia, quanto atividades humanas, como uso da terra e adubação, afetam a distribuição espacial do teor de matéria orgânica do solo. Conforme Liu *et al.* (2020), a variação no teor de

matéria orgânica do solo pode estar diretamente relacionada a fatores antropogênicos, tais como o uso da terra pelos agricultores e suas práticas, incluindo a aplicação de fertilizantes químicos e orgânicos, além dos tipos de culturas implantadas. De acordo com Shi *et al.* (2019), atividades humanas dinâmicas em períodos curtos, como uso da terra, adubação, preparo do solo e sistemas de cultivo, têm um impacto significativo na dinâmica do teor de matéria orgânica do solo.

#### 7.2.3.5 Análise geral

A análise geral dos resultados apresentados em relação aos diferentes atributos químicos do solo entre os anos de 2010 e 2022 revela algumas informações importantes. As análises das EOFs foram essenciais para entender a variabilidade espacial e temporal desses atributos. As primeiras EOFs geralmente explicam uma grande parte da variância total dos dados, capturando os principais padrões de variação. No caso do teor de cálcio, as duas primeiras EOFs foram suficientes para explicar mais de 70% da variância total, enquanto para o teor de matéria orgânica e o pH, foram necessárias três EOFs para isso. Já o teor de fósforo, foram necessárias quatro EOFs.

A necessidade de apenas dois modos para explicar os padrões de variabilidade do teor de cálcio indica uma distribuição mais simples e menos variável em comparação com outros atributos. Isso sugere que os fatores que afetam a distribuição do teor de cálcio no solo são mais uniformes ou seguem um padrão mais simples. Por outro lado, a necessidade de quatro modos para explicar a variabilidade do teor de fósforo indica uma distribuição espacial e temporal mais complexa. Isso indica que a variabilidade do teor de fósforo é influenciada por múltiplos fatores e não pode ser representada adequadamente por poucos padrões simples.

No geral os mapas das EOFs revelam padrões de variabilidade distintos para cada atributo químico. Os mapas das EOF-1 destacaram os principais padrões de variação para esses atributos, sem que: para o teor de cálcio, foram evidenciadas diferenças entre a região central e os extremos do mapa; para o pH, observaram-se distinções entre as extremidades norte e sudeste em comparação com a região central; para o teor de fósforo, foram caracterizadas variações de leste a oeste; e para o teor de matéria orgânica, foram evidenciados padrões de variabilidade na região central.

Os mapas das outras EOFs destacam características secundárias importantes principalmente em relação a variações no eixo norte-sul destacando tendências direcionais como características secundárias em todos os atributos analisados.

Os anos que mais influenciaram os padrões de variabilidade dos atributos químicos do solo foram 2010, 2016, 2021 e 2022. O ano de 2010 foi importante para pH (EOF-3), teor de fósforo (EOF-1) e o teor de matéria orgânica (EOF-3). O ano de 2016 influenciou o teor de cálcio (EOF-1), teor de fósforo (EOF-4) e o teor de matéria orgânica (EOF-1 e EOF-2). O ano de 2021 foi marcante para o teor de cálcio (EOF-1 e EOF-2), pH (EOF-2) e teor de fósforo (EOF-1). Já 2022 foi importante para o teor de cálcio (EOF-1 e EOF-2), pH (EOF-1) e o teor de matéria orgânica (EOF-1 e EOF-3).

Esses anos foram cruciais para identificar os padrões de variação espacial e temporal nos dados e refletem eventos que ocorreram nesses anos que influenciaram na variabilidade espaço-temporal desses atributos químicos do solo. eventos que podem estar associados a práticas agrícolas ou fenômenos climáticos ocorridos nesses anos, pois tanto a gestão agrícola quanto os fatores ambientais influenciam a variabilidade espacial e temporal (Kayad *et al.*, 2021).

As análises dos espectros de potência foram importantes para revelar alguns padrões sazonais que podem estar influenciando na variabilidade espaço-temporal. Para o teor de cálcio, os principais picos de frequência indicaram ciclos de dez e cinco anos, podendo estar relacionados a práticas agrícolas e variações climáticas.

O teor de matéria orgânica apresentou picos de potência em torno de dois e dez anos, refletindo eventos cíclicos que afetam sua variabilidade. O pH mostrou um grande pico de potência em baixas frequências e longos períodos, sugerindo variações de longo prazo, provavelmente, devido à capacidade tampão do solo e à aplicação de corretivos. O teor de fósforo exibiu pequenos picos espalhados por todas as frequências, indicando a presença de fenômenos variados atuando no campo.

Os espectros individuais, caracterizados pelas séries temporais de cada ponto amostral, apresentaram grande dispersão em relação ao espectro médio em todos os atributos químicos, evidenciando diferenças entre os diferentes espectros e, assim, efeitos variados em diferentes pontos da área de estudo, resultando em variações localizadas. Esses padrões cíclicos e as variações locais contribuem para a compreensão da dinâmica temporal e espacial dos atributos químicos do solo.

#### 5.2.4 Conclusão

A análise da variabilidade dos atributos químicos do solo por meio das EOFs revelou padrões importantes de variação espacial e temporal, influenciados por diferentes fatores. Essa técnica associada a análise dos espectros de potência da LSDFT permitiu identificar e caracterizar padrões que afetam a variabilidade dos atributos químicos do solo que de outra forma poderia ser mais difícil de ser detectada.

Os resultados mostraram que a distribuição espacial e temporal do teor de cálcio foi a mais simples, sendo bem representada por apenas duas EOFs. Em contraste, a variabilidade do teor de fósforo é mais complexa, necessitando de quatro EOFs para uma representação adequada.

Essa diferença sugere que a distribuição do teor de cálcio é influenciada por fatores mais uniformes ou segue padrões menos complexos, enquanto o teor de fósforo é afetado por uma gama mais ampla de fatores. Além disso, os anos que mais influenciaram os padrões de variabilidade foram 2010, 2016, 2021 e 2022, indicando que eventos naturais ou manejo do solo podem ter ocorrido nesses anos, influenciando a distribuição espacial e temporal desses atributos químicos.

Ressalta-se também que a análise dos espectros de potência revelou a existência de padrões sazonais na variabilidade dos atributos químicos do solo, apresentando principalmente picos em frequências baixas indica eventos sazonais ocorrendo em períodos longos, sendo mais evidentes no teor de cálcio no solo e no pH, possivelmente decorrentes de manejo do solo, como aplicação de calcário para correção da acidez.

A aplicação das técnicas de EOFs e LSDFT mostrou-se eficaz para lidar com dados irregulares e oferecer uma análise detalhada dos padrões de variabilidade. Essas informações são valiosas para que os produtores possam tomar decisões e desenvolver estratégias de manejo agrícola baseadas em dados mais precisos, especialmente na aplicação de insumos como fertilizantes e corretivos, em locais e momentos estratégicos, melhorando a produtividade e o uso sustentável do solo.

De modo geral, os objetivos propostos foram atingidos, pois as EOFs permitiram a decomposição dos dados e a identificação dos principais padrões de variabilidade, enquanto a LSDFT mostrou-se adequada para tratar a irregularidade temporal das amostras. Dessa forma, o estudo identificou padrões sazonais e espaciais relevantes na variabilidade dos atributos químicos do solo. A aplicação conjunta das EOFs e LSDFT em dados temporais irregulares, no contexto da

agricultura, representa uma contribuição metodológica inédita, especialmente ao investigar a variabilidade espaço-temporal em uma área produtora de soja, o que reforça sua relevância para o campo da agricultura de precisão.

**Agradecimentos:** Agradecimentos ao apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior- CAPES, código de financiamento 001, CNPq e Laboratórios de Estatística Aplicada (LEA) e de Estatística Espacial (LEE), UNIOESTE.

### Referências

ANGERT, A.; WEINER, T.; MAZEH, S.; TAMBURINI, F.; FROSSARD, E.; BERNASCONI, S.M., *et al.* Seasonal variability of soil phosphate stable oxygen isotopes in rainfall manipulation experiments. **Geochimica et Cosmochimica Acta**, v. 75, n. 15, p. 4216-4227, 2011.

APARECIDO, L.E.O.; ROLIM, G.S.; RICHETTI, J.; SOUZA, P.S.; JOHANN, J.A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, p. 405-417. <https://doi.org/10.1590/1413-70542016404003916>, 2016.

CASTRIGNANÒ, A.; BUTTAFUOCO, G.; KHOSLA, R.; MOUAZEN, A.; MOSHOU, D.; NAUD, O., editores. Agricultural internet of things and decision support for precision smart farming. **Academic Press**, 2020.

CRESSIE, N.; WIKLE, C.K. Statistics for spatio-temporal data. **John Wiley & Sons**, 2015.

DELSOLE, T.; TIPPETT, M. Statistical methods for climate scientists. **Cambridge University Press**, 2022.

DUPUIS, C.; SCHUMACHER, C. Using Lomb–Scargle analysis to derive empirical orthogonal functions from gappy meteorological data. **Journal of Applied Meteorology and Climatology**, v. 57, n. 10, p. 2217-2229, 2018.

FERRAZ, G.; BARBOSA, B.; REYNALDO, É.; SANTOS, S.; GONÇALVES, J.;

FERRAZ, P. Variabilidade espacial del pH del suelo muestreado por dos metodologías utilizadas en agricultura de precisión en granjas bajo rotación de cultivos. **DYNA**, v. 86, n. 209, p. 289-297. <https://doi.org/10.15446/dyna.v86n209.70897>, 2019.

FINKENSTADT, B.; HELD, L.; ISHAM, V. Statistical methods for spatio-temporal systems. Chapman and Hall/**CRC**, 2006.

FURTADO, D. Análise multivariada. Lavras: Editora da UFLA, 1996.

GOMES, A.D.; DOS SANTOS, P.H.L.; DO NASCIMENTO, J.M.; ARCOVERDE, S.N.S.; SECRETTI, M.L.; DA COSTA, E.G. Variabilidade Espacial De Atributos Químicos Do Solo E Produtividade Da Soja. **Anais da Academia Pernambucana de Ciência Agrônômica**, v. 18, n. 2, 2021.

HAN, T.; CAI, A.; LIU, K.; HUANG, J.; WANG, B.; LI, D., *et al.* The links between potassium availability and soil exchangeable calcium, magnesium, and aluminum are mediated by lime in acidic soil. **Journal of Soils and Sediments**, v. 19, p. 1382-1392, 2019.

HANNACHI, A.; JOLLIFFE, I.T.; STEPHENSON, D.B. Empirical orthogonal functions and related techniques in atmospheric science: A review. **International Journal of Climatology**, v. 27, n. 9, p. 1119-1152, 2007.

HU, P.L.; LIU, S.J.; YE, Y.Y.; ZHANG, W.; WANG, K.L.; SU, Y.R. Effects of environmental factors on soil organic carbon under natural or managed vegetation restoration. **Land Degradation and Development**, v. 29, n. 3, p. 387-397, 2018.

IBACACHE-PULGAR, G.; PACHECO, P.; NICOLIS, O.; URIBE-OPAZO, M.A. Local Influence for the Thin-Plate Spline Generalized Linear Model. **Axioms**, v. 13, n. 6, p. 346, 2024.

ISPIROVA, G.; EFTIMOV, T.; SELJAK, B.K. Evaluating missing value imputation methods for food composition databases. **Food and Chemical Toxicology**, v. 141, p. 111368, 2020.

LEMERCIER, B.; GAUDIN, L.; WALTER, C.; AUROUSSEAU, P.; ARROUAYS, D.; SCHVARTZ, C.; ABRASSART, J. Soil phosphorus monitoring at the regional level by means of a soil test database. *Soil Use and Management*, 24(2), 131-138. 2008.

LEUTHOLD, S.J.; LAVALLEE, J.M.; BASSO, B.; BRINTON, W.F.; COTRUFO, M.F. Shifts in controls and abundance of particulate and mineral-associated organic matter fractions among subfield yield stability zones. **SOIL**, v. 10, n. 1, p. 307-319, 2024.

LIU, H.; LI, S.; ZHOU, Y. Spatial-temporal variability of soil organic matter in urban fringe over 30 years: a case study in Northeast China. **International Journal of Environmental Research and Public Health**, v. 17, n. 1, p. 292, 2020.

KAYAD, A.; SOZZI, M.; GATTO, S.; WHELAN, B.; SARTORI, L.; MARINELLO, F. Ten years of corn yield dynamics at field scale under digital agriculture solutions: A case study from North Italy. **Computers and Electronics in Agriculture**, v. 185, p. 106126, 2021.

MALTAURO, T.C.; GUEDES, L.P.; URIBE-OPAZO, M.A.; CANTON, L.E. Multivariate spatial sample reduction of soil chemical attributes by means of application zones. **Spanish Journal of Agricultural Research**, v. 21, n. 2, p. e0205-e0205, 2023.

NASTIS, S.A.; MICHAILEDIS, A.; CHATZITHEODORIDIS, F. Climate change and agricultural productivity. **African Journal of Agricultural Research**, v. 7, n. 35, p. 4885-4893, 2012.

NAVARRA, A.; SIMONCINI, V. A guide to empirical orthogonal functions for climate data analysis. **Springer Science & Business Media**, 2010.

NEHA; PASARI, S. A review of empirical orthogonal function (EOF) with an emphasis on the co-seismic crustal deformation analysis. **Natural Hazards**, v. 110, n. 1, p. 29-56, 2022.

NZE MEMIAGHE, J.D.; CAMBOURIS, A.N.; ZIADI, N.; KARAM, A.; PERRON, I. Spatial variability of soil phosphorus indices under two contrasting grassland fields in Eastern Canada. **Agronomy**, v. 11, n. 1, p. 24, 2020.

OKOLIE, C.C.; DANSO-ABBEAM, G.; GROUPSON-PAUL, O.; OGUNDEJI, A.A. Climate-smart agriculture amidst climate change to enhance agricultural production: a bibliometric analysis. **Land**, v. 12, n. 1, p. 50, 2022.

PAHLAVAN-RAD, M.R.; AKBARIMOGHADDAM, A. Spatial variability of soil texture fractions and pH in a flood plain (case study from eastern Iran). **Catena**, v. 160, p. 275-281, 2018.

PIOTROWSKA-DŁUGOSZ, A.; LEMANOWICZ, J.; DŁUGOSZ, J.; SPYCHAJ-FABISIAK, E.; GOZDOWSKI, D.; RYBACKI, M. Spatio-temporal variations of soil properties in a plot scale: a case study of soil phosphorus forms and related enzymes. **Journal of Soils and Sediments**, v. 16, p. 62-76, 2016.

PRESS, W.H.; RYBICKI, G.B. Fast algorithm for spectral analysis of unevenly sampled data. **Astrophysical Journal**, v. 338, p. 277-280, 1989.

PYTHAROULI, S.I.; STIROS, S.C. Spectral analysis of unevenly spaced or discontinuous data using the "normperiod" code. **Computers and Structures**, v. 86, n. 1-2, p. 190-196, 2008.

RHEINHEIMER, D.S.; TIECHER, T.; GONZATTO, R.; ZAFAR, M.; BRUNETTO, G. Residual effect of surface-applied lime on soil acidity properties in a long-term experiment under no-till in a Southern Brazilian sandy Ultisol. **Geoderma**, v. 313, p. 7-16, 2018.

RIBEIRO, D.L.; MALTAURO, T.C.; GUEDES, L.P.C.; URIBE-OPAZO, M.A.; DALPOSSO, G.H. Directional Differences in Thematic Maps of Soil Chemical Attributes with Geometric Anisotropy. **Stats**, v. 7, n. 1, p. 65-78, 2024.

SANTOS HG, JACOMINE PKT, ANJOS LHC, OLIVEIRA VA, LUMBRERAS JF, COELHO MR, *et al.* Sistema brasileiro de classificação de solos. 5. ed. **rev. ampl.** Brasília, DF: Embrapa; 2018.

SCARGLE, J.D. Studies in astronomical time series analysis. III-Fourier transforms, autocorrelation functions, and cross-correlation functions of unevenly spaced data. **Astrophysical Journal**, v. 343, p. 874-887, 1989.

SEILMAYER, M.; GONZALEZ, F.G.; WONDRACK, T. The Multivariate Extension of the Lomb-Scargle Method. **arXiv preprint arXiv:2001.10200**, 2020.

ŞENTOP, M.S.; YÜCEL, M.; ÜSTÜNDAĞ, B.B. Spatio-Temporal Missing Data Reconstruction by Using Deep Neural Networks in Agricultural Monitoring Systems. In 2023 11th International Conference on Agro-Geoinformatics (Agro-Geoinformatics). **IEEE**, p. 1-6, 2023.

SHAHARUDIN, S.M.; AHMAD, N. Choice of cumulative percentage in principal component analysis for regionalization of peninsular Malaysia based on the rainfall amount. In: Modeling, Design and Simulation of Systems: 17th Asia Simulation Conference, AsiaSim 2017, Melaka, Malaysia, August 27–29, 2017, Proceedings, Part II 17. **Springer** Singapore, p. 216-224, 2017.

SHARMA, S. Precision Agriculture: Reviewing the Advancements Technologies and Applications in Precision Agriculture for Improved Crop Productivity and Resource Management. **Review of Food and Agriculture**, v. 4, n. 2, p. 45-49, 2023.

SHI, P.; ZHANG, Y.; LI, P.; LI, Z.; YU, K.; REN, Z., *et al.* Distribution of soil organic carbon impacted by land-use changes in a hilly watershed of the Loess Plateau, China. **Science of the Total Environment**, v. 652, p. 505-512, 2019.

SUN, Y.; GUO, W.; WEINDORF, D.C.; SUN, F.; DEB, S.; CAO, G., *et al.* Field-scale spatial variability of soil calcium in a semi-arid region: Implications for soil erosion and site-specific management. **Pedosphere**, v. 31, n. 5, p. 705-714, 2021.

TAKAMOTO, A.; TAKAHASHI, T.; NIRA, R. Soil chemical properties affecting soybean yield on a nationwide scale in Japan. **Soil Science and Plant Nutrition**, v. 66, n. 6, p. 900-905, 2020.

TANG, B. Digital frequency spectrum analysis based on discrete Fourier transform. In: International Conference on Network Communication and Information Security (ICNCIS 2022). **SPIE**, v. 12503, p. 114-126, 2022.

TOLOI, M.N.V.; BONILLA, S.H.; TOLOI, R.C.; SILVA, H.R.O.; NÄÄS, I.D.A. Development indicators and soybean production in Brazil. **Agriculture**, v. 11, n. 11, p. 1164, 2021.

URIBE-OPAZO, M. A.; DE BASTIANI, F.; GALEA, M.; SCHEMMER, R. C.; ASSUMPÇÃO, R. A. B. Influence diagnostics on a reparameterized t-Student spatial linear model. **Spatial Statistics**, 41, 100481. 2021.

WALKLEY, A.; BLACK, I.A. An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. **Soil Science**, v. 37, p. 29-38, 1934.

WHEELER, D.M. Temporal changes in some soil chemical properties at four depths following the surface application of lime. **New Zealand Journal of Agricultural Research**, v. 40, n. 2, p. 309-316, 1997.

WIKLE, C.K.; ZAMMIT-MANGION, A.; CRESSIE, N. Spatio-temporal statistics with R. Chapman and Hall/**CRC**, 2019.

XU, Z.; ZHANG, T.; WANG, S.; WANG, Z. Soil pH and C/N ratio determines spatial variations in soil microbial communities and enzymatic activities of the agricultural

ecosystems in Northeast China: Jilin Province case. **Applied Soil Ecology**, v. 155, p. 103629, 2020.

XIE, X.; QIU, J.; FENG, X.; HOU, Y.; WANG, S.; JIA, S., *et al.* Spatial Distribution and Estimation Model of Soil pH in Coastal Eastern China. **International Journal of Environmental Research and Public Health**, v. 19, n. 24, p. 16855, 2022.

YU, D.; XIE, P.; ZENG, C.; XIE, L.; CHEN, J. In situ enclosure experiments on the occurrence, development and decline of black bloom and the dynamics of its associated taste and odor compounds. **Ecological Engineering**, 87, 246-253. 2016.

ZHUO, Z.; XING, A.; LI, Y.; HUANG, Y.; NIE, C. Spatio-temporal variability and the factors influencing soil-available heavy metal micronutrients in different agricultural sub-catchments. **Sustainability**, 11(21), 5912. 2019.

ZHOU, Wei-Xing; SORNETTE, Didier. Statistical significance of periodicity and log-periodicity with heavy-tailed correlated noise. **International Journal of Modern Physics C**, v. 13, n. 02, p. 137-169, 2002.

## 6. CONSIDERAÇÕES FINAIS

Esta tese investigou a variabilidade espaço-temporal de atributos químicos do solo em uma área agrícola produtora de grãos, aplicando diferentes técnicas estatísticas. A pesquisa foi apresentada em dois artigos científicos que contribuíram para o entendimento do comportamento desses atributos químicos do solo.

Os resultados da pesquisa mostraram a importância da Geoestatística Espaço-temporal e das Funções Ortogonais Empíricas (EOFs), em conjunto com a Transformada de *Fourier de Lomb-Scargle* Discreta (LSDFT), para analisar a variabilidade espaço-temporal de atributos químicos do solo. Essas técnicas permitiram identificar padrões de variação complexos, oferecendo uma visão detalhada das influências espaciais e temporais sobre os atributos químicos do solo.

Os resultados revelaram a existência de dependência espacial e temporal nos atributos químicos do solo, com variações ao longo do espaço e do tempo. Esta informação é essencial para a gestão agrícola, pois possibilita intervenções mais precisas e eficazes, melhorando a aplicação de insumos (taxa variada) e reduzindo os impactos ambientais.

A pesquisa enfrentou algumas limitações, como por exemplo a coleta irregular de dados em determinados anos-safra. A falta de dados contínuos dificultou uma análise uniforme ao longo de todo o período de estudo. Recomenda-se que futuras pesquisas abordem essas limitações, utilizando diferentes técnicas que lidem de forma eficaz com dados irregulares.

As implicações práticas dos resultados desta tese são amplas. A capacidade de identificar padrões sazonais e espaciais na variabilidade dos atributos químicos do solo pode orientar práticas de manejo agrícola mais eficientes e sustentáveis. Além disso, as técnicas discutidas podem ser aplicadas em outras regiões e tipos de culturas, ampliando o alcance da pesquisa.

Em resumo, esta tese contribui para a agricultura de precisão ao demonstrar como diferentes técnicas estatísticas podem ser aplicadas para compreender a variabilidade espaço-temporal dos atributos químicos do solo. As descobertas fornecem uma base para a implementação de práticas agrícolas mais eficientes e sustentáveis, com benefícios potenciais para a produtividade agrícola e a saúde ambiental.

Para futuras investigações, sugere-se explorar outras técnicas estatísticas que possam complementar as abordagens utilizadas neste trabalho. Além disso,

correlacionar dados de atributos químicos do solo com mudanças climáticas, como variações na precipitação e temperatura, pode fornecer informações valiosas sobre os impactos climáticos na variabilidade desses atributos.

Outra abordagem é o emprego de técnicas de aprendizado de máquina para integrar dados de campo com dados de sensoriamento remoto, melhorando a previsão da variabilidade espaço-temporal dos atributos do solo. Outra estratégia é utilizar outros modelos geoestatísticos que considerem as interações entre espaço e tempo ou também novas metodologias para calcular a dependência espaço-temporal com base em parâmetros geoestatísticos. Por fim, relacionar a variabilidade espaço-temporal com dados de produtividade pode ajudar a entender como essa variabilidade afetou a produtividade da soja.

## REFERÊNCIAS

AIKES JR., J.; DE SOUZA, E. G.; BAZZI, C. L.; SOBJAK, R. Thematic Maps and Management Zones for Precision Agriculture: Systematic Literature Study, Protocols, and Practical Cases. Curitiba: Poncã, 2021.

APARECIDO, L.E.O.; ROLIM, G.S.; RICHETTI, J.; SOUZA, P.S.; JOHANN, J.A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, p. 405-417. <https://doi.org/10.1590/1413-70542016404003916>, 2016.

BALDWIN, M. P.; STEPHENSON, D. B.; JOLLIFFE, I. T. Spatial weighting and iterative projection methods for EOFs. **Journal of Climate**, v. 22, n. 2, p. 234-243, 2009.

BASSOI, L. H.; INAMASU, R. Y.; BERNARDI, A. C. DE C.; VAZ, C. M. P.; SPERANZA, E. A.; CRUVINEL, P. E. Agricultura de precisão e agricultura digital. **TECCOGS – Revista Digital de Tecnologias Cognitivas**, n. 20, p. 17-36, 2019.

BEVILACQUA, M.; MATEU, J.; PORCU, E.; ZHANG, H.; ZINI, A. Weighted composite likelihood-based tests for space-time separability of covariance functions. **Statistics and Computing**, v. 20, p. 283-293, 2010.

BERNARDI, A. C. C.; NAIDE, J. M.; RESENDE, A. V.; BOSSOI, L. H.; INAMASU, R. Y. Agricultura de precisão: resultados de um Novo olhar. Brasília: EMBRAPA, 2014. 600p.

BERNARDI, A. C. C.; BETTIOL, G. M.; GREGO, C. R.; ANDRADE, R. G.; RABELLO, L. M.; INAMASU, R. Y. Ferramentas de agricultura de precisão como auxílio ao manejo da fertilidade do solo. **Cadernos de Ciência e Tecnologia, Brasília**, v. 32, n. 1/2, p. 205-221, jan./ago. 2015.

BOTTEGA, E. L.; DE QUEIROZ, D. M.; PINTO, F. A. C.; DE SOUZA, C. M. A.; VALENTE, D. S. M. Precision agriculture applied to soybean: Part I-Delineation of management zones. *Australian Journal of Crop Science*, v. 11, p. 573-579, 2017.

BRAGA, R.; PINTO, P. A. Agricultura de precisão: adoção & principais obstáculos. *AGROTEC - Revista técnico-científica agrícola, Coimbra – PT*, n.1, p.84-89, dez. 2011.

CÂMARA, G.; MEDEIROS, J. S. GIS para meio ambiente. In: Sistema de informações geográficas, 1998, Curitiba. Anais... Curitiba: Sagres, 1998. p. 140-180.  
CAMPOS, Y.; SOSSA, H.; PAJARES, G. Spatio-temporal analysis for obstacle detection. In: agricultural videos. **Applied Soft Computing**, v. 45, p. 86-97, in: CAMARGO, E. C. G.; FUCKS, S. D.; CÂMARA, G. Análise espacial de superfícies. São José dos Campos: Instituto Nacional de Pesquisas Espaciais – **INPE**, 2004. 2016.

CANELLAS, L. P.; VELLOSO, A. C. X.; MARCIANO, C. R.; RAMALHO, J. F. G. P.; RUMJANEK, V. M.; RESENDE, C. E.; SANTOS, G. A. Propriedades químicas de um Cambissolo cultivado com cana-de-açúcar, com preservação do palhiço e adição de

vinhaça por longo tempo. **Revista Brasileira de Ciência do Solo**, v. 27, p. 935-944, 2003.

CHRISTAKOS, G. On certain classes of spatiotemporal random fields with applications to space-time data processing. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 21, p. 861-875, 1991.

CONSTANTINOU, P.; KOKOSZKA, P.; REIMHERR, M. Testing separability of space--time functional processes. **arXiv: Methodology**, 2015.

COSTA, D. M. C.; PAULETTO, D. Importância dos sistemas agroflorestais na composição de renda de agricultores familiares: estudo de caso no município de Belterra, Pará. **Nativa**, v. 9, n. 1, p. 92-99, 2021.

CRESSIE, N.; HUANG, H. Classes of nonseparable, spatio-temporal stationary covariance functions. **Journal of the American Statistical Association**, v. 94, n. 448, p. 1330-1339, 1999.

CRESSIE, N.; WIKLE, C. K. Statistics for spatio-temporal data. **John Wiley & Sons**, 2015.

DAL'CANTON, L. E.; MALTAURO, T. C.; GUEDES, L. P. C.; URIBE-OPAZO, M. A.; CIMA, E. G. Bivariate spatial correlation between soil attributes and soybean productivity in an agricultural area with Dystroferric Red Latosol. **Australian Journal of Crop Science**, v. 17, n. 1, p. 20-ii, 2023.

DALLA NORA, D.; AMADO, T. J. C.; ALBA, P.; BORTOLOTTI, R. P.; KELLER, C. Agricultura de precisão: variabilidade dos atributos químico-físicos do solo e relação com a produtividade do milho. **Revista Engenharia na Agricultura**, v. 21, n. 1, p. 59-68, 2013.

DE BASTIANI, F.; GALEA, M.; CYSNEIROS, A. H. M. A.; URIBE-OPAZO, M. A. Gaussian spatial linear models with repetitions: an application to soybean productivity. **Spatial Statistics**, v. 21, p. 319-335, 2017. DOI: 10.1016/j.spasta.2017.07.013.

DE CESARE, L.; MYERS, D. E.; POSA, D. FORTRAN programs for space-time modeling. **Computers e Geosciences**, v. 28, p. 205-212, 2002.

DE IACO, S.; MYERS, D. E.; POSA, D. Nonseparable space-time covariance models: some parametric families. **Mathematical Geology**, v. 34, p. 23-42, 2002. DOI: 10.1023/A:1014075310344.

DE IACO, S.; PALMA, M.; POSA, D. A general procedure for selecting a class of fully symmetric space-time covariance functions. **Environmetrics**, v. 26, p. 212-224, 2016. DOI: 10.1002/env.2392.

DEBNATH, S.; SINHA, M. Rotated empirical orthogonal function analysis for spatio-temporal data analysis. **Journal of Mechanics of Continua and Mathematical Sciences**, v. 17, n. 4, 2022.

DIACONO, M.; CASTRIGNANÒ, A.; TROCCOLI, A.; DE BENEDETTO, D.; BASSO, B.; RUBINO, P. Spatial and temporal variability of wheat grain yield and quality in a Mediterranean environment: A multivariate geostatistical approach. **Field Crops Research**, 131, 49-62. 2012.

DONALD, M.; MENGERSEN, K.; YOUNG, R. A four-dimensional spatio-temporal analysis of an agricultural dataset. **PLoS ONE**, v. 10, 2015.

DUPUIS, C.; SCHUMACHER, C. Using Lomb–Scargle analysis to derive empirical orthogonal functions from gappy meteorological data. **Journal of Applied Meteorology and Climatology**, v. 57, n. 10, p. 2217-2229, 2018.

FERREIRA, P. S.; GOMES, V. P.; SANTOS, A. M.; SOUZA, W. M.; GALVÍNCIO, J. D. Mudanças climáticas e a geopotencialidade à fruticultura em municípios de Pernambuco: subsídios à agricultura familiar. **Caderno de Geografia**, v. 26, n. 46, p. 522-544, 2016.

FINKENSTADT, B.; HELD, L.; ISHAM, V. Statistical methods for spatio-temporal systems. Chapman and Hall/**CRC**, 2006.

FUENTES, M. Testing for separability of spatial–temporal covariance functions. **Journal of Statistical Planning and Inference**, v. 136, p. 447-466, 2006.

GNEITING, T.; LARSON, K.; WESTRICK, K.; GENTON, M. G.; ALDRICH, E. Calibrated probabilistic forecasting at the Stateline wind energy centre: the regime-switching space-time (RST) method. **Journal of the American Statistical Association**, v. 101, p. 968-979, 2006.

GNEITING, T.; RAFTERY, A. E. Strictly proper scoring rules, prediction, and estimation. **Journal of the American Statistical Association**, v. 102, n. 477, p. 359-378, 2007.

GNEITING, T.; GENTON, M. G.; GUTTORP, P. Geostatistical space-time models, stationarity, separability, and full symmetry. In: FINKENSTADT, B.; HELD, L.; ISHAM, V. Statistical methods for spatio-temporal systems. Boca Raton: **Chapman e Hall/CRC**, p. 151-175, 2007.

GUEDES, L. P. C. Otimização de amostragem espacial. 2008. 143f. Tese de doutorado, Programa de Pós-Graduação em Estatística e Experimentação Agronômica, Universidade de São Paulo, Escola Superior de Agricultura “Luiz de Queiroz”, São Paulo, 2008.

GREGO, C. R.; SPERANZA, E. A.; RODRIGUES, G. C.; LUCHIARI JUNIOR, A.; VENDRUSCULO, L. G.; RODRIGUES, C. A. G.; INAMASU, R. Y.; VAZ, C. M. P.; RABELLO, L. M.; JORGE, L. A. de C.; ZOLIN, C. A.; FRANCHINI, J. C.; RONQUIM, C. C. (2020). Tecnologias desenvolvidas em Agricultura de Precisão. In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; OLIVEIRA, S. R. de M.; MEIRA, C. A. A.; LUCHIARI JUNIOR, A.; BOLFE, E. L. (Ed.). Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas. Brasília, DF: Embrapa, cap. 7, p. 166-191, 2020.

- HAUSCHILD, F. E. G.; FIORIN, J. E.; AMADO, T. J. C.; SANTI, A. L. Técnicas de agricultura de precisão para definição de zonas de manejo. Congresso Brasileiro de Agricultura de Precisão – ConBAP. Anais... São Pedro – SP, set. 2014.
- JAWSON, S. D.; NIEMANN, J. D. Spatial patterns from EOF analysis of soil moisture at a large scale and their dependence on soil, land-use, and topographic properties. **Advances in Water Resources**, 30(3), 366-381. 2007.
- JULEA, A.; MÉGER, N.; RIGOTTI, C.; TROUVÉ, E.; JOLIVET, R.; BOLON, P. Efficient spatio-temporal mining of satellite image time series for agricultural monitoring. **Transactions on Machine Learning and Data Mining**, v. 5, p. 23-44, 2012.
- KIM, S., DAUGHTRY, C., RUSS, A., PEDRERA-PARRILLA, A., & PACHEPSKY, Y. Analysis of spatiotemporal variability of corn yields using empirical orthogonal functions. **Water**, 12(12), 3339. 2020.
- KYRIAKIDIS, P. C.; JOURNEL, A. G. Geostatistical space-time models: a review. **Mathematical Geology**, v. 31, n. 6, p. 651-684, 1999.
- LORBIESKI, R.; GUEDES, L. P. C.; URIBE-OPAZO, M. A.; KESTRING, F. B. F. Regionalization of an agricultural area by means of multivariate data and their relationship with soybean productivity. **Australian Journal of Crop Science**, v. 17, n. 7, p. 570-580, 2023.
- LORENZ, E. N. **Empirical orthogonal functions and statistical weather prediction**. Cambridge: Massachusetts Institute of Technology, Department of Meteorology, 1956.
- MADDISON, D. A spatio-temporal model of farmland values. **Journal of Agricultural Economics**, v. 60, p. 171-189, 2009.
- MALTAURO, T. C.; GUEDES, L. P. C.; URIBE-OPAZO, M. A.; DAL'CANTON, L. E. Multivariate spatial sample reduction of soil chemical attributes by means of application zones. **Spanish Journal of Agricultural Research**, v. 21, n. 2, e0205-e0205, 2023.
- MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, p. 1246-1266, 1963.
- MOLIN, J. P. Definição de unidades de manejo a partir de mapas de produtividade. Revista da Sociedade Brasileira de Engenharia Agrícola, v. 22, n. 1, p. 83-92, 2002.
- MOLIN, J. P.; INAMASU, R. Y.; JUNTOLLI, F. V.; SANTOS, R. L. B. Agricultura de Precisão. Boletim técnico, Ministério da Agricultura, Pecuária e Abastecimento Secretaria de Desenvolvimento Agropecuário e Cooperativismo. 3.ed. Brasília, DF, 2013.
- MOLIN, J.P.; AMARAL, L.R.; COLAÇO, A. Agricultura de precisão. São Paulo: Oficina de Textos, 238p. 2015.

- MONTERO, J. M.; AVILÉS, G. F.; MATEU, J. Spatial and spatio-temporal geostatistical modelling and kriging. UK: **Wiley**, 2015.
- NDONGO, Ferdinand Bertrand. **Spatio-temporal processes for functional data with application in climate monitoring**. 2017. Tese de Doutorado. Ph. D. thesis, Università degli studi di Bergamo.
- NEHA; PASARI, S. A review of empirical orthogonal function (EOF) with an emphasis on the co-seismic crustal deformation analysis. **Natural Hazards**, v. 110, n. 1, p. 29-56, 2022.
- NIELSEN, D. R.; ALEMI, M. H. Statistical opportunities for analyzing spatial and temporal heterogeneity of field soils. **Plant and Soil**, v. 115, p. 285-296, 1989.
- ORTIZ, R. La adopción de la biotecnología moderna y su compatibilidad con una agricultura sustentable. **Idesia (Arica)**, v. 30, n. 3, p. 3-10, 2012.
- PEBESMA, E. J. Multivariable geostatistics in S: the gstat package. **Computers & Geosciences**, v. 30, n. 7, p. 683-691, 2004.
- PETITGAS, P.; DORAY, M.; HURET, M.; MASSÉ, J.; WOILLEZ, M. Modelling the variability in fish spatial distributions over time with empirical orthogonal functions: anchovy in the Bay of Biscay. **ICES Journal of Marine Science**, 71(9), 2379-2389. 2014.
- PORCU, E.; GREGORI, P.; MATEU, J. Nonseparable stationary anisotropic space-time covariance functions. *Stochastic Environmental Research and Risk Assessment*, v. 21, p. 113-122, 2006. DOI: 10.1007/s00477-006-0048-3.
- PORCU, E.; MATEU, J. Mixture-based modeling for space-time data. **Environmetrics**, v. 18, p. 285-302, 2007. DOI: 10.1002/env.832.
- PORCU, E.; MATEU, J.; CHRISTAKOS, G. Quasi-arithmetic means of covariance functions with potential applications to space-time data. **Journal of Multivariate Analysis**, v. 100, p. 1830-1844, 2009. DOI: 10.1016/j.jmva.2009.02.013.
- PYTHAROULI, S. I.; STIROS, S. C. Spectral analysis of unevenly spaced or discontinuous data using the "normperiod" code. **Computers & Structures**, v. 86, n. 1-2, p. 190-196, 2008.
- RAO, A. R.; HSIEH, C. H. Empirical orthogonal function analysis of rainfall and runoff series. **Water resources management**, v. 4, p. 235-250, 1991.
- SANTOS HG, JACOMINE PKT, ANJOS LHC, OLIVEIRA VA, LUMBRERAS JF, COELHO MR, *et al.* Sistema brasileiro de classificação de solos. 5. ed. rev. ampl. Brasília, DF: Embrapa; 2018.
- SCARGLE, J. D. Studies in astronomical time series analysis. III-Fourier transforms, autocorrelation functions, and cross-correlation functions of unevenly spaced data. **Astrophysical Journal**, v. 343, p. 874-887, 1989.

SCHEPERS, A. R.; SHANAHAN, J. F.; LIEBIG, M. A.; SCHEPERS, J. S.; JOHNSON, S. H.; LUCHIARI Jr, A. Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. **Agronomy Journal**, v. 96, n. 1, p. 195-203, 2004.

SEILMAYER, M.; GONZALEZ, F. G.; WONDRACK, T. The multivariate extension of the Lomb-Scargle method. **arXiv preprint arXiv:2001.10200**, 2020.

ŞENTOP, Mehmet Selahaddin; YÜCEL, Meriç; ÜSTÜNDAĞ, Burak Berk. Spatio-Temporal Missing Data Reconstruction by Using Deep Neural Networks in Agricultural Monitoring Systems. In: **2023 11th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)**. IEEE, 2023. p. 1-6.

SILVA, A. S.; RIBEIRO JR, P. J.; ELMATZOGLOU, I. Modelagem geoestatística utilizando a família de Gneiting de funções de covariância espaço-temporais. **Revista de Matemática e Estatística**, São Paulo, v. 25, n. 1, 2007.

STEIN, A. Analysis of space–time variability in agriculture and the environment with geostatistics. **Statistica Neerlandica**, v. 52, n. 1, p. 18-41, 1998.

SUN, B. M.; ZHOU, Q. Expressing the spatio-temporal pattern of farmland change in arid lands using landscape metrics. **Journal of Arid Environments**, v. 124, p. 118-127, 2016.

TESLENOK, K.; TESLENOK, S. Spatio-temporal analysis of innovations diffusion in the agriculture. **Revista de Matemática: Teoría y Aplicaciones**, v. 26, p. 147-158, 2020.

TOMAZ, A.; MARTINS, I.; CATARINO, A.; MOURINHA, C.; DÔRES, J.; FABIÃO, M.; PALMA, E. P. Spatial and temporal discrimination of soil attributes through multivariate statistical analysis: a case study in irrigated annual crops in south Portugal, **Revista de Ciências Agrárias (Portugal)**, Vol. 45, No. 4, 238-242 ref. 4 ref. 2022.

VAROUCHAKIS, E. A.; THEODORIDOU, P. G.; KARATZAS, G. P. Spatiotemporal geostatistical modeling of groundwater levels under a Bayesian framework using means of physical background. **Journal of Hydrology**, 2019.

VIANA, R.; SANTOS, G.; MOREIRA, D.; LOUZADA, J.; ROSA, L. O. O uso da geoestatística espaço-temporal na predição da temperatura máxima do ar. **Revista Brasileira de Geografia Física**, v. 12, p. 96-111, 2019.

ZAMBERLETTI, P.; PAPAÏX, J.; GABRIEL, E.; OPITZ, T. Spatio-temporal point processes as meta-models for population dynamics in heterogeneous landscapes. **bioRxiv**, 2021.

ZHANG, Z.; MOORE, J. C. Mathematical and physical fundamentals of climate change. Elsevier, 2014.