


UNIVERSIDADE FEDERAL DO PARANÁ

IASMIN FERNANDA PORTELA PFUTZ

INTEGRAÇÃO SENSORIAMENTO REMOTO E GEOESTATÍSTICA PARA  
AVALIAÇÃO DA PRODUÇÃO DE POVOAMENTOS DE *Tectona grandis*



CURITIBA

2024

IASMIN FERNANDA PORTELA PFUTZ

INTEGRAÇÃO SENSORIAMENTO REMOTO E GEOESTATÍSTICA PARA  
AVALIAÇÃO DA PRODUÇÃO DE POVOAMENTOS DE *TECTONA GRANDIS*

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal.

Orientador: Prof. Dr. Allan Libanio Pelissari

Coorientador: Prof. Dr. Sidney Fernando Caldeira

Coorientadora: Profa. Dra. Ana Paula Dalla Corte

CURITIBA

2024

Ficha catalográfica elaborada pela  
Biblioteca de Ciências Florestais e da Madeira - UFPR

Pfutz, Iasmin Fernanda Portela

Integração sensoriamento remoto e geoestatística para avaliação da  
produção de povoamentos de *Tectona grandis* / Iasmin Fernanda Portela  
Pfutz. - Curitiba, 2024.

1 recurso on-line : PDF

Orientador: Prof. Dr. Allan Libanio Pelissari

Coorientadores: Prof. Dr. Sidney Fernando Caldeira

Profa. Dra. Ana Paula Dalla Corte

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências  
Agrárias. Programa de Pós-Graduação em Engenharia Florestal. Defesa:  
Curitiba, 07/10/2024.

1. Teca (Árvore) - Cultivo. 2. Florestas - Sensoriamento remoto. 3. Florestas -  
Medição - Métodos estatísticos. 4. Povoamento florestal - Avaliação. 5. Análise  
de regressão. 6. Produtividade - Avaliação. I. Pelissari, Allan Libanio. II. Caldeira,  
Sidney Fernando. III. Dalla Corte, Ana Paula. IV. Universidade Federal do  
Paraná, Setor de Ciências Agrárias. V. Título.

CDD - 621.367809152

CDU - 528.8

634.0.52

634.022



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE CIÊNCIAS AGRÁRIAS  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
FLORESTAL - 40001016015P0

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **IASMIN FERNANDA PORTELA PFUTZ** intitulada: **INTEGRAÇÃO SENSORIAMENTO REMOTO E GEOESTATÍSTICA PARA AVALIAÇÃO DA PRODUÇÃO DE POVOAMENTOS DE *Tectona grandis***, sob orientação do Prof. Dr. ALLAN LIBANIO PELISSARI, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutora está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 07 de Outubro de 2024.

Assinatura Eletrônica

07/10/2024 15:01:28.0

ALLAN LIBANIO PELISSARI

Presidente da Banca Examinadora

Assinatura Eletrônica

07/10/2024 15:17:01.0

LUCIANO RODRIGO LANSSANOVA

Avaliador Externo (INSTITUTO FED. DE EDUC., CIÊNC. E  
TECNOLOGIA DE MATO GROSSO)

Assinatura Eletrônica

07/10/2024 15:01:00.0

SINTIA VALERIO KOHLER

Avaliador Externo (UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA)

Assinatura Eletrônica

07/10/2024 15:25:55.0

CYRO MATHEUS COMETTI FAVALESSA

Avaliador Externo (UNIVERSIDADE FEDERAL DE MATO GROSSO)

Assinatura Eletrônica

07/10/2024 14:52:43.0

JONATHAN WILLIAM TRAUTENMÜLLER

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

Avenida Lothário Meissner, 632 - CURITIBA - Paraná - Brasil

CEP 80210-170 - Tel: (41) 3360-4212 - E-mail: pgfloresta@gmail.com

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.

Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 403161

**Para autenticar este documento/assinatura, acesse <https://siga.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp> e insira o código 403161**

Ao meu marido, André Luis Stakowian,  
Aos meus pais Berenice e Acir,  
A família Portela e Pfutz  
Com todo meu amor e gratidão  
Dedico.

## AGRADECIMENTOS

À Deus, pela força, sabedoria e coragem concedidas ao longo desta jornada.

Aos meus pais, por seu amor incondicional e por sempre incentivarem minha busca pelo conhecimento.

Ao meu amor, André Luis Stakowian, pelo apoio, pelo companheirismo de trabalhar nos finais de semana e por todo carinho.

Ao meu orientador, pela paciência, pelos ensinamentos compartilhados, pela orientação e auxílio durante esses últimos 6 anos e meio, eles foram fundamentais.

Ao meu coorientador Prof Dr. Sidney Fernando Caldeira pela ajuda e por todas as contribuições que enriqueceram o trabalho.

Aos professores, Prof Dr. Carlos Sanquetta e Ana Paula Dalla Corte pela ajuda e oportunidades concedidas que me ajudaram na formação profissional.

Aos colegas da pós-graduação pelo companheirismo, conversas e momentos de descontração.

Ao Programa de Pós-Graduação em Engenharia Florestal pela possibilidade de realizar esse doutorado e a Universidade Federal do Paraná que me recebeu como caloura em 2010.

Finalmente, minha gratidão a todos que contribuíram para que este trabalho se tornasse realidade.

Muito obrigada!

“Não é a mais forte das espécies que sobrevive, nem a mais inteligente, mas aquela que melhor se adapta às mudanças” (Charles Darwin).

## RESUMO

No Brasil, atualmente há aproximadamente 93 mil hectares com *Tectona grandis*, espécie originária da Ásia e valiosa pela qualidade da madeira. O uso de sensoriamento remoto é uma alternativa viável para associar dados de inventário florestal, como o volume, com índices de vegetação, obtidos, a partir de imagens de satélite. Devido à necessidade nutricional da *T. grandis*, especialmente Potássio e Cálcio, pesquisas quantitativas sobre sua produção e produtividade são essenciais para o planejamento do manejo de precisão. O objetivo geral deste trabalho foi aplicar ferramentas estatísticas e geoestatísticas no estudo da produção e produtividade de um povoamento comercial de *T. grandis* com o auxílio de variáveis de sensoriamento remoto e atributos químicos do solo. Foi realizado um inventário florestal, com a medição dos diâmetros e alturas totais em 46 unidades amostrais de 900 m<sup>2</sup> para a estimativa do volume do povoamento. Os índices de vegetação foram obtidos a partir de imagens Sentinel e os atributos químicos do solo pelas amostras de solo coletadas nas parcelas. Foram aplicados métodos geoestatísticos de krigagem ordinária e cokrigagem ordinária, além da regressão por componentes principais. Na krigagem ordinária, o efeito pepita puro foi registrado para os índices de vegetação IPVI, NDI11 e NDVIRR e para as variáveis do solo P e H+Al. Correlação inversa foi observada entre a variável CHR e volume do povoamento. Houve similaridade nas distribuições espaciais entre as variáveis do povoamento e os atributos químicos do solo. Na região central e noroeste, foram observados os maiores valores de volume do povoamento, altura dominante e atributos químicos do solo, com exceção do Mg e K, nas regiões Leste e Sudoeste os menores valores para as todas as variáveis analisadas. Com a Regressão por Componentes Principais, houve ganho na qualidade do ajuste e destaque da importância de componentes como CTC, MO, Ca, DAP e Mg na explicação da variabilidade do volume e da altura do povoamento. A inclusão de atributos químicos do solo na modelagem geoestatística, juntamente com a aplicação de técnicas como cokrigagem ordinária e regressão por componentes principais, melhorou a precisão das estimativas do povoamento. Há relação espacial entre a produção volumétrica com os índices de vegetação, e podem ser utilizados para o monitoramento e como indicativo da qualidade produtiva do povoamento.

Palavras-chave: geoestatística; teca; índices de vegetação; regressão.



## ABSTRACT

Currently, in Brazil, there are approximately 93,000 hectares of *Tectona grandis*, a species native to Asia and valued for the quality of its wood. Remote sensing is a viable alternative to associate forest inventory data, such as volume, with satellite images using vegetation indices. Due to the nutritional needs of *T. grandis*, especially Potassium and Calcium, quantitative research on its production and productivity is essential for precision management planning. The main aim of this study was to apply statistical and geostatistical tools to the study of production and productivity of a commercial *T. grandis* stand with the help of remote sensing variables and soil chemical attributes. A forest inventory was conducted, measuring diameters and total heights in 46 sample units of 900 m<sup>2</sup> to estimate the volume of the stand. Vegetation indices were obtained from Sentinel images and soil chemical attributes from collected soil samples. Geostatistical methods of ordinary kriging and ordinary cokriging, as well as principal component regression, were applied. In ordinary kriging, the pure nugget effect was recorded for the vegetation indices IPVI, NDI11, and NDVIRR and for the soil variables P and H+Al. An inverse correlation was observed between the variable CHR and the volume of the stand. The stand variables and soil chemical attributes showed similarity in their spatial distributions. In the central and northwest regions, the highest values of stand volume, dominant height, and soil chemical attributes were observed, except for Mg and K. On the other hand, the eastern and southwestern regions showed the lowest values for all the analyzed variables. With Principal Component Regression, there was a gain in the quality of the fit and emphasis on the importance of components such as CEC, OM, Ca, DBH, and Mg in explaining the variability of stand volume and height. The inclusion of soil chemical attributes in geostatistical modeling, along with the application of techniques such as ordinary cokriging and principal component regression, improved the accuracy of stand estimates. The vegetation indices showed a spatial relationship with the volumetric production of the stand and can be used for monitoring and as an indicator of the productive quality of the stand.

Keywords: geostatistics; teak; vegetation indices; regression.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO GERAL.....</b>	<b>12</b>
	<b>REFERÊNCIAS.....</b>	<b>16</b>
<b>2</b>	<b>CAPÍTULO I: RELAÇÃO ESPACIAL ENTRE VOLUME DE UM POVOAMENTO DE TECA E VARIÁVEIS DE SENSORIAMENTO REMOTO EM IMAGENS OBTIDAS COM O SENTINEL 2.....</b>	<b>17</b>
2.1	INTRODUÇÃO.....	18
2.1.1	Hipóteses.....	20
2.2	MATERIAL E MÉTODOS .....	20
2.2.1	Área de estudo .....	20
2.2.2	Dados do povoamento.....	21
2.2.3	Dados de sensoriamento remoto.....	21
2.2.4	Análise Exploratória dos Dados.....	27
2.2.5	Análise Geoestatística .....	28
2.3	RESULTADOS .....	31
2.3.1	Análise Exploratória das Variáveis .....	31
2.3.2	Mapas dos índices de Vegetação.....	34
2.3.3	Análise Geoestatística .....	37
2.4	DISCUSSÃO .....	42
2.5	CONCLUSÃO .....	44
	<b>REFERÊNCIAS.....</b>	<b>45</b>
<b>3</b>	<b>CAPÍTULO II: ESTIMATIVAS DA PRODUÇÃO E PRODUTIVIDADE DO SÍTIO DE <i>TECTONA GRANDIS</i> CORRELACIONADAS COM OS ATRIBUTOS QUÍMICOS DO SOLO.....</b>	<b>50</b>
3.1	INTRODUÇÃO.....	51
3.1.1	Hipóteses.....	53
3.2	MATERIAL E MÉTODOS .....	53
3.2.1	Área de Estudo .....	53
3.2.2	Coleta de Dados.....	54
3.2.3	Modelagens Geoestatísticas .....	54
3.2.4	Regressão por Componentes Principais .....	56

3.3	RESULTADOS .....	58
3.3.1	Análise Exploratória.....	58
3.3.2	Krigagem Ordinária.....	59
3.3.3	Cokrigagem ordinária .....	64
3.3.4	Regressão por Componentes Principais .....	66
3.4	DISCUSSÃO .....	70
3.5	CONCLUSÃO .....	74
	<b>REFERÊNCIAS.....</b>	<b>75</b>
<b>4</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>79</b>
4.1	RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	79

## 1 INTRODUÇÃO GERAL

As florestas desempenham um papel fundamental na regulação ambiental, atuando como sumidouros de carbono, proporcionando habitats para diversas espécies, e regulando os ciclos hídricos, além de fornecerem uma ampla gama de serviços ecossistêmicos. Elas também são fontes essenciais de matérias-primas renováveis utilizadas na fabricação de papel, mobiliário, bioenergia e diversos outros produtos. Diante desse cenário, os plantios florestais assumem uma importância estratégica ao oferecerem uma solução sustentável para atender à crescente demanda por produtos florestais, proporcionando uma alternativa viável à exploração de florestas naturais.

Nesse contexto, a *Tectona grandis* L. f., conhecida como teca, destaca-se pela alta performance da espécie para o suprimento das demandas globais de madeiras tropicais de rápido crescimento, com grande capacidade de adaptação climática, bastante resistente a ação de pragas e insetos e, também pelas propriedades tecnológicas da madeira (KOLLERT; KLEINE, 2017; REIS; OLIVEIRA; SANTOS, 2023). O cultivo de *T. grandis* envolve um regime específico de práticas de manejo que visam otimizar seu crescimento e a qualidade da madeira. Um dos principais componentes do manejo da plantação de teca é a implementação de tratamentos silviculturais eficazes (HITSUMA *et al.*, 2021). Além disso, a produtividade dos plantios de *T. grandis* varia em função de diversos fatores tais como: as condições edafoclimáticas locais, o material genético, as técnicas adotadas na preparação do solo e a adubação (REIS; OLIVEIRA; SANTOS, 2023).

O crescimento da *T. grandis* pode ser significativamente impactado pelo tipo de material genético e pelo sistema de cultivo. O cultivo convencional, por exemplo, apresenta maior crescimento e homogeneidade em comparação ao cultivo mínimo do solo (REIS; OLIVEIRA; SANTOS, 2023).

A definição do espaçamento inicial e do arranjo do plantio afetam o crescimento, produção, desbaste, desrama, sobrevivência, idade de corte, custos e rendimentos operacionais (PAIVA *et al.* 2011).

A fertilização é outro aspecto que requer atenção especial na plantação de *T. grandis*. A espécie é exigente quanto o pH, e também, quanto aos teores de cálcio,

de fósforo, de magnésio e baixa tolerância ao alumínio, além de ser responsiva a adição de fertilizantes (MATRICARDI, 1989).

Além dos fatores mencionados, as decisões sobre os regimes de desrama e desbaste também afetam o crescimento e a produção (PAIVA; LEITE, 2015). Normalmente, a desrama na *T. grandis* inicia no segundo ano, removendo ramos até um terço da altura total das árvores; no terceiro ano, recomenda-se retirar ramos até metade da altura total, e, no quarto ano, até dois terços da altura (PELLISSARI *et al.*, 2012).

A desrama intensa nos estágios iniciais pode reduzir a área foliar e ter impacto negativo no crescimento da teca. Por isso, recomenda-se manter, no mínimo, 40% da copa verde remanescente (REIS; OLIVEIRA; SANTOS, 2023).

O desbaste é uma técnica essencial na silvicultura, pois visa evitar a mortalidade por competição entre as árvores. Influenciado por diversos fatores, como sítio e material genético, a definição do regime de desbaste deve incluir idade, ciclo, peso e tipo (PAIVA; LEITE, 2015).

Por meio dos modelos de distribuição de diâmetros e do método dos ingressos percentuais, observa-se que a idade técnica do primeiro desbaste em plantações de teca é identificada até um ano antes do povoamento entrar em estagnação de crescimento (REIS; OLIVEIRA; SANTOS, 2023).

As principais restrições ao plantio estão associadas à certas características do sítio, uma vez que a *T. grandis* não tolera excesso de umidade no solo e requer solos profundos, férteis e de textura média. Além disso, seu crescimento é menor em locais com temperatura média inferior a 20° C e em altitudes superiores a 500 m (LAMPRECHT, 1990; REIS; OLIVEIRA; SANTOS, 2023). A espécie não tolera geada nem baixas temperatura de inverno, sendo desaconselhável seu plantio em áreas com histórico de geadas (KAOSA-ARD, 1989; REIS; OLIVEIRA; SANTOS, 2023).

Ao comparar a *T. grandis* com culturas como eucalipto e pinus, torna-se evidente o diferencial significativo dessa espécie. Segundo Reis *et al.* (2023) a *T. grandis* destaca-se por sua madeira de alta qualidade, conhecida por sua resistência, durabilidade e apelo estético, crescimento monopodial, rusticidade aos fatores bióticos e demanda segura e consiste no mercado internacional. Enquanto o eucalipto e o pinus são frequentemente cultivados para a produção de papel e celulose. A singularidade dos plantios de *T. grandis* a tornam uma escolha necessária para

produtores que buscam não apenas eficiência em escala, mas também a fabricação de produtos florestais exclusivos de alta qualidade.

Compreender as particularidades do manejo da *T. grandis* é fundamental para otimizar a produção e garantir a sustentabilidade a longo prazo. Esse entendimento profundo sobre as práticas silviculturais específicas é essencial não apenas para maximizar o rendimento das plantações, mas também para enfrentar os desafios inerentes ao cultivo dessa cultura única. Além disso, a aplicação de métodos de manejo apropriados pode influenciar diretamente a saúde das árvores, a qualidade da madeira e, conseqüentemente, a viabilidade econômica das plantações. Assim, um manejo adequado se torna um fator determinante para o sucesso e a longevidade das florestas de *T. grandis*.

Nesse contexto, a modelagem estatística e geoestatística emergem como ferramentas essenciais que complementam o conhecimento sobre o manejo. Elas não apenas explicam o comportamento da *T. grandis*, mas também fundamentam práticas de manejo e preveem a produtividade futura. Mapas temáticos da variabilidade espacial da área basal em plantações de *T. grandis*, segundo Pelissari *et al.* (2015) permitem individualizar características de desbaste por região. A modelagem da variabilidade espacial na produção de plantações de *T. grandis* permite sistemas de amostragem eficientes, considerando estratos homogêneos e alocação otimizada para redução de custos de inventários florestais. A espacialização do estoque volumétrico apoia a gestão, definindo regimes de manejo por talhão, alinhados às necessidades da indústria e redução de custos operacionais (PELISSARI *et al.* 2017). Pelissari *et al.* (2015) utilizaram a krigagem ordinária e indicatriz para mapear classes de sítio e probabilidades de sítios mais produtivos em plantações de *T. grandis*. Assim, essas modelagens auxiliam na determinação e estabelecimento de práticas silviculturais apropriadas, essenciais para gerenciar efetivamente as plantações de *T. grandis*.

Nesse contexto, o objetivo geral deste trabalho foi aplicar ferramentas estatísticas e geoestatísticas no estudo da produção e produtividade de um povoamento comercial de *T. grandis* com o auxílio de variáveis de sensoriamento remoto e atributos químicos do solo. Tendo como objetivos específicos: 1) identificar e analisar as correlações lineares com as variáveis de sensoriamento remoto e com os atributos químicos do solo; 2) aplicar a geoestatística utilizando as variáveis de

sensoriamento remoto e atributos químicos do solo como covariáveis; e 3) aplicar a regressão por componentes principais utilizando os atributos químicos do solo como covariáveis.

## REFERÊNCIAS

- HITSUMA, G. et al. Effects of tree density and size symmetry of competition on diameter growth in the early stages of growth in planted teak (*Tectona grandis*) trees in northern Thailand. **Journal of Forest Research**, v. 26, n. 5, p. 321–327, 2021.
- KAOSA-ARD, A. Teak its natural distribution and related factors. *Nat His Bull Siam Soc*, [s. l.], v. 29, p. 55–74, 1989.
- KOLLERT, W.; KLEINE, M. **The Global Teak Study. Analysis, Evaluation and Future Potential of Teak Resources**. Vienna: International Union Of Forest Research Organizations (Iufro, 2017)
- LAMPRECHT, H. **Silvicultura nos trópicos: ecossistemas florestais e respectivas espécies arbóreas: possibilidades e métodos de aproveitamento sustentado**. Eschborn: GTZ, 1990, 343 p.
- MATRICARDI, W. A. T. **Efeitos dos fatores do solo sobre o desenvolvimento da teca (*Tectona grandis* L.f.) cultivada na grande Cáceres - Mato Grosso**. 1989. 135 f. Dissertação (Mestrado em Ciências Florestais) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 1989.
- PAIVA, H. N. JACOVINE, L. A. G.; TRINDADE, C.; RIBEIRO, G. T. **Cultivo de eucalipto: implantação e manejo**. Viçosa, MG: Aprenda Fácil, 2011. 351 p.
- PAIVA, H. N.; LEITE, H. G. Desbastes e desramas em povoamentos de Eucalyptus. In: SCHUMACHER, M. V.; VIEIRA, M. (ed.). **Silvicultura do eucalipto no Brasil**. Santa Maria, RS: Ed. da UFSM, 2015. p. 83-112.
- PELISSARI, A. L. et al. Correlação espacial dos atributos químicos do solo com o desenvolvimento da teca em Mato Grosso. **Pesquisa Florestal Brasileira**, v. 32, n. 71, p. 247–256, 2012.
- PELISSARI, A. L. et al. Geostatistical modeling of timber volume spatial variability for *Tectona grandis* l. f. precision forestry. **Cerne**, v. 23, n. 1, p. 115–122, 2017.
- PELISSARI, A. L. et al. Propostas de mapeamentos da capacidade produtiva de sítios florestais por meio de análises geoestatísticas. **Scientia Forestalis**, v. 43, n. 107, p. 601–608, 2015.
- REIS, C. A. F.; OLIVEIRA, E. B. de; SANTOS, A. M. **Teca (*Tectona grandis* L. F.) no Brasil**. 2023 – Brasília, DF: Embrapa, 2023.



## 2 CAPÍTULO I: RELAÇÃO ESPACIAL ENTRE VOLUME DE UM POVOAMENTO DE TECA E VARIÁVEIS DE SENSORIAMENTO REMOTO EM IMAGENS OBTIDAS COM O SENTINEL 2

### RESUMO

As florestas plantadas desempenham papel crucial nos setores econômicos e ambiental, atenuando a pressão sobre o desmatamento de florestas autóctones e mitigação de mudanças climáticas. No Brasil, cerca de 93 mil hectares são reflorestados com *Tectona grandis* L. f., uma espécie valiosa pela qualidade da madeira, ampliando seu cultivo devido à demanda no mercado florestal. Para avaliação do potencial produtivo de povoamentos florestais é fundamental obter o seu volume, com a realização de inventários florestais. A estimativa do volume por métodos tradicionais, embora eficiente, é onerosa e requer mão de obra qualificada. Com o uso do sensoriamento remoto é possível associar dados de campo com imagens de satélite, a partir dos índices de vegetação. Dessa forma, este trabalho teve como objetivo avaliar a relação espacial entre a produção volumétrica de um povoamento de *T. grandis* com as variáveis de sensoriamento remoto oriundas de imagens do satélite Sentinel-2/MSI. Por meio de inventário florestal realizado em 213 ha de plantio de teca, aos 22 anos de idade, em 46 unidades amostrais de 900 m<sup>2</sup>, foram obtidas as variáveis diâmetro à altura do peito (DAP) em cm e de altura total em metros, e estimado o volume do povoamento. Para avaliar a relação entre o volume e as variáveis de sensoriamento remoto, as imagens Sentinel foram processadas para obtenção dos seguintes índices de vegetação: *chlorophyll red-edge* (CHR), *difference vegetation index* (DVI), *global environmental monitoring index* (GEMI), *infrared percentagem vegetation index* (IPVI), *inverted red-edge chlorophyll index* (IRECI), *modified chlorophyll absorption in reflectance index* (MCARI), *sentinel-2 red-edge position* (S2REP), *normalized difference infrared index* (NDI11), *red and red-edge normalized difference infrared index* (NDVIRR); e os índices biofísicos: índice de área foliar (LAI) e fração da radiação solar fotossinteticamente ativa absorvida pelo dossel (FAPAR). Após a obtenção das variáveis do povoamento e de sensoriamento remoto, foram aplicados os métodos geoestatísticos de krigagem ordinária e cokrigagem ordinária, com a seleção dos melhores ajustes com base na validação cruzada. Na

krigagem ordinária, o efeito pepita puro foi registrado para as variáveis IPVI, NDI11 e NDVIRR. Correlação inversa foi observada entre a variável CHR e volume do povoamento. Há correlação espacial entre a produção volumétrica do povoamento com os índices de vegetação, que podem ser utilizados para o monitoramento e como indicativo da qualidade produtiva do povoamento.

PALAVRAS-CHAVE: índices de vegetação; geoestatística; teca.

## 2.1 INTRODUÇÃO

As florestas plantadas têm relevante importância nos setores econômico e ambiental pela redução na pressão do desmatamento de florestas nativas e na mitigação das mudanças do clima (SILVA *et al.*, 2021). No Brasil, segundo a IBÁ, (2019), aproximadamente 93 mil hectares eram reflorestados com *Tectona grandis* L. f., espécie de rápido crescimento e de tronco retilíneo que produz madeira com resistência à flexão e tração, além de estabilidade, durabilidade e beleza estética, o que lhe confere utilidade para a produção de móveis, na construção civil e no uso naval (MIDGLEY *et al.*, 2015; PELISSARI *et al.*, 2014). Essas qualidades são associadas ao aumento do interesse pelo cultivo da espécie, em razão da aceitação no mercado florestal e da valorização de sua madeira.

A obtenção do volume de madeira é fundamental para avaliar o potencial produtivo dos povoamentos florestais, além de ser utilizado para o planejamento da produção florestal (AZEVEDO *et al.*, 2011). Nos inventários florestais tradicionais, o procedimento mais habitual para estimar o volume de madeira consiste na obtenção de variáveis de fácil mensuração, como o diâmetro à 1,3m de altura do solo (DAP) e a altura da árvore. Diversos métodos podem ser utilizados para estimar o volume, como equações volumétricas, funções de afilamento e fatores de forma (DAI *et al.*, 2021).

Apesar de serem procedimentos tradicionais e eficientes, a quantificação do volume de madeira, por muitas vezes, é uma atividade onerosa, que requer tempo, trabalho intenso e mão de obra qualificada (DAI *et al.*, 2021; DE MACEDO *et al.*, 2017; TESFAMICHAEL; VAN AARDT; AHMED, 2010). Dessa forma, recentemente, o uso do sensoriamento remoto (SR) pode ser uma ferramenta importante no manejo

florestal, pelo desenvolvimento e disponibilidade de dados de satélite de média e alta resolução espacial, para a caracterização da estrutura das florestas e conseqüentemente das variáveis dendrométricas, como volume, altura e biomassa. A obtenção da estimativa dessa variável por meio do sensoriamento remoto se fundamenta na associação de dados de radiância/reflectância, oriundos de imagens de satélite, com dados de campo (MÄKELÄ; PEKKARINEN, 2004; ROSENQVIST *et al.*, 2003).

A partir de índices de vegetação é possível realizar a associação de dados de campo com imagens de satélite. Esses índices são valores adimensionais gerados por meio de operações aritméticas realizadas entre as bandas espectrais de uma imagem. O principal objetivo é explorar o comportamento espectral para realçar determinadas características da vegetação, propiciando vincular informações espectrais aos parâmetros florestais por meio do desenvolvimento de analogias (COHEN *et al.*, 2001; POWELL *et al.*, 2010; ZANOTTA; FERREIRA; ZORTEA, 2019). Nesse sentido, os índices de vegetação foram elaborados com o objetivo de empregar as informações obtidas por SR para avaliar a cobertura vegetal e diagnosticar área foliar, biomassa, cobertura vegetal, teor de clorofila, produtividade, entre outros (JENSEN; EPIPHANIO, 2009; PONZONI; SHIMABUKURO; KUPLICH, 2012).

As imagens do satélite Sentinel 2, produzidas pela Agência Espacial Europeia (ESA), cobrem o globo e são de alta resolução temporal, espacial e espectral, sem custos de aquisição às diversas aplicações (MAJASALMI; PAUSE *et al.*, 2021; PERTILLE *et al.*, 2019; RAUTIAINEN, 2016; SOTHE *et al.*, 2017). Em relação aos sensores anteriormente desenvolvidos, as vantagens do Sentinel 2 são as quatro bandas estreitas na região do *red-edge*, sendo uma região entre o vermelho e o infravermelho próximo (NIR) e associada às várias características da vegetação, como o teor de clorofila foliar e a biomassa (MAJASALMI; RAUTIAINEN, 2016; PEREZ *et al.*, 2022; PERTILLE *et al.*, 2019; SOTHE *et al.*, 2017). Ainda, alguns índices foram desenvolvidos especificamente para o sensor (FRAMPTON *et al.*, 2013; PEREZ *et al.*, 2022) como o S2REP (Posição da Borda do Vermelho para o Sentinel 2 – *Sentinel 2 Red Edge Postition*) e o IRECI (Índice de Clorofila do Limite Vermelho Invertido – *Inverted Red-Edge Chlorophyll Index*).

Devido à importância comercial dos plantios de *T. grandis*, como o fornecimento de produtos madeireiros de elevado padrão de qualidade, faz-se

necessária a busca por ferramentas que possibilitem gerar informações que fundamentam o manejo da cultura. Assim, considera-se que a investigação de índices de vegetação correlacionados com a produção volumétrica dos povoamentos florestais é um importante meio para o estabelecimento de estratégias de monitoramento dos plantios.

Nesse sentido, o objetivo deste estudo foi avaliar a relação espacial entre a produtividade de um povoamento comercial de *T. grandis* com as variáveis de sensoriamento remoto oriundas de imagens do satélite Sentinel-2/MSI. Como objetivos específicos, considerou-se: i) obter variáveis de sensoriamento remoto para a área do povoamento florestal e, ii) ajustar modelos geoestatísticos para as variáveis volume do povoamento e de sensoriamento remoto.

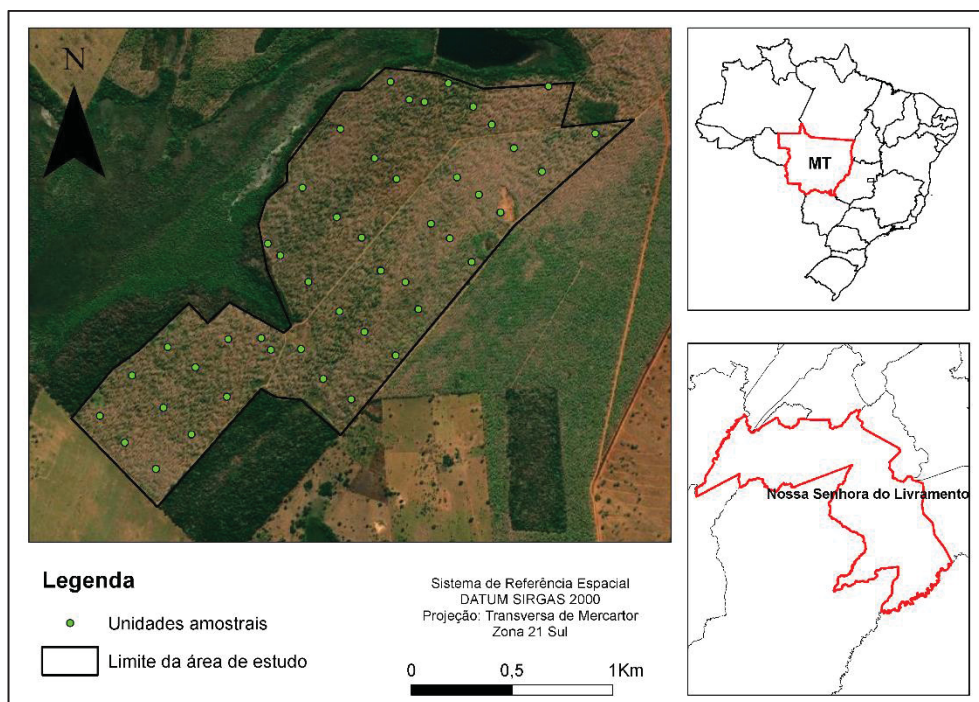
### 2.1.1 Hipóteses

- a) Existe uma relação espacial entre a produtividade de um povoamento e as variáveis de sensoriamento remoto obtidas pelo satélite Sentinel.
- b) A partir do mapeamento da distribuição espacial das variáveis de sensoriamento remoto é possível avaliar a produtividade de um povoamento de *T. grandis*.

## 2.2 MATERIAL E MÉTODOS

### 2.2.1 Área de estudo

A presente pesquisa foi conduzida em um povoamento seminal de *T. grandis* com 22 anos de idade e implantado no espaçamento inicial de 3 m x 3 m em 213 ha. O plantio é um empreendimento da Teca do Brasil Florestal Ltda, e está localizado no município de Nossa Senhora do Livramento, estado do Mato Grosso, Brasil (FIGURA 2.1). De acordo com a classificação de Koppen, o clima da região é do tipo subtropical Aw, com estação seca no inverno, precipitação média de 1.300 mm ano<sup>-1</sup> e temperatura média anual de 25° C (ALVARES *et al.*, 2014). O solo está classificado como PLANOSSOLO Háplico Eutrófico de textura franco-argilosa-arenosa e o relevo é caracterizado como suavemente ondulado (SANTOS *et al.*, 2018).

FIGURA 2.1 - LOCALIZAÇÃO DO POVOAMENTO DE *T. grandis* NO ESTADO DO MATO GROSSO.

FONTE: O autor (2022)

Ao longo da condução do povoamento, foram realizados oito desbastes seletivos até a idade de 22 anos, correspondendo a redução média de 86% da densidade inicial do plantio. Além disso, foram executadas desramas no segundo, terceiro e quarto ano, seguidas por desramas de manutenção nas idades seguintes.

### 2.2.2 Dados do povoamento

As variáveis dendrométricas do povoamento foram coletadas em 46 parcelas georreferenciadas de 900 m<sup>2</sup> (30 m x 30 m), correspondendo a densidade inicial de 100 árvores por unidade amostral. Nessas parcelas, foram coletadas as medidas de diâmetro à altura do peito (DAP) em cm e de altura total em metros. Em seguida, os volumes individuais foram estimados considerando um fator de forma médio de 0,463 resultante da cubagem rigorosa executada no povoamento.

### 2.2.3 Dados de sensoriamento remoto

Para a obtenção das variáveis de sensoriamento remoto, imagens do satélite Sentinel-2/MSI (*Multispectral Instrument*), foram adquiridas no portal *Earth Explorer* do

Serviço Geológico dos Estados Unidos (USGS, 2023). As imagens foram obtidas como dados no nível 1C, sendo dados com reflectância no topo da atmosfera (*Top of the Atmosphere* - TOA). Em seguida, foram convertidas em nível 2A de reflectância de superfície com correção atmosférica, usando o processador Sen2Cor no *software* SNAP v.9.0 executados com as configurações de parâmetros padrão.

A *T. grandis* é uma espécie caducifólia, ou seja, perde suas folhas no período de seca, que ocorre entre os meses de maio a outubro. Assim, foram obtidas imagens em meses diferentes (TABELA 2.1), uma em dezembro, período em que há a presença de folhas da *T. grandis*, a copa estará densa com maior reflectância do verde e praticamente pouca exposição do solo. Já a outra imagem foi obtida em julho, período em que a copa perde suas folhas, apresentando baixa reflectância do verde e com possível exposição do solo. Além disso, foi considerada a baixa cobertura de nuvens (< 5%) e a imagem foi reprojeta para Universal Transversa de Mercator (UTM), Datum SIRGAS 2000 – Fuso 21S.

TABELA 2.1 – IMAGENS DO SENSOR SENTINEL-2/MSI PARA O POVOAMENTO DE *T. GRANDIS*

Imagem	Época	Data
1	Sem folhas	25/07/2021
2	Com folhas	27/12/2021

Fonte: O autor (2023)

Foram obtidas duas imagens para a área de estudo, com o objetivo de comparar o período com folhas e sem folhas da *T. grandis*. Para o cálculo das variáveis de sensoriamento remoto, representadas pelos índices de vegetação, foi utilizada a imagem do período com folhas, uma vez que são as superfícies das folhas responsáveis por interagir com a radiação solar. As bandas foram reamostradas para a resolução espacial de 10 m, e após esse pré-processamento, os índices de vegetação (IV) foram gerados a partir de matemática de banda da imagem (TABELA 2.2). Além desses, foram calculados dois índices biofísicos da vegetação, sendo o Índice de Área Foliar (LAI – *Leaf Area Index*) e a Fração da Radiação Solar Fotossinteticamente Ativa Absorvida pelo Dossel (FAPAR – *Fraction of Absorbed Photosynthetically Active Radiation*).

TABELA 2.2 – ÍNDICES DE VEGETAÇÃO CALCULADOS PARA AS IMAGENS DO SENTINEL-2/MSI PARA UM POVOAMENTO DE *T. grandis*.

IV	Equação	Referência
<i>Chlorophyll Red-Edge</i> (CHR)	$\left(\frac{B5}{B8}\right) - 1$	(GITELSON; GRITZ; MERZLYAK, 2003)
<i>Difference Vegetation</i> <i>Index (DVI)</i>	$(B8 - B4)$	(CLEVERS, 1988; RICHARDSON; WIEGAND, 1977)
<i>Global Environmental</i> <i>Monitoring Index (GEMI)</i>	$\eta (1 - 0.25\eta) - \frac{B4 - 0,125}{1 - B4}$	(PINTY; VERSTRAETE, 1992)
<i>Infrared Percentage</i> <i>Vegetation Index (IPVI)</i>	$\frac{B8}{(B8 + B4)}$	(CRIPPEN, 1990)
<i>Inverted Red Edge</i> <i>Chlorophyll Index (IRECI)</i>	$\frac{(B7 - B4)}{(B5/B6)}$	(FRAMPTON <i>et al.</i> , 2013)
<i>Modified Chlorophyll</i> <i>Absorption in Reflectance</i> <i>Index (MCARI)</i>	$[(B5 - B4) - 0,2(B5 - B3)]. (B5 - B4)$	(DAUGHTRY <i>et al.</i> , 2000)
<i>Sentinel-2 Red-Edge</i> <i>Position (S2REP)</i>	$705 + 35 \left[ \frac{\left(\frac{(B7 + B4)}{2}\right) - B5}{(B6 - B5)} \right]$	(FRAMPTON <i>et al.</i> , 2013 ; GUYOT ; BARET, 1988)
<i>Normalized Difference</i> <i>Infrared Index (NDI11)</i>	$\frac{(B8 - B11)}{(B8 + B11)}$	(HARDISKY; KLEMAS; SMART, 1983)
<i>Red and Red-Edge NDVI</i> (NDVIRR)	$\frac{B8 - (a \cdot B4) + (1 - a)B5}{B8 + (a \cdot B4) + (1 - a)B5}$	(XIE <i>et al.</i> , 2018)
<i>Leaf Area Index (LAI)</i>	$LAI = \frac{\text{Leaf area}}{\text{Ground area}}$	(WATSON; WATSON, 1953)
<i>Fraction of Absorbed</i> <i>Photosynthetically Active</i> <i>Radiation (FAPAR)</i>	$FAPAR = \frac{PAR_i - PAR_r - PAR_t}{PAR_i}$	(SAKOWSKA; JUSZCZAK; GIANELLE, 2016)

IV = índices de vegetação; B2 = *Blue* (490 nm); B3 = *Green* (560 nm); B4 = *Red* (665 nm); B5 = *Red-Edge 1* (705 nm); B6 = *Red-Edge 2* (740 nm); B7 = *Red-Edge 3* (783 nm); B8 = *NIR* (842 nm); B8A = *Red-Edge 4* (865 nm); B11 = *SWIR 1* (1610 nm); B12 = *SWIR 2* (2190 nm);  $a$  = fator de ajuste (considerado 0,5);  $\eta = (2(B8^2 - B4^2) + 1,5 B8 + 0,5 B4)/(B8 + B4 + 0,5)$ ;  $PAR$  = radiação fotossinteticamente ativa, sendo  $PAR_i$ ,  $PAR_r$ ,  $PAR_t$ , a incidente, a refletida e a transmitida, respectivamente; Leaf área = área de folhas (m<sup>2</sup>); Ground área = unidade de terreno (m<sup>2</sup>).

FONTE: O autor (2023).

O algoritmo do SNAP funciona criando um banco de dados que reúne informações detalhadas sobre as características da vegetação e as refletâncias medidas no topo do dossel, conhecidas como TOC (Top of Canopy). Essas refletâncias são as quantidades de luz refletidas pela vegetação e captadas por sensores remotos. Para interpretar esses dados, o algoritmo utiliza redes neurais artificiais (RNN), que são modelos de inteligência artificial treinados para fazer

previsões. Essas redes aprendem a estimar as características do dossel, como densidade e estrutura, a partir das refletâncias do TOC. O treinamento das redes também considera os ângulos de observação, que indicam como o sensor está posicionado em relação ao dossel, garantindo que a análise leve em conta a configuração exata da coleta dos dados (WESS; BARET, 2016).

A partir da coordenada do ponto central de cada parcela no povoamento, foi efetuada a delimitação quadrada de 900 m<sup>2</sup>, com a finalidade de obter um valor médio de IV e índices biofísicos por parcela. Esse procedimento foi realizado em ambiente GIS (*Geographic Information System*) utilizando a ferramenta buffer do software QGIS (QGIS DEVELOPMENT TEAM, 2023).

O Chlorophyll Red-Edge Index (CHR) é amplamente utilizado para estimar o conteúdo de clorofila nas plantas, um indicador direto da saúde e do vigor da vegetação. Este índice apresenta uma relação inversa com o teor de clorofila, ou seja, valores mais baixos do CHR estão associados a maiores concentrações de clorofila, representando vegetação mais saudável e vigorosa. Em contraste, valores mais altos indicam menor teor de clorofila, sugerindo que a vegetação está sob algum tipo de estresse. Esse comportamento ocorre porque plantas com alta concentração de clorofila absorvem mais luz na faixa do vermelho e refletem mais luz no infravermelho próximo. Já plantas com baixa concentração de clorofila absorvem menos luz vermelha e refletem menos luz infravermelha, o que resulta em um aumento no valor do índice (zarco-tejeda ET AL., 2000; DELEGIDO et al., 2013).

O *Difference Vegetation Index* (DVI) é um dos índices de vegetação mais simples, sendo baseado na diferença entre a refletância na faixa do vermelho e do infravermelho próximo (NIR). O princípio fundamental do DVI é que a vegetação verde saudável absorve grande parte da luz vermelha para a fotossíntese e reflete significativamente a luz na faixa do NIR. Quanto maior a diferença entre a luz refletida nessas duas bandas, mais densa e saudável é a vegetação. Plantas saudáveis apresentam valores elevados de DVI, enquanto plantas estressadas ou áreas sem vegetação apresentam valores reduzidos. Embora o DVI seja eficaz para fornecer uma estimativa da densidade e do vigor da vegetação, ele é suscetível à interferência de solo exposto ou materiais não vegetais, o que pode comprometer sua precisão em áreas com cobertura vegetal esparsa (TUCKER, 1979; HUETE, 1988; JENSEN, 2009; LILESAND et al., 2015).



O *Global Environmental Monitoring Index* (GEMI) foi desenvolvido como uma alternativa a outros índices, como o NDVI, com o objetivo de melhorar a correção para efeitos atmosféricos e a interferência do solo exposto. Valores elevados de GEMI indicam vegetação densa e saudável, caracterizada por uma alta reflectância no infravermelho próximo e baixa reflectância no vermelho. Em contraste, valores baixos de GEMI estão associados a vegetação esparsa ou estressada. O GEMI é particularmente útil para o monitoramento temporal da vegetação, permitindo o rastreamento de mudanças, como o crescimento ou a degradação de áreas florestais. Além disso, ele pode ser aplicado em estudos que buscam entender como a vegetação responde a mudanças nas condições ambientais, como secas ou aumento de temperatura, oferecendo uma ferramenta robusta para a gestão de recursos naturais (HUETE, 1988; PINTY & VERSTRAETE, 1992; JENSEN, 2009).

O *Infrared Percentage Vegetation Index* (IPVI), por sua vez, é um índice derivado do NDVI e é usado para monitorar a densidade e a saúde da vegetação. Ele simplifica a análise ao usar a reflectância no infravermelho próximo (NIR) como uma métrica fundamental para distinguir entre vegetação saudável e não saudável. Valores próximos de 1 no IPVI indicam vegetação densa e vigorosa, enquanto valores próximos de 0 estão associados a vegetação esparsa ou sob estresse. Sua simplicidade torna o IPVI uma ferramenta útil em análises rápidas, mas, assim como o DVI, ele pode ser sensível à presença de solo exposto.

O *Inverted Red-Edge Chlorophyll Index* (IRECI) é um índice projetado para estimar o conteúdo de clorofila nas folhas e avaliar a saúde da vegetação, utilizando a borda do vermelho (red-edge). Este índice é especialmente sensível a variações no teor de clorofila devido ao uso de comprimentos de onda no red-edge, uma faixa espectral onde ocorre uma transição abrupta entre alta absorção da luz vermelha pelas folhas e a alta reflectância no infravermelho próximo. O uso do IRECI é vantajoso em áreas com vegetação densa, onde índices convencionais como o NDVI podem apresentar saturação. O IRECI permite uma distinção mais detalhada entre vegetação saudável e estressada, sendo amplamente utilizado na agricultura de precisão e no monitoramento ambiental para detectar mudanças sutis no teor de clorofila, que indicam problemas como deficiência de nutrientes ou estresse hídrico. Estudos apontam que o IRECI é uma ferramenta robusta para análises temporais da

vegetação, permitindo monitoramento de variações sazonais e a resposta das plantas a mudanças nas condições climáticas (DELEGIDO et al., 2011).

O Modified Chlorophyll Absorption in Reflectance index (MCARI) é um índice de vegetação projetado para estimativa do conteúdo de clorofila nas plantas minimizando a interferência do solo nas áreas de baixa cobertura vegetal. O MCARI foi desenvolvido para resolver as limitações do NDVI, que pode ser afetado pelo solo exposto, particularmente em áreas agrícolas. O índice utiliza uma correção baseada na reflectância da banda verde para aumentar sua sensibilidade a clorofila e reduzir a interferência de materiais não vegetais. Aplicações do MCARI incluem monitoramento agrícola, permitindo a detecção precoce de estresses nutricionais em cultivos e a melhoria na precisão de estimativas da saúde das plantas (WU et al., 2020).

O Sentinel-2 Red-Edge Position (S2REP) é um índice espectral desenvolvido para o sensor Sentinel-2 e calcular a posição da borda do vermelho (red-edge) que está diretamente ligado ao teor de clorofila nas folhas. O S2REP é amplamente utilizado para monitorar a vegetação em alta resolução espacial, o que é particularmente útil em estudos de ecossistemas complexos ou áreas agrícolas de grande escala. Ele oferece uma estimativa precisa da posição do red-edge, que é um indicador chave da absorção de luz pela clorofila, e é particularmente útil para avaliar o vigor da vegetação e a produtividade agrícola (FRAMPTON et al., 2013). O uso do S2REP permite identificar mudanças na condição da vegetação com maior precisão em relação a outros índices que não exploram a faixa do red-edge.

O Normalized Difference Infrared Index (NDI11) é utilizado principalmente para monitorar o teor de água nas plantas e no solo. Este índice é aplicado em áreas como gestão hídrica agrícola, pois ele mede a capacidade de retenção de água pela vegetação. O NDI11 é particularmente sensível as mudanças na evapotranspiração e tem sido utilizado para monitorar secas e estresse hídrico em cultivos (SOBRINO et al., 2001). Além disso, o NDI11 pode ser utilizado em modelagem climática, ajudando a prever a resposta da vegetação a mudança na disponibilidade de água.

Red and Red-Edge NDVI (NDVIRR) é uma variação do NDVI que utiliza a faixa red-edge em vez da faixa vermelha padrão, aumentando a precisão da estimativa de clorofila em áreas de vegetação densa. Este índice é utilizado em áreas com alta densidade de biomassa, onde o NDVI convencional pode saturar, dificultando a distinção entre níveis mais altos de biomassa. O uso do red-edge melhora a

sensibilidade a variações na saúde da vegetação, sendo utilizado em monitoramento de florestas e grandes áreas agrícolas. O NDVIRR tem sido amplamente aplicado em projetos de monitoramento ambiental, especialmente na gestão florestal e em avaliações de biodiversidade (CLEVER & GITELSON, 2013).

O Leaf Area Index é um índice que mede a área foliar por unidade de superfície de solo, sendo um dos indicadores mais diretos da densidade de vegetação e capacidade fotossintética de uma área. O LAI é fundamental para modelar processos ecológicos, como o ciclo de carbono, a evapotranspiração e a produtividade (CHEN & BLACK, 1992). A capacidade do LAI de representar a densidade e a estrutura da vegetação o torna uma ferramenta essencial no monitoramento ambiental e na gestão sustentável dos recursos naturais.

O Fraction of Absorbed Photosynthetically Active Radiation (FAPAR) é um índice que mede a fração de radiação fotossinteticamente ativa (400-700nm) absorvida pela vegetação, sendo um indicador fundamental da eficiência fotossintética e da produtividade. O FAPAR está relacionado a capacidade da vegetação de converter luz solar em biomassa, sendo amplamente utilizado para estimar a produção de biomassa e o sequestro de carbono. O FAPAR é um dos parâmetros centrais em modelos de produtividade de plantas e tem grande relevância no contexto de mudanças climáticas, pois ajuda a monitorar o ciclo de carbono e o impacto das flutuações ambientais na produtividade vegetal (GOBRON et al., 1999).

#### 2.2.4 Análise Exploratória dos Dados

Foi realizada uma análise exploratória da variável volume e das variáveis de sensoriamento remoto para descrever o comportamento geral dos dados, além da identificação de valores discrepantes (*outliers*). Essa etapa foi constituída pela análise estatística descritiva e pelo teste de normalidade de Shapiro-Wilk, ao nível de 5% de significância; diagramas de dispersão, histogramas de frequência e correlação linear de Pearson, ao nível de 5% de significância.

Para a análise do coeficiente de correlação linear, foi utilizada a classificação proposta por Schober et al. (2018), sendo que coeficientes inferiores a 0,39 indicam correlação baixa; entre 0,40 e 0,69, a correlação é moderada; entre 0,70 e 0,89, a correlação é forte; e, quando superiores a 0,90, a correlação é considerada muito forte.

Para a interpretação do coeficiente de variação ( $cv\%$ ), foi adaptada a classificação proposta por Pimentel-Gomes, (2023) sendo que  $cv\%$  inferiores a 10% são considerados baixos; entre 10 e 20%, os  $cv\%$  são moderados; entre 20 e 30%, são altos; e superiores a 30%, os  $cv\%$  são considerados muito altos.

## 2.2.5 Análise Geoestatística

A análise geoestatística foi utilizada para modelar os padrões espaciais das variáveis volume do povoamento (V) e de sensoriamento remoto (SR), por meio da determinação das semivariâncias experimentais (1). Na sequência, modelos de semivariogramas teóricos foram ajustados (TABELA 2.3) com o auxílio do programa R (R Core Team, 2023) e do pacote *gstat* (PEBESMA, 2004).

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2 \quad (1)$$

Em que:  $\gamma(h)$  = semivariância da variável  $Z$ ;  $h$  = distância (m); e  $N(h)$  = número de pares de pontos medidos  $Z(X_i)$  e  $Z(X_i + h)$ , separados por uma distância  $h$ .

TABELA 2.3 – MODELOS TEÓRICOS DE SEMIVARIOGRAMAS.

Modelo	Equação	Condição
Esférico	$\gamma(h) = C_0 + C \left[ 1,5 \left( \frac{h}{a} \right) - 0,5 \left( \frac{h}{a} \right)^3 \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Exponencial	$\gamma(h) = C_0 + C \left[ 1 - \exp\left(-\frac{h}{a}\right) \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Gaussiano	$\gamma(h) = C_0 + C \left[ 1 - \exp\left(-\frac{h^2}{a^2}\right) \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Pentaesférico	$\gamma(h) = C_0 + C \left[ \frac{15}{8} \left( \frac{h}{a} \right) - \frac{5}{4} \left( \frac{h}{a} \right)^3 + \frac{3}{8} \left( \frac{h}{a} \right)^5 \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$

Circular	$\gamma(h) = C_0 + C \left[ 7 \left( \frac{h}{a} \right)^2 - \frac{35}{4} \left( \frac{h}{a} \right)^3 + \frac{7}{2} \left( \frac{h}{a} \right)^5 - \frac{3}{4} \left( \frac{h}{a} \right)^7 \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Nugget	$\gamma(h) = 0$	para $h = 0$
	$\gamma(h) = 1$	para $h > a$
Matérn	$\gamma(h) = C_0 + C \left[ 1 - \frac{2}{R(k)} \left( \frac{h\sqrt{k}}{a} \right)^k K_k \left( \frac{2h\sqrt{k}}{a} \right) \right]$	para $h =$ 0 e $k > 0$

$\gamma(h)$  = semivariância;  $C_0$  = efeito pepita;  $C_0 + C$  = patamar;  $a$  = alcance (m);  $h$  = distância (m);  $R$  = função gama;  $k$  = parâmetro de suavização;  $K$  = função Bessel.

FONTE: (Yamamoto; Landim, 2013).

A seleção do melhor ajuste foi feita com base na menor soma de quadrados dos desvios (SQD). Além disso, os semivariogramas foram determinados nas direções de 0°, 45°, 90° e 135° para verificar a presença de anisotropia. Caso detectada, o ângulo de anisotropia foi ajustado para a obtenção de um modelo semivariográfico com parâmetros comuns (efeito pepita, patamar e alcance) em todas as direções (YAMAMOTO; LANDIM, 2013).

Após a seleção dos melhores ajustes e verificadas as dependências espaciais das variáveis, a interpolação espacial foi executada por meio da krigagem ordinária pontual. Nesse interpolador, a estimativa em um ponto não amostrado envolve combinação linear de valores encontrados na vizinhança próxima. As distâncias entre o ponto amostrado e o ponto a ser estimado foram considerados para determinar os pesos para estimar as variáveis das unidades amostrais em um ponto não amostrado (BAGNARA; DOMINGOS; PRIETTO, 2012; YAMAMOTO; LANDIM, 2013). Posteriormente, mapas temáticos foram confeccionados com o *software* R, utilizando cinco classes com intervalos constantes de amplitudes para cada variável e, em seguida, a avaliação visual da similaridade dos padrões espaciais.

A avaliação estatística da interpolação espacial ocorreu por meio da análise dos valores observados e estimados da variável volume do povoamento nos pontos amostrados, aplicando a validação cruzada *leave-one-out* com o auxílio do pacote *gstat* (PEBESMA, 2004). Foram consideradas as seguintes estatísticas: MAE – erro médio absoluto (2) e MPE – erro médio em porcentagem (3), RMSE – raiz quadrada

do erro médio quadrático em porcentagem (4), BIAS – viés (5) e  $r_{x\hat{x}}$  – correlação linear simples de Pearson entre os valores observados ( $x_i$ ) e estimados ( $\hat{x}_i$ ).

$$MAE = \sum_{i=1}^n \frac{|y_i - x_i|}{n} \quad (2)$$

$$MPE = \frac{MAE}{\bar{x}} 100 \quad (3)$$

$$RMSE\% = \frac{RMSE}{\bar{x}} 100, \text{ sendo } RMSE = \sqrt{\frac{(x_i - \hat{x})^2}{n}} \quad (4)$$

$$BIAS = \sum x_i - \hat{x}_i \quad (5)$$


Em seguida, semivariogramas cruzados (7) entre a variável principal ( $Z_1$ ) volume do povoamento, com as variáveis secundárias ( $Z_2$ ) de sensoriamento remoto, foram calculados e, posteriormente, modelos geoestatísticos foram ajustados e selecionados com base na menor soma de quadrados dos desvios (SQD) (TABELA 3). Com essa análise, foi possível avaliar a presença de correlação espacial entre essas variáveis, complementando as análises dos mapas temáticos.

$$\gamma_{1,2}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z_1(X_{1i}) - Z_1(X_{1i} + h)][Z_2(X_{2i}) - Z_2(X_{2i} + h)] \quad (7)$$

Em que:  $\gamma_{1,2}(h)$  = semivariância da variável  $Z_1$  e  $Z_2$ ;  $Z_1$  = variável principal volume do povoamento;  $Z_2$  = variáveis secundárias de sensoriamento remoto;  $h$  = distância; e  $N(h)$  = número de pares de pontos medidos  $Z_i(X_{ii})$  e  $Z_i(X_{ii} + h)$ , separados por uma distância  $h$ .

A sequência metodológica para obtenção das variáveis do povoamento e das variáveis de sensoriamento remoto, assim com a análise geoestatística seguiram as etapas elencadas na Figura 2.2.

FIGURA 2.2 – SEQUÊNCIA METODOLÓGICA PARA OBTENÇÃO DAS VARIÁVEIS DO POVOAMENTO, DAS VARIÁVEIS DE SENSORIAMENTO REMOTO E DA ANÁLISE GEOESTATÍSTICA.



Fonte: O autor (2024)

## 2.3 RESULTADOS

### 2.3.1 Análise Exploratória das Variáveis

Para o volume do povoamento (V) a amplitude foi de 311,31 m<sup>3</sup> ha<sup>-1</sup> entre o maior e o menor valor observado nas unidades amostrais do povoamento de *T. grandis*, considerado moderado o coeficiente de variação (cv%) de 18%. Por outro lado, para as variáveis de sensoriamento remoto IRECI, MCARI e NDI11 foram altos valores de cv%, de 19,2% a 21,7%. Para as demais variáveis, foram mais homogêneas, em razão dos valores de cv% inferiores a 10% (TABELA 2.4).

TABELA 2.4 – ANÁLISE ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS VOLUME DO POVOAMENTO E DE SENSORIAMENTO REMOTO.

Variável	Mínimo	Média	Máximo	Desvio Padrão	cv%	Shapiro-Wilk
V (m <sup>3</sup> ha)	235,82	417,86	547,13	75,41	18,0	0,942*
CHR	-0,79	-0,74	-0,61	0,04	4,9	0,857*
DVI	0,27	0,35	0,43	0,04	11,3	0,961 <sup>ns</sup>
GEMI	0,77	0,87	0,95	0,05	5,2	0,965 <sup>ns</sup>
IPVI	0,84	0,93	0,95	0,02	2,3	0,828*
IRECI	0,07	0,12	0,16	0,02	19,2	0,962 <sup>ns</sup>
MCARI	0,10	0,21	0,32	0,05	21,7	0,974 <sup>ns</sup>
S2REP	0,72	0,72	0,73	0,00	0,1	0,890*
NDI11	0,09	0,30	0,38	0,06	20,2	0,862*
NDVIRR	0,72	0,87	0,92	0,04	4,2	0,838*
LAI	1,88	3,43	4,51	0,60	17,1	0,893 <sup>ns</sup>
FAPAR	0,59	0,81	0,89	0,06	7,5	0,951*

<sup>ns</sup> = não significativo (há distribuição normal); e \* = significativo a 5% pelo teste de Shapiro-Wilk (não há distribuição normal).

Fonte: O autor (2023)

Por meio do teste de Shapiro-Wilk (TABELA 2.4), verificou-se a normalidade dos dados para as variáveis de sensoriamento remoto DVI, GEMI, IRECI, MCARI e LAI. Para as demais, observou-se a ausência de normalidade, ao nível de 5% de significância.

Para a variável V, a correlação linear foi moderada com as variáveis de SR (FIGURA 3). Os valores variaram de 0,402 a 0,594, sendo a maior correlação atribuída à variável GEMI. Para a variável CHR a correlação foi negativa (-0,524) com V.

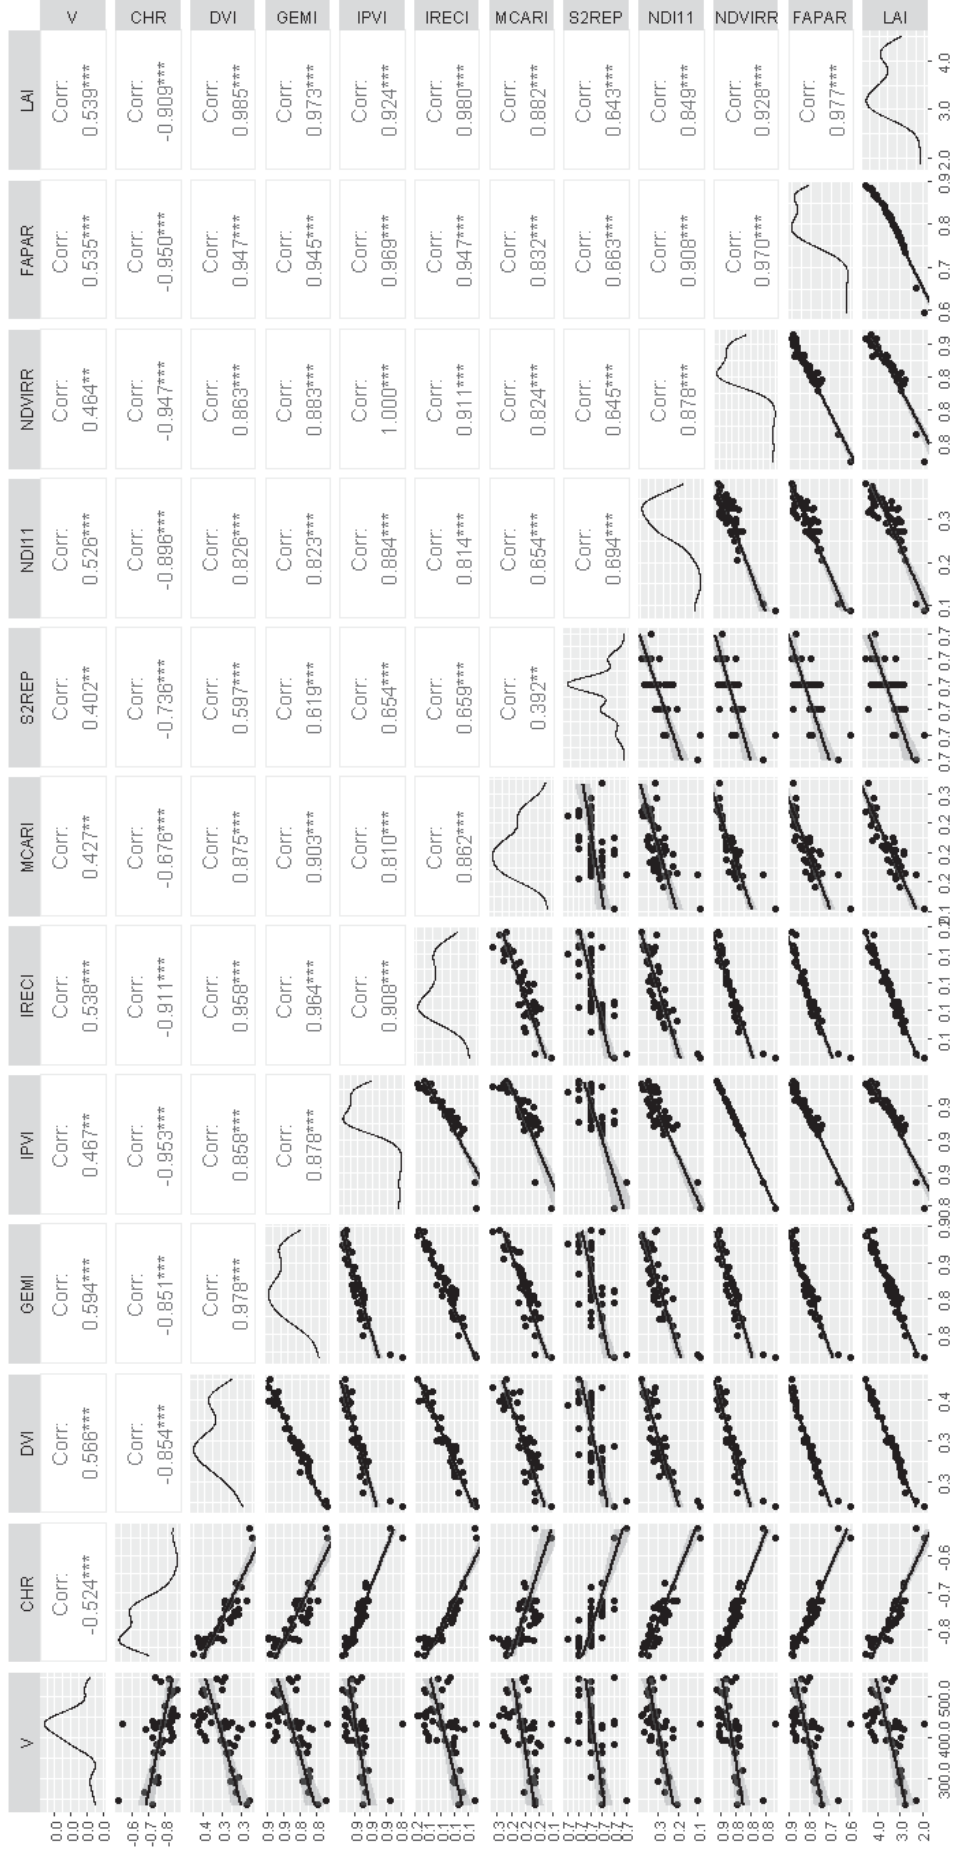
Para os índices de vegetação DVI, GEMI, IPVI, IRECI, NSVI11 e NDVIRR a correlação foi muito forte ( $>0,90$ ) com os índices biofísicos LAI e FAPAR. Para o índice CHR a correlação foi negativa e muito forte com os índices NDVIRR, IRECI, IPVI, LAI e FAPAR. Para algumas variáveis de SR a correlação foi muito forte entre si, por serem derivadas das mesmas fontes, como as bandas do infravermelho próximo (*NIR*), vermelho (*RED*) e *red-edge*.

Distribuições assimétricas negativas foram observadas para as variáveis IPVI, S2REP, NDI11, NDVIRR e FAPAR, com o deslocamento da classe de maior frequência à direita da distribuição, enquanto para as variáveis DVI e LAI a tendência foi à bimodalidade (FIGURA 2.3). Por outro lado, distribuições unimodais com pouca assimetria foram notadas para as variáveis GEMI, IRECI e MCARI, corroborando a presença de normalidade detectada com o teste de Shapiro-Wilk (TABELA 4). Como não foram observadas assimetrias positivas, optou-se pela utilização dos dados nas escalas originais, sem a aplicação de transformações das variáveis.

Na análise dos gráficos de dispersão (FIGURA 2.3) observou-se tendência positiva de aumento dos valores de volume do povoamento (V) com as variáveis de sensoriamento remoto. Exceção foi notada com a variável CHR, para a qual houve tendência negativa. De modo geral, o grau de dispersão das observações corroborou com a moderada correlação linear entre as variáveis.



FIGURA 2.3 – RELAÇÃO ENTRE AS VARIÁVEIS VOLUME DO POVOAMENTO E DE SENSORIAMENTO REMOTO.

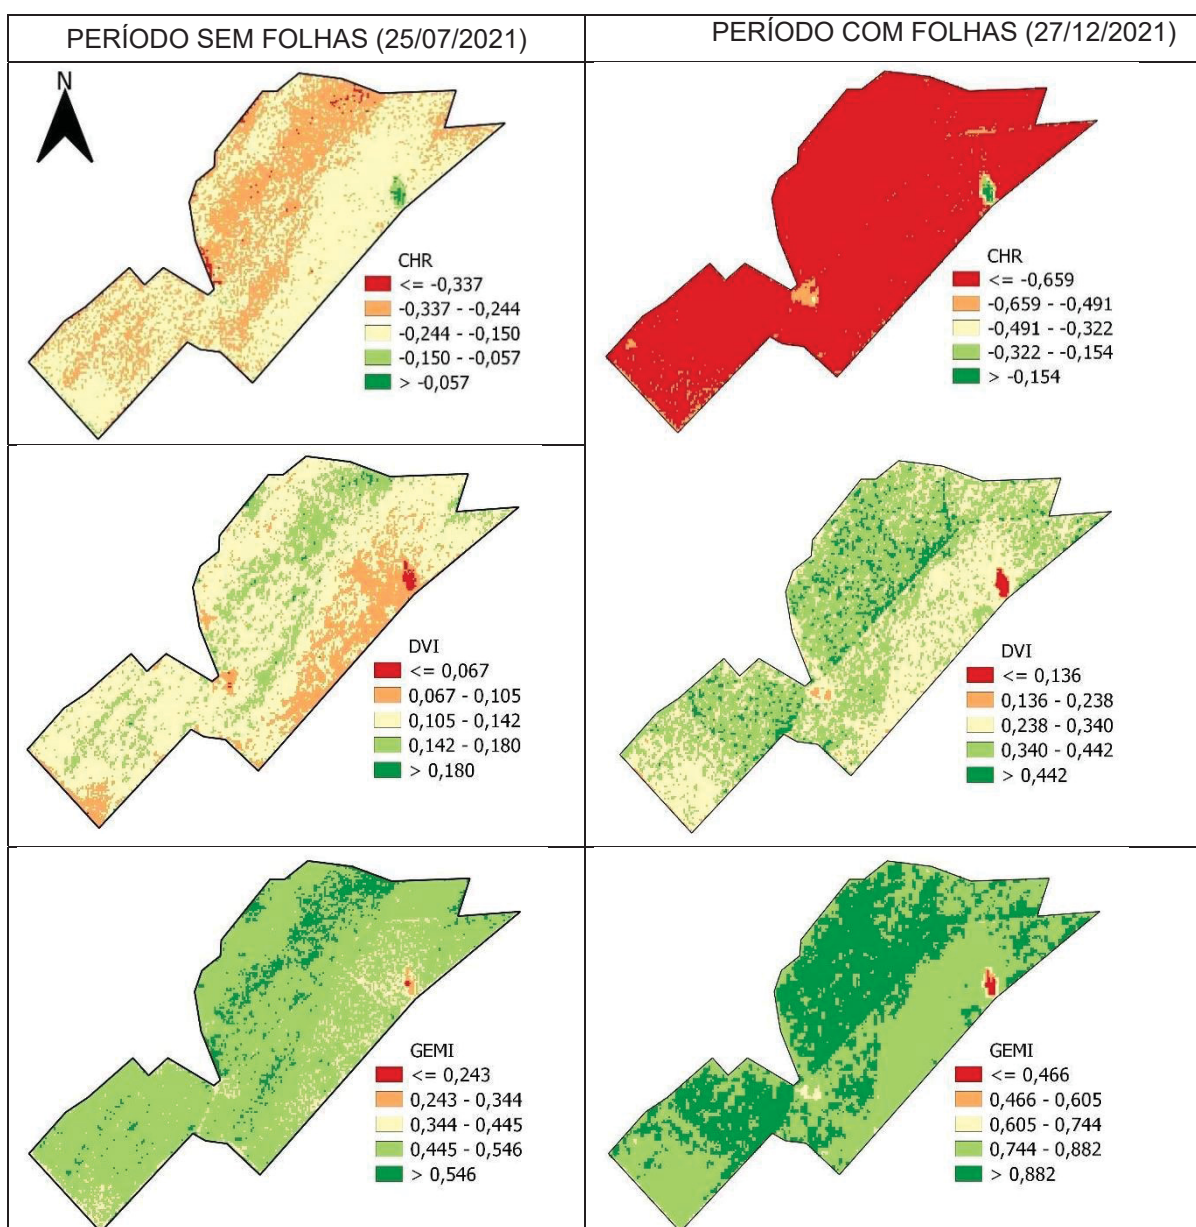


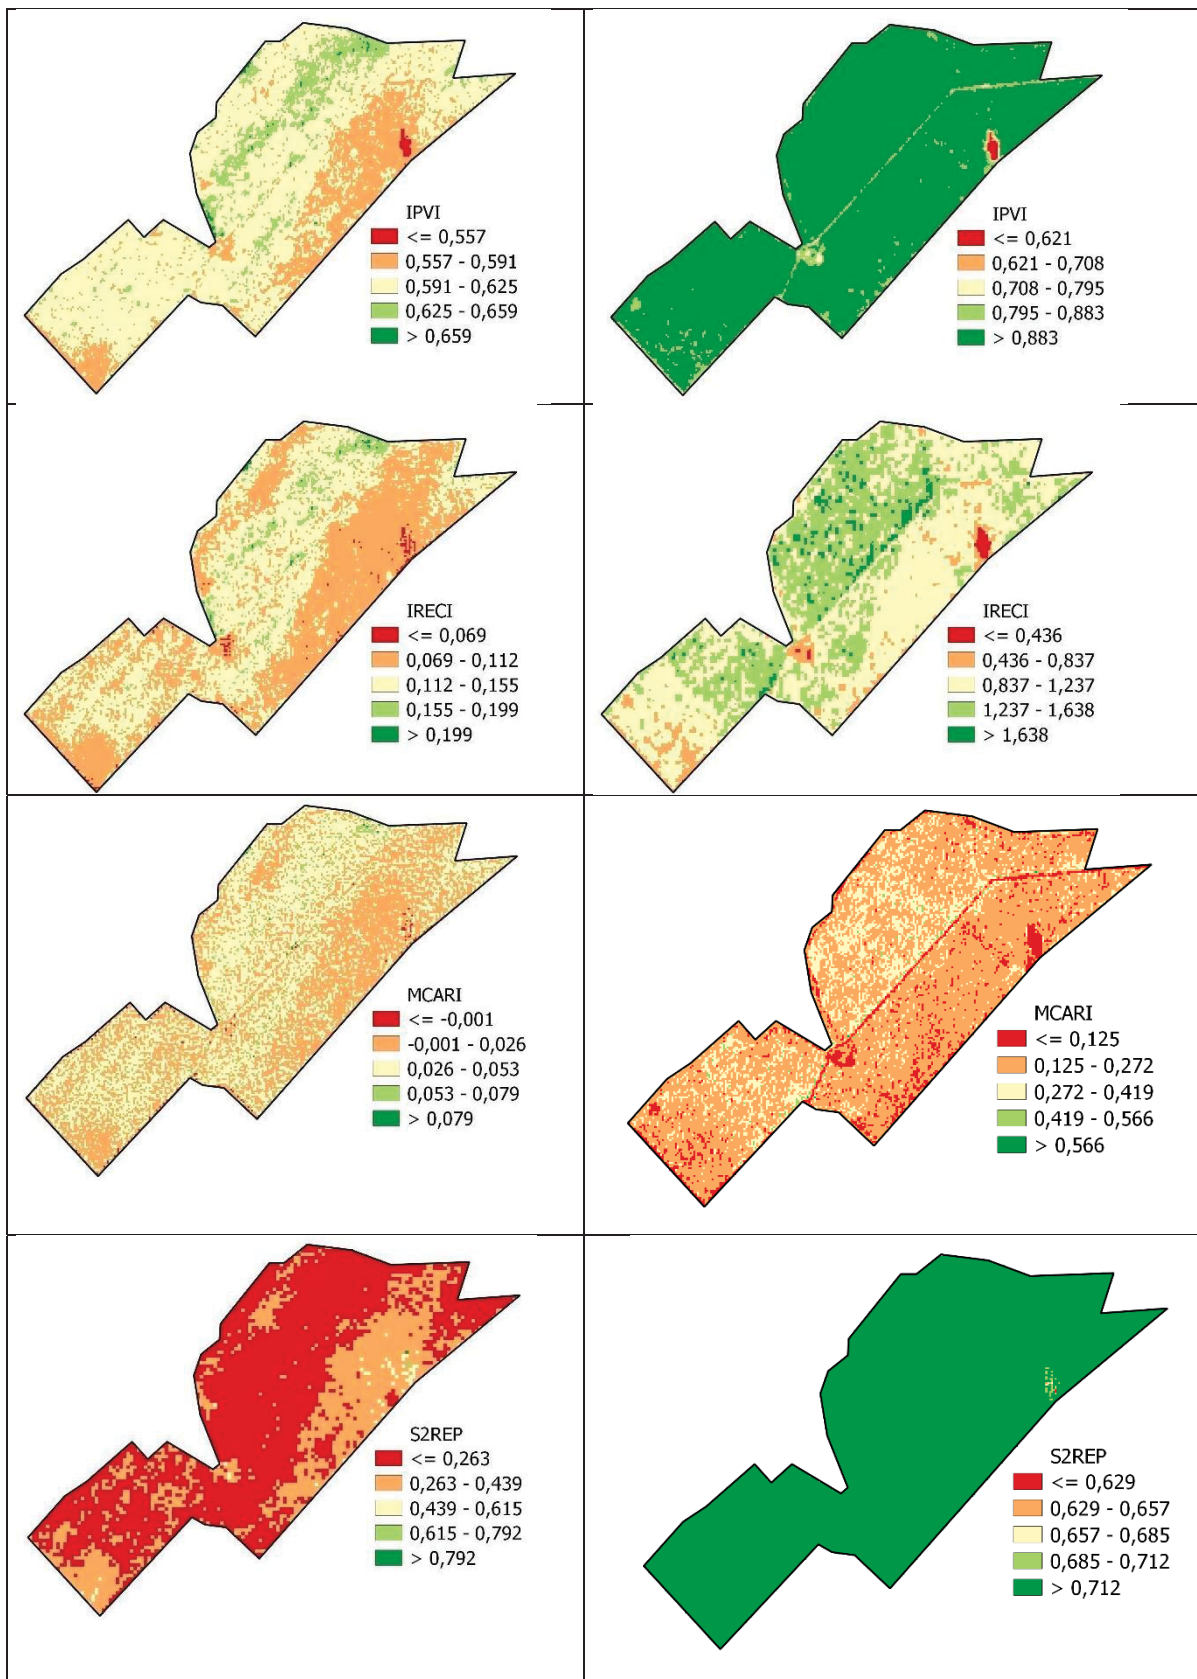
FONTE: O autor (2023).

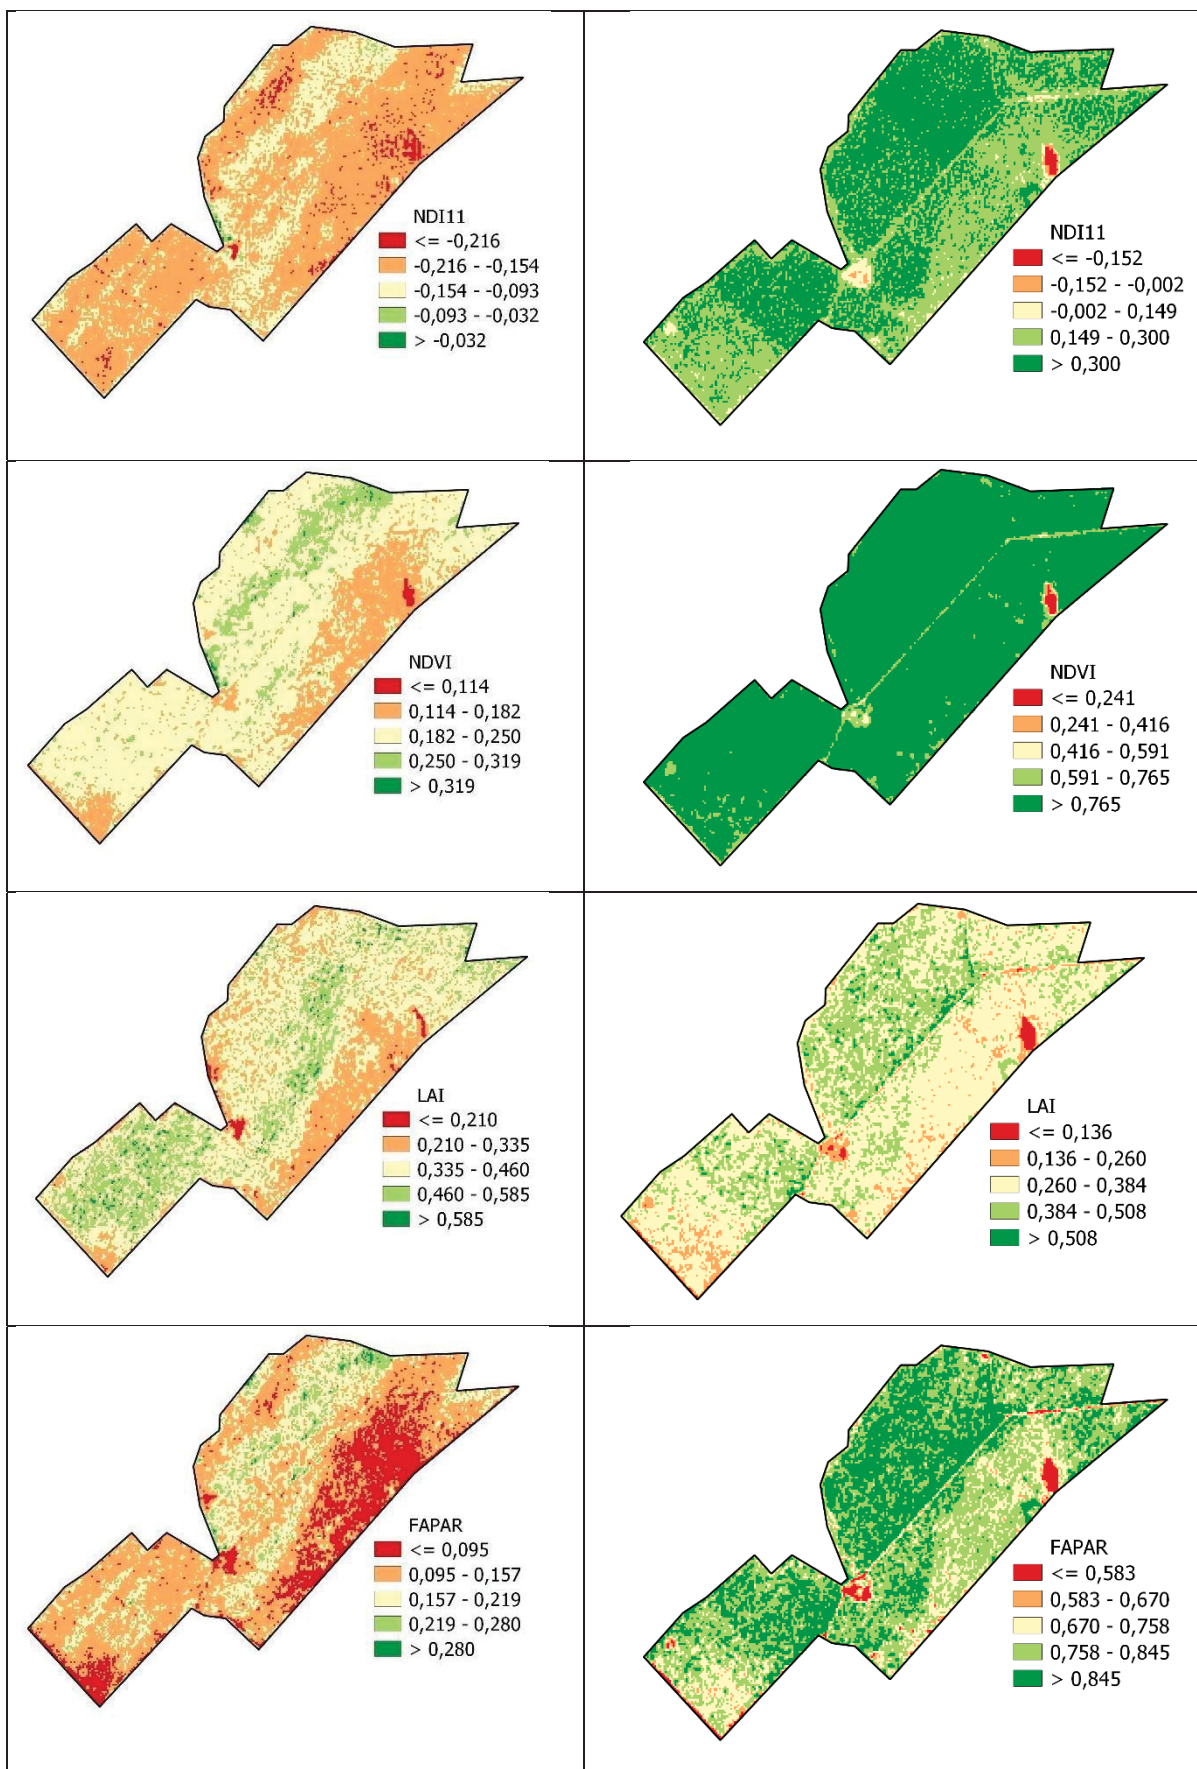
### 2.3.2 Mapas dos índices de Vegetação

Os mapas a seguir (FIGURA 2.4) mostram o padrão de distribuição espacial dos índices de vegetação. Com exceção do índice CHR, que tem uma correlação negativa com o volume do povoamento, os valores de índices próximos de 1, indicam áreas de vegetação com folhas e copas mais densas, por outro lado os valores de índices próximos de 0, indicam regiões com copas ralas ou presença de solo, principalmente devido aos desbastes realizados no plantio, que diminuiram a densidade de árvores no povoamento.

FIGURA 2.4 – MAPAS TEMÁTICOS DOS ÍNDICES DE VEGETAÇÃO PARA O PERÍODO COM FOLHAS E SEM FOLHAS.







### 2.3.3 Análise Geoestatística

Para o volume do povoamento (V), o melhor ajuste foi obtido com o modelo pentaesférico (TABELA 2.5), ao passo que para as variáveis DVI, IRECI e S2REP os melhores ajustes foram com o modelo de Matérn. Com o modelo exponencial, o melhor ajuste foi para GEMI, MCARI e FAPAR, enquanto que, para as demais variáveis IPVI, NDI11 e NDVIRR não houve ajuste, é interpretado como efeito pepita puro (nugget). Além disso, a análise dos semivariogramas direcionais indicou que os dados são isotrópicos, não apresentando anisotropia significativa em nenhuma direção avaliada.

TABELA 2.5 - PARÂMETROS DOS SEMIVARIOGRAMAS AJUSTADOS E VALIDAÇÃO CRUZADA PARA AS VARIÁVEIS VOLUME DO POVOAMENTO E DE SENSORIAMENTO REMOTO

Variável	Modelo	$C_0$	$C_0+C$	$a$	MAE	MPE	RMSE%	$r_{\hat{x}x}$	BIAS
V	Pentaesférico	0	5.448,1	458	46,40	11,1%	15,2%	0,52	-1,05
CHR	Gaussiano	0	0,0013	155	0,027	3,7%	5,1%	0,11	$8 \times 10^{-5}$
DVI	Matérn	0	0,0017	189	0,028	8,1%	10,3%	0,40	$7 \times 10^{-4}$
GEMI	Exponencial	0	0,0025	265	0,029	3,3%	4,4%	0,52	$5 \times 10^{-4}$
IPVI	Nugget	0,0004							
IRECI	Matérn	0	0,0005	225	0,015	13,3%	16,7%	0,48	$3 \times 10^{-4}$
MCARI	Exponencial	0	0,0025	248	0,028	13,4%	18,5%	0,52	$8 \times 10^{-4}$
S2REP	Matérn	0	$1 \times 10^{-6}$	212	$6 \times 10^{-4}$	0,1%	0,12%	0,33	$-2 \times 10^{-6}$
NDI11	Nugget	0,0039							
NDVIRR	Nugget	0,0013							
LAI	Gaussiano	0	0,0039	128	0,420	12,0%	15,7%	0,40	0,010
FAPAR	Exponencial	0	0,4049	201	0,048	5,9%	7,7%	0,09	$9 \times 10^{-5}$

$C_0$  = efeito pepita;  $C_0+C$  = patamar;  $a$  = alcance (m); MAE = erro médio absoluto; MPE = erro médio em porcentagem; RMSE% = raiz quadrada do erro médio quadrático em porcentagem;  $r_{\hat{x}x}$  = correlação linear entre valores observados e estimados; e BIAS = viés;

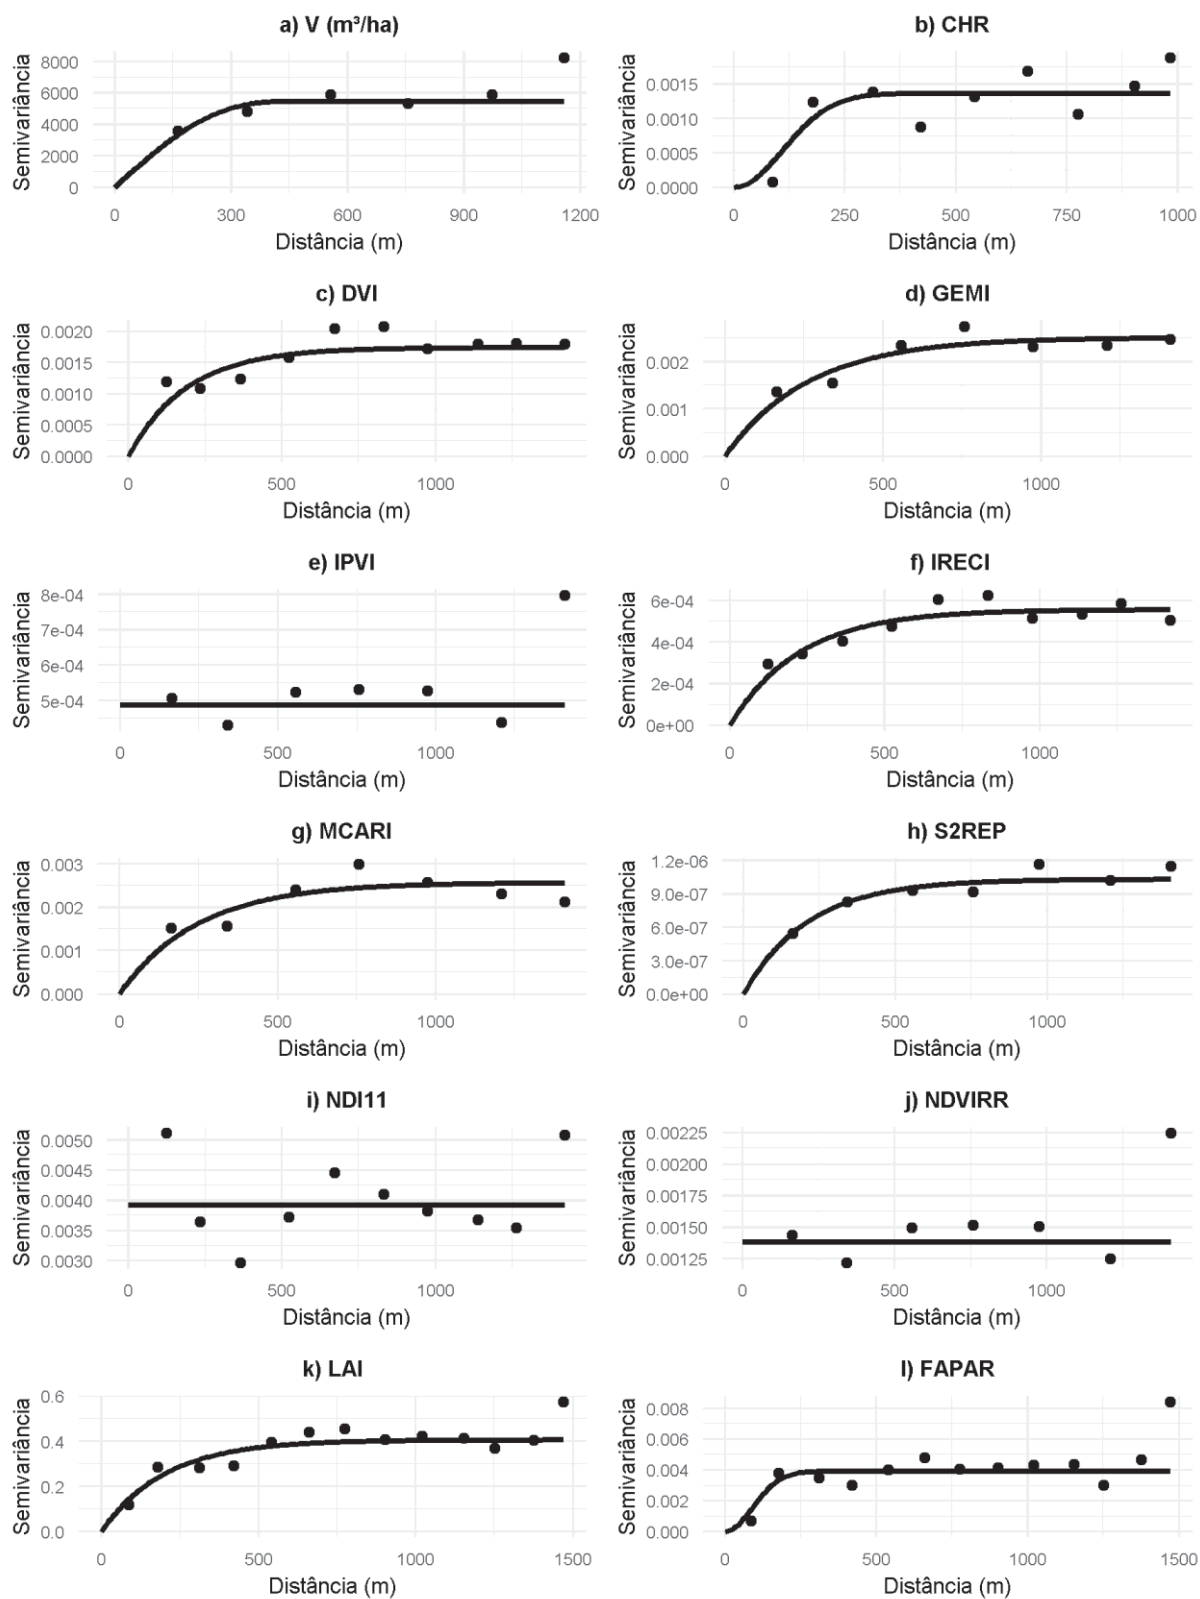
Fonte: O autor (2023)

Para os alcances estimados ( $a$ ), foram obtidos os valores mínimos de 128 m para o índice LAI e o máximo de 458 m para V. Para as demais variáveis, os alcances variaram entre 189 e 265 m. Na validação cruzada, a precisão foi confirmada pelos valores de erro médio absoluto (MAE), erro médio em porcentagem (MPE) e de raiz quadrada do erro médio quadrático em porcentagem (RMSE%). Para as variáveis V, IRECI, MCARI, NDI11 e LAI foram registrados os maiores erros, com RMSE%

superiores a 15%. Além disso, a correlação linear entre os valores estimados e observados ( $r_{\hat{x}x}$ ) foi moderada para as variáveis V, GEMI, IRECI, MCARI e LAI. Ademais, com os valores de BIAS foi observada a ausência de tendências expressivas de super ou subestimativas para as variáveis que apresentaram ajuste.

A partir da análise gráfica dos semivariogramas (FIGURA 2.5), observou-se que as variáveis IPVI, NDI11 e NDVIRR apresentaram efeito pepita puro, que consiste na ausência de dependência espacial. Além disso, notou-se a dispersão reduzida das semivariâncias observadas em torno da linha média estimada para as variáveis, com exceção para CHR, cuja dispersão foi maior. Com o comportamento crescente das semivariâncias estimadas e posterior estabilização em torno de uma distância máxima, definida pelo alcance ( $\alpha$ ), foi confirmada a qualidade dos ajustes geoestatísticos.

FIGURA 2.5– SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS VOLUME DO POVOAMENTO E DE SENSORIAMENTO REMOTO.



FONTE: O autor (2023).

Com a krigagem ordinária, nos mapas temáticos dos índices de vegetação foram observados padrões espaciais similares ao volume do povoamento (FIGURA 2.6a), em que a região central apresentou os maiores valores e a Leste os menores. Exceção foi notada para a variável CHR (FIGURA 2.6b), cuja relação negativa com o volume do povoamento também pode ser observada no semivariograma cruzado, indicativo de correlação espacial negativa, em que o aumento de uma ocasiona a redução dos valores da outra.

Com o ajuste dos semivariogramas cruzados foi demonstrado que a variável V apresenta correlação com as variáveis de SR, com predominância de melhores ajustes com o modelo gaussiano, exceto para a variável CHR e GEMI em que o melhor ajuste foi com o modelo exponencial e para a variável S2REP com o modelo circular (TABELA 2.6). Os alcances ( $a$ ), com variação de 316 m a 469 m, foram interpretados como indicadores de homogeneidade espacial elevada nas estruturas espaciais dessas variáveis.

Nos semivariogramas cruzados das variáveis DVI, IRECI, MCARI, S2REP e LAI foi constatada dispersão reduzida dos valores observados em torno da linha média estimada. Por outro lado, para as variáveis CHR, GEMI e FAPAR foi observada maior dispersão dos valores em torno da linha média (FIGURA 2.7).

TABELA 2.6 - PARÂMETROS DOS SEMIVARIOGRAMAS CRUZADOS AJUSTADOS PARA A VARIÁVEL VOLUME DO POVOAMENTO EM FUNÇÃO DAS VARIÁVEIS DE SENSORIAMENTO REMOTO.

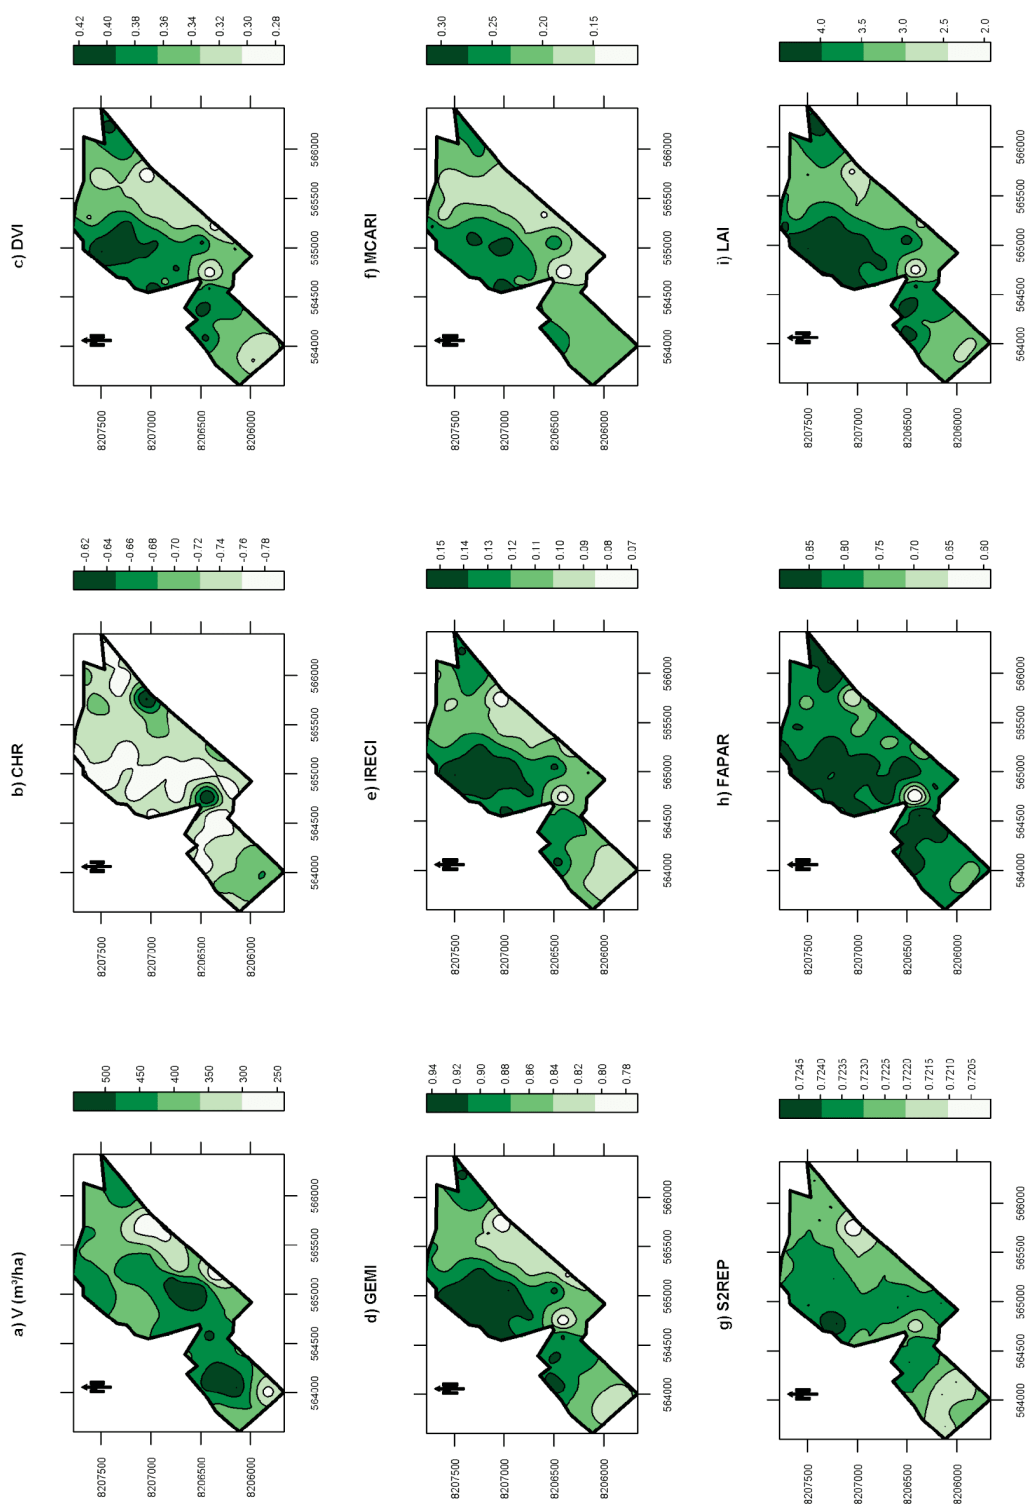
Variável primária	Variável secundária	Modelo	$C_0+C$	$a$
V	CHR	Exponencial	-1,848	328
V	DVI	Gaussiano	2,182	386
V	GEMI	Exponencial	2,48	316
V	IRECI	Gaussiano	1,07	327
V	MCARI	Gaussiano	1,99	438
V	S2REP	Circular	$3,4 \times 10^{-02}$	469
V	LAI	Gaussiano	29,12	327
V	FAPAR	Gaussiano	2,91	317

$C_0+C$  = patamar; e  $a$  = alcance (m).

Fonte: O autor (2023).

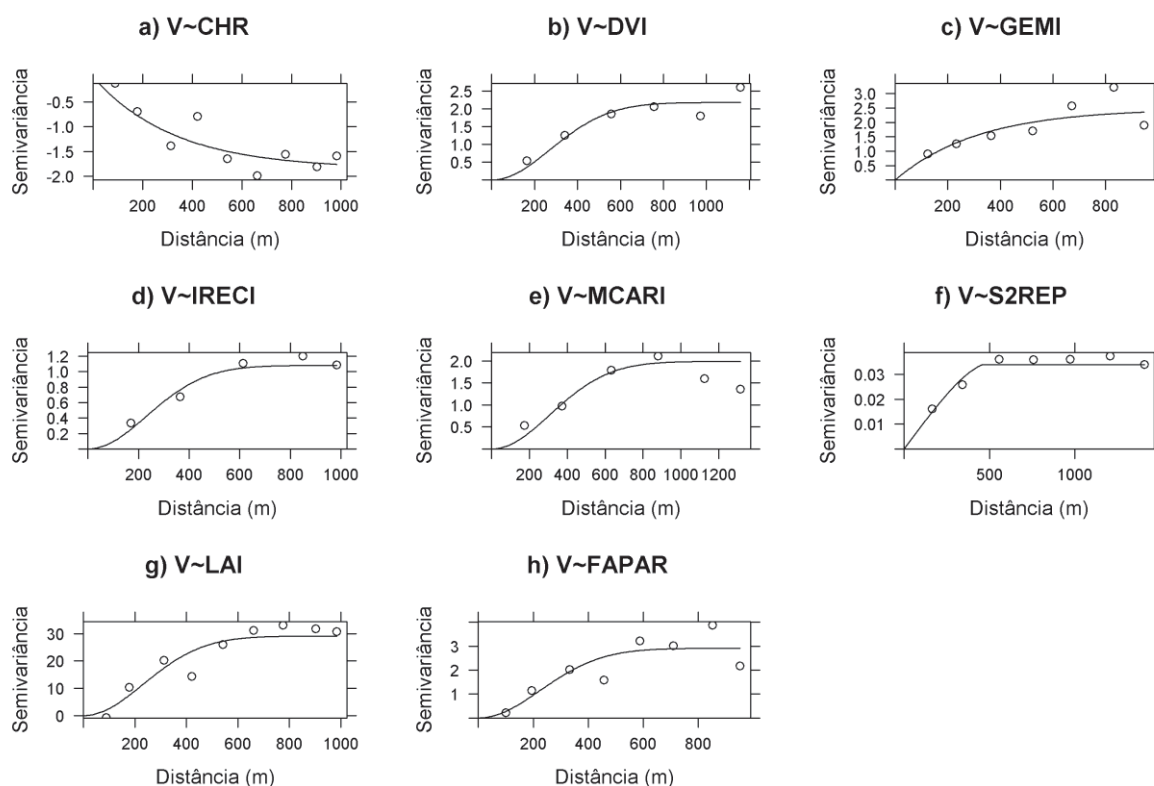


FIGURA 2.6 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS VOLUME DO POVOAMENTO E DE SENSORIAMENTO REMOTO.



FONTE: O autor (2023).

FIGURA 2.7 – SEMIVARIOGRAMAS CRUZADOS AJUSTADOS PARA A VARIÁVEL VOLUME DO POVOAMENTO EM FUNÇÃO DAS VARIÁVEIS DE SENSORIAMENTO REMOTO.



FONTE: O autor (2023).

## 2.4 DISCUSSÃO

O presente estudo objetivou avaliar a relação espacial entre a produção volumétrica de um povoamento comercial de *T. grandis* com as variáveis de sensoriamento remoto oriundas de imagens do satélite Sentinel-2/MSI. Nesse sentido, para o volume do povoamento foram observados níveis moderados na correlação e padrões espaciais similares aos observados para as principais variáveis de sensoriamento remoto.

Para os índices de vegetação que foram gerados nas bandas espectrais vermelho e infravermelho, como DVI, GEMI, IPVI, IRECI, NDVI11 e NDVIRR, a correlação foi muito forte com o índice biofísico LAI. Isso está associado à maior reflectância nesta faixa espectral, que se deve a um maior número de folhas e maior LAI (PERTILLE *et al.*, 2020). Resultado semelhante foi obtido por (ALMEIDA *et al.*,

2015) em que, quanto maior o índice de vegetação, maior o LAI. A exceção foi o índice CHR, que resultou em correlação negativa.

O índice CHR foi desenvolvido por Gitelson; Gritz; Merzlyak, 2003, a partir da relação inversa entre as bandas verde e borda vermelha (*red-edge*), em que há relação inversamente proporcional dessas bandas ao teor de clorofila. Isso explica a correlação negativa com o volume do povoamento e com as demais variáveis de sensoriamento remoto, uma vez que pontos com elevados valores de clorofila resultam em baixos valores do índice CHR.

De maneira geral, nas regiões Leste e central do plantio de *T. grandis* foram registrados, respectivamente, os menores e os maiores valores de volume do povoamento, com semelhança aos padrões espaciais observados nas variáveis de sensoriamento remoto, especialmente para os índices LAI e FAPAR. Essa maior similaridade com esses índices biofísicos deve-se às suas propriedades de indicadores de produtividade da vegetação (BRÉDA, 2003; LANDSBERG; SANDS, 2011; XIAO; LIANG; SUN, 2018).

Na região central, o destaque foram os baixos valores das variáveis de sensoriamento remoto, em razão da maior exposição do solo relacionada a um aceiro no centro do plantio.

Observou-se que o valor médio do índice GEMI foi maior que as demais variáveis, uma vez que esse índice é menos afetado pelas variações atmosféricas. O GEMI é derivado do NDVI e SR, com o objetivo de reduzir os efeitos das perturbações da atmosfera, uma vez que o valor numérico desses índices é transformado pela atmosfera (LEPRIEUR; KERR; PICHON, 1996; PINTY; VERSTRAETE, 1992; SOLTANIKAZEMI *et al.*, 2022). A partir da distribuição espacial do índice MCARI, foi possível observar que a região Leste apresentou uma ampla área de baixos valores. Esse resultado pode ser indicativo de algum estresse no povoamento, uma vez que o MCARI é útil para identificar vegetação estressada e senescente (FRAMPTON *et al.*, 2013).

Para os índices IRECI e S2REP foram observadas distribuição espacial semelhantes entre si e com o volume do povoamento. Para essas variáveis são utilizadas as bandas da borda do vermelho (*red-edge*), para registrar densidades de vegetação moderadas a altas (ALI; IMRAN, 2020; XU *et al.*, 2019). Além disso, são significativos do conteúdo total de clorofila e nitrogênio, bem como podem ser

associados às características da vegetação, como biomassa, e fitossanidade das plantas (ALI; IMRAN, 2020; KANKE *et al.*, 2012; MUTANGA; SKIDMORE, 2007).

Foram registrados valores baixos para o índice DVI, sendo que valores positivos indicam a presença de vegetação e em torno de zero indicam exposição do solo. Além disso, esse índice é utilizado para o monitoramento da vegetação e para mapear a intensidade das queimadas, devido sua sensibilidade para coberturas mais densas (BANNARI *et al.*, 1995; FERNÁNDEZ-MANSO; FERNÁNDEZ-MANSO; QUINTANO, 2016; MUDERERI *et al.*, 2019).

De modo geral, as variáveis de sensoriamento remoto podem ser utilizadas como indicativos da qualidade da produção de povoamentos de *T. grandis*. Cada índice de vegetação pode ser correlacionado com alguma característica da vegetação, tais como: LAI e FAPAR, como indicadoras de produtividade; MCARI, como evidência de vegetação estressada ou senescente; IRECI e S2REP, como parâmetros do teor de clorofila, biomassa e conteúdo de nitrogênio; o índice CHR que apresenta uma relação inversa com o teor de clorofila; o GEMI que reduz o efeito das variações atmosféricas; e o DVI que serve para monitoramento da vegetação

## 2.5 CONCLUSÃO

A modelagem geoestatística da distribuição espacial do volume do povoamento de *T. grandis* e dos índices de vegetação obtidos pelo sensor Sentinel-2 apresentaram precisão estatística, cujos padrões foram espacialmente similares. Observou-se maiores relações espaciais com os índices de vegetação que descrevem a produtividade florestal, como o LAI e FAPAR, além do índice IRECI e S2REP que estão relacionados com a biomassa do povoamento.

A relação espacial entre a produção volumétrica de um povoamento de teca com as variáveis LAI, FAPAR, IRECI e S2REP de sensoriamento remoto, viabiliza o seu para o monitoramento produtivo do plantio.

## REFERÊNCIAS

- ALI, A.; IMRAN, M. Evaluating the potential of red edge position (REP) of hyperspectral remote sensing data for real time estimation of LAI & chlorophyll content of kinnow mandarin (*Citrus reticulata*) fruit orchards. **Scientia Horticulturae**, v. 267, n. December 2019, p. 109326, 2020.
- ALMEIDA, A. Q. de *et al.* Índice de área foliar de Eucalyptus estimado por índices de vegetação utilizando imagens TM - Landsat 5. **Floresta e Ambiente**, v. 22, n. 3, p. 368–376, 2015.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2014.
- AZEVEDO, G. B. de *et al.* Estimativas volumétricas em povoamentos de eucalipto sob regime de alto fuste e talhadia no sudoeste da Bahia. **Pesquisa Florestal Brasileira**, v. 31, n. 68, p. 309–318, 2011.
- BAGNARA, D.; DOMINGOS, P.; PRIETTO, M. Aplicação da krigagem ordinária na modelagem do pH e da dureza da água subterrânea na área central de Passo Fundo – RS. **Teoria e Prática na Engenharia Civil**, v. 20, p. 15–22, 2012.
- BANNARI, A. *et al.* A review of vegetation indices. **Remote Sensing Reviews**, v. 13, n. 1–2, p. 95–120, 1995.
- BRÉDA, N. J. J. Ground-based measurements of leaf area index: A review of methods, instruments and current controversies. **Journal of Experimental Botany**, v. 54, n. 392, p. 2403–2417, 2003.
- CLEVERS, J. G. P. W. The derivation of a simplified reflectance model for the estimation of leaf area index. **Remote Sensing of Environment**, v. 25, n. 1, p. 53–69, 1988.
- COHEN, W. B. *et al.* Modelling forest cover attributes as continuous variables in a regional context with Thematic Mapper data. **International Journal of Remote Sensing**, v. 22, n. 12, p. 2279–2310, 2001.
- CRIPPEN, R. E. Calculating the vegetation index faster. **Remote Sensing of Environment**, v. 34, n. 1, p. 71–73, 1990.
- DAI, P. V. S. *et al.* Estimate of wood volume based on vegetation indices. **Scientia Forestalis/Forest Sciences**, v. 49, n. 129, p. 1–12, 2021.
- DAUGHTRY, C. S. T. *et al.* Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229–239, 2000.
- FERNÁNDEZ-MANSO, A.; FERNÁNDEZ-MANSO, O.; QUINTANO, C. SENTINEL-2A red-edge spectral indices suitability for discriminating burn severity. **International**

**Journal of Applied Earth Observation and Geoinformation**, v. 50, p. 170–175, 2016.

FRAMPTON, W. J. *et al.* Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 83–92, 2013.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, n. 3, p. 271–282, 2003.

GUYOT, G.; BARET, F. Utilisation de la haute resolution spectrale pour suivre l'état des couverts vegetaux. **Journal of Chemical Information and Modeling**, v. 53, n. 9, p. 1689–1699, 1988.

HARDISKY, M. A.; KLEMAS, V.; SMART, R. M. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. **Photogrammetric Engineering & Remote Sensing**, v. 49, n. 1, p. 77–83, 1983.

Indústria Brasileira de Árvores. IBÁ 2019. Brasília, DF, 2019. **Relatório Anual 2019**.

JENSEN, J. R.; NEVES, C.; AL, E. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José Dos Campos, Sp: Parêntese, 2011.

KANKE, Y. *et al.* Red Edge as a Potential Index for Detecting Differences in Plant Nitrogen Status in Winter Wheat. **Journal of Plant Nutrition**, v. 35, n. 10, p. 1526–1541, 2012.

LANDSBERG, J.; SANDS, P. **Physiological ecology of forest production: principles, processes and models**. Amsterdam: Elsevier/Academic Press, 2011.

LEPRIEUR, C.; KERR, Y. H.; PICHON, J. M. Critical assessment of vegetation indices from avhrr in a semi-arid environment. **International Journal of Remote Sensing**, v. 17, n. 13, p. 2549–2563, 1996.

MACEDO, F. L. DE *et al.* Estimativa do volume de madeira para *Eucalyptus* sp. com imagens de satélite de alta resolução espacial. **Scientia Forestalis**, v. 45, n. 114, p. 237–247, 2017.

MAJASALMI, T.; RAUTIAINEN, M. The potential of Sentinel-2 data for estimating biophysical variables in a boreal forest: A simulation study. **Remote Sensing Letters**, v. 7, n. 5, p. 427–436, 2016.

MÄKELÄ, H.; PEKKARINEN, A. Estimation of forest stand volumes by Landsat TM imagery and stand-level field-inventory data. **Forest Ecology and Management**, v. 196, n. 2–3, p. 245–255, 2004.

MIDGLEY, S. *et al.* Planted teak: global production and markets, with reference to Solomon Islands. ACIAR Technical Reports nº 85. **Australian Centre for International Agricultural Research (ACIAR)**: Canberra. p. 92, 2015.

MUDERERI, B. T. *et al.* A comparative analysis of planetscope and sentinel sentinel-2 space-borne sensors in mapping striga weed using guided regularized random forest classification ensemble. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 42, n. 2/W13, p. 701–708, 2019.

MUTANGA, O.; SKIDMORE, A. K. Red edge shift and biochemical content in grass canopies. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, n. 1, p. 34–42, 2007.

PAUSE, M. *et al.* Evaluation of Sentinel-2 vegetation indices for prediction of LAI, fAPAR and fCover of winter wheat in Bulgaria. **Remote Sensing**, v. 8, n. 2, p. 89–108, 2021.

PEBESMA, E. J. Multivariable geostatistics in S: the gstat package. **Computers & Geosciences**, v. 30, n. 7, p. 683–691, ago. 2004.

PELISSARI, A. L. *et al.* Cultivo Da Teca: Características da Espécie para Implantação e Condução de Povoamentos Florestais. **Agrarian Academy**, v. 1, n. 1, p. 127–145, 2014.

PEREZ, G. G. *et al.* Use of Sentinel 2 imagery to estimate vegetation height in fragments of Atlantic Forest. **Ecological Informatics**, v. 69, p. 101680 - 101680, 2022.

PERTILLE, C. T. *et al.* Estimation of leaf area index of Pinus taeda L. And Cupressus lusitanica Mill. And vegetation indices. **Scientia Forestalis**, v. 48, n. 125, p. 1–13, 2020.

PERTILLE, C. T. *et al.* Volume estimation from remote sensing information in a povoament of Pinus taeda L. **Scientia Forestalis**, v. 47, n. 123, p. 526–535, 2019.

PIMENTEL-GOMES, F. **Curso de Estatística Experimental**. 15. ed. Piracicaba: FEALQ, Digitaliza Conteúdo, 2023.

PINTY, B.; VERSTRAETE, M. M. GEMI: A Non-Linear Index to Monitor Global Vegetation from Satellites. **Vegetatio**, v. 101, n. 1, p. 15–20, 1992.

PONZONI, F. J. SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. São Paulo: Oficina de textos, 2012.

POWELL, S. L. *et al.* Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: A comparison of empirical modeling approaches. **Remote Sensing of Environment**, v. 114, n. 5, p. 1053–1068, 2010.

QGIS Development Team, 2023. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>

R CORE TEAM (2023). **R: A language and environment for statistical computing**. **R Foundation for Statistical Computing**, Vienna, Austria. Available in: <https://www.R-project.org>.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, n. 12, p. 1541–1552, 1977.

ROSENQVIST, Å. *et al.* A review of remote sensing technology in support of the Kyoto Protocol. **Environmental Science and Policy**, v. 6, n. 5, p. 441–455, 2003.

SAKOWSKA, K.; JUSZCZAK, R.; GIANELLE, D. Remote Sensing of Grassland Biophysical Parameters in the Context of the Sentinel-2 Satellite Mission. **Journal of Sensors**, v. 2016, 2016.

SANTOS, H. G. *et al.* **Sistema brasileiro de classificação de solos**. 5. Ed., rev. e ampl. – Brasília, DF: Embrapa, 2018.

SCHÖBER, P.; BOER, C.; SCHWARTE, L. A. Correlation coefficients: Appropriate use and interpretation. **Anesthesia and Analgesia**, v. 126, n. 5, p. 1763–1768, 2018.

SILVA, E. J. *et al.* Potencial de imagens do Sentinel-2 na estimativa da biomassa de *Tectona grandis* L.f. a Amazônia Ocidental. **Research, Society and Development**, v. 10, n. 11, p. 1–19, 2021.

SOLTANIKAZEMI, M. *et al.* Field-scale estimation of sugarcane leaf nitrogen content using vegetation indices and spectral bands of Sentinel-2: Application of random forest and support vector regression. **Computers and Electronics in Agriculture**, v. 200, n. April, p. 107130, 2022.

SOTHE, C. *et al.* Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, 2017.

TESFAMICHAEL, S. G.; VAN AARDT, J. A. N.; AHMED, F. Estimating plot-level tree height and volume of eucalyptus grandis plantations using small-footprint, discrete return lidar data. **Progress in Physical Geography**, v. 34, n. 4, p. 515–540, 2010.

United States geological Survey. USGS. (2023). Disponível em: <https://earthexplorer.usgs.gov/>. Acesso em: 4 out. 2023.

WATSON, D. J.; WATSON, M. A. Comparative Physiological Studies on the Growth of Field Crops. **Annals of Applied Biology**, v. 40, n. 1, p. 1–37, 1953.

WESS, M.; BARET, F. **Sentinel2 ToolBox Level2 Products**, 2016. Disponível em: [https://step.esa.int/docs/extra/ATBD\\_S2ToolBox\\_L2B\\_V1.1.pdf](https://step.esa.int/docs/extra/ATBD_S2ToolBox_L2B_V1.1.pdf).

XIAO, Z.; LIANG, S.; SUN, R. Evaluation of three long time series for global fraction of absorbed photosynthetically active radiation (FAPAR) products. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 9, p. 5509–5524, 2018.

XIE, Q. *et al.* Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 5, p. 1482–1492, 2018.



XU, N. *et al.* Analysis of vegetation red edge with different illuminated/shaded canopy proportions and to construct normalized difference canopy shadow index. **Remote Sensing**, v. 11, n. 10, p. 1–16, 2019.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações:** Oficina de textos, 2013.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite.** Oficina de Textos, 2019.

### 3 CAPÍTULO II: ESTIMATIVAS DA PRODUÇÃO E PRODUTIVIDADE DO SÍTIO DE *TECTONA GRANDIS* CORRELACIONADAS COM OS ATRIBUTOS QUÍMICOS DO SOLO

#### RESUMO

A *Tectona grandis*, originária da Ásia e introduzida no Brasil, é uma alternativa econômica às espécies florestais nativas para a produção de madeira para serraria. A necessidade nutricional dessa espécie destaca a importância de pesquisas para o planejamento sustentável, uma vez que atributos, como pH do solo, teor de cálcio e a seleção do local, são cruciais para o seu desenvolvimento. Assim, o objetivo deste trabalho foi investigar o potencial de aprimoramento na precisão das estimativas de volume do povoamento de *T. grandis* e do sítio, dado pela altura dominante, por meio da inclusão de atributos químicos do solo como variáveis auxiliares no contexto das modelagens estatísticas e espaciais. Por meio do inventário florestal, foram coletadas medidas de diâmetro e alturas em 46 unidades amostrais de 900 m<sup>2</sup>. Os volumes totais do povoamento e as alturas dominantes foram estimados como variáveis de produção e produtividade do sítio, respectivamente. Amostras de solo foram coletadas para análise laboratorial dos atributos químicos: potencial hidrogeniônico (pH), fósforo (P), potássio (K), cálcio (Ca), magnésio (Mg), acidez potencial (H+Al), matéria orgânica (MO) e capacidade de troca catiônica (CTC). Após a obtenção das variáveis do povoamento e dos atributos químicos do solo, foram aplicados os métodos de krigagem ordinária, cokrigagem ordinária e regressão por componentes principais. A regressão por componentes principais (PCR) foi utilizada para reduzir a multicolinearidade entre variáveis do solo e melhorar a precisão das estimativas. Com a krigagem ordinária, o efeito pepita puro foi observado para as variáveis P e H+Al. Para as variáveis do povoamento e atributos químicos do solo, houve similaridade em suas distribuições espaciais. A modelagem geoestatística foi precisa e eficiente estatisticamente para estimar a variabilidade espacial das variáveis do povoamento e dos atributos químicos do solo. De modo geral, na região central e noroeste, foram observados os maiores valores de volume do povoamento, altura dominante e atributos químicos do solo, à exceção do Mg e K. Por outro lado, as regiões Leste e Sudoeste apresentaram os menores valores para todas as variáveis analisadas. Com

a PCR, houve ganho na qualidade de ajuste e destaque da importância de componentes como CTC, MO, Ca, DAP e Mg na explicação da variabilidade do volume e da altura do povoamento. A inclusão de atributos químicos do solo na modelagem geoestatística, juntamente com a aplicação de técnicas como cokrigagem ordinária e regressão por componentes principais, melhorou a precisão das estimativas do povoamento.

PALAVRAS-CHAVE: geoestatística; regressão; teca.

### 3.1 INTRODUÇÃO

Originária do continente asiático, a *Tectona grandis* L. f. é uma espécie arbórea introduzida no Brasil como alternativa às espécies florestais nativas de elevado valor econômico para a indústria de base florestal (SILVA *et al.*, 2016; TEWARI; SINGH, 2018). Considerando a importância econômica das plantações de *T. grandis*, pesquisas são necessárias para obter informações quantitativas da produção e da produtividade das florestas, como subsídio ao planejamento sustentável dos recursos madeireiros (TOMPALSKI *et al.*, 2021).

A *T. grandis* é uma espécie com elevada necessidade nutricional, principalmente Potássio (K) e Cálcio (Ca), uma vez que são os elementos mais absorvidos, além do Fósforo (P), Zinco (Zn), Boro (B) e Magnésio (Mg) que contribuem para a produtividade das florestas plantadas (FERNÁNDEZ-MOYA *et al.*, 2015). O pH do solo é um dos fatores chave que limitam o desenvolvimento de povoamento de *T. grandis*, em que o adequado crescimento está correlacionado com o pH na faixa de 5.5 – 8.0, ou seja, solos neutros ou ligeiramente alcalinos (KAOSA-ARD, 1989; ZECH; DRECHSEL, 1991; ZHOU *et al.*, 2012). Além disso, a *T. grandis* requer uma quantidade relativamente elevada de Ca no solo para seu desenvolvimento, sendo que o teor desse nutriente no solo pode ser utilizado como indicador da qualidade do sítio (KAOSA-ARD, 1989; KUMAR, 2005).

A seleção do local é uma questão fundamental na gestão de plantações de *T. grandis*, entretanto, a fertilização subsequente é de suma importância, pois tem como objetivo recompor a elevada demanda de nutrientes, e manter as adequadas

concentrações de nutrientes disponíveis no solo (FERNANDEZ-MOYA *et al.*, 2013; ZECH; DRECHSEL, 1991; ZHOU *et al.*, 2017).

Nesse contexto, a silvicultura de precisão é um método de manejo baseado na aquisição e na análise de dados geoespaciais, possibilitando intervenções localizadas na floresta, com precisão adequada (MIRANDA NETO *et al.*, 2012). A geoestatística é uma ferramenta de precisão, por meio da qual é possível fazer inferências espaciais sobre locais não amostrados por meio de pontos amostrados de atributos na produção florestal e, assim, produzir mapas de variabilidade espacial como auxiliares na decisão sobre o manejo florestal (KARAHAN; ERŞAHIN, 2018; OLIVER; WEBSTER, 2014).

Diversos estudos foram conduzidos por meio da modelagem geoestatística nas ciências florestais, principalmente com interpolador univariado de krigagem ordinária (MACEDO NETO *et al.*, 2020; PELISSARI *et al.*, 2017; PFUTZ *et al.*, 2021). Esse método utiliza a dependência espacial para prever valores em quaisquer pontos em uma área de interesse (YAMAMOTO; LANDIM, 2013). Por outro lado, a cokrigagem ordinária (DOLÁCIO *et al.*, 2021; QIN *et al.*, 2020) consiste em um método multivariado, com o qual é possível fazer previsões de uma variável considerando as relações espaciais com uma variável auxiliar dentro do mesmo campo aleatório (OLEA, 2012; YAMAMOTO; LANDIM, 2013).

Como os atributos químicos do solo são importantes variáveis que afetam o crescimento e a produção de povoamentos de *T. grandis*, elas podem ser empregadas como variáveis auxiliares na modelagem geoestatística, a fim de aumentar a precisão das previsões em nível espacial (MACEDO NETO *et al.*, 2020; PELISSARI *et al.*, 2014).

Neste estudo, objetivou-se investigar o potencial de aprimoramento na precisão das estimativas de volume do povoamento de *T. grandis* e do sítio, dado pela altura dominante, por meio da inclusão de atributos químicos do solo como variáveis auxiliares no contexto das modelagens estatísticas e espaciais. Como objetivos específicos, considerou-se: i) identificar a correlação espacial entre as variáveis do povoamento e de atributos químicos do solo; ii) empregar variáveis químicas do solo como covariáveis em modelagem geoestatística; e iii) aplicar a regressão por componentes principais, utilizando os atributos químicos do solo como covariáveis.

### 3.1.1 Hipóteses

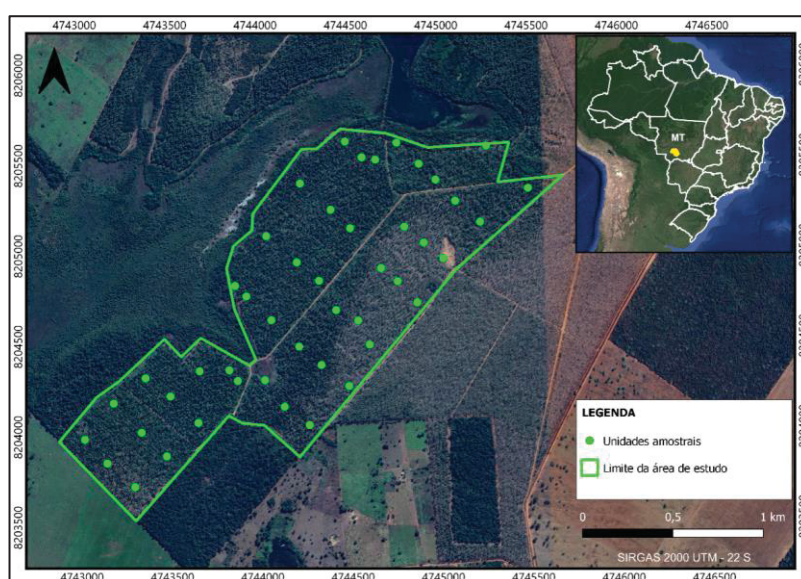
- c) Os atributos químicos do solo, associados como covariáveis nas modelagens estatística e geoestatística, possibilitam o aumento na precisão das estimativas de volume de povoamento.
- d) A partir do mapeamento da distribuição espacial dos atributos químicos do solo é possível obter informações com precisão estatística da produção e da produtividade como subsídios ao manejo florestal

## 3.2 MATERIAL E MÉTODOS

### 3.2.1 Área de Estudo

O presente estudo foi realizado em um povoamento homogêneo de *T. grandis* de 213 hectares, aos 17 anos de idade e espaçamento de 3 m x 3 m, localizado no estado de Mato Grosso, Brasil (FIGURA 3.1). O clima da região é do tipo Aw (Köppen), com precipitação média anual de 1.300 mm.ano<sup>-1</sup> e temperatura média de 25 °C (ALVARES *et al.*, 2014). O solo é classificado como PLANOSSOLO HÁPLICO com textura franco-argilo-arenosa e a topografia é suavemente inclinada (PELLISSARI *et al.*, 2017).

FIGURA 3.1 - DISTRIBUIÇÃO ESPACIAL DAS UNIDADES DE AMOSTRA E COORDENADAS GEOGRÁFICAS DO POVOAMENTO DE *T. grandis*.



FONTE: O autor (2023).

Durante a condução do povoamento, desbastes seletivos foram executados ao 5, 8, 11, 13 e 16 anos, reduzindo a densidade média para aproximadamente 175 árvores por hectare. Além disso, podas foram realizadas no segundo, terceiro e quarto anos, aplicando manutenções nos anos seguintes.

### 3.2.2 Coleta de Dados

Para a coleta de dados, 46 unidades amostrais georreferenciadas de 900 m<sup>2</sup> (30 m x 30 m) foram alocadas e medidas de diâmetros à altura do peito (DAP) e alturas totais foram mensuradas. Os volumes totais individuais foram estimados considerando o fator de forma médio de 0,463 da cubagem rigorosa realizada no povoamento florestal. Posteriormente, foram estimados os volumes totais do povoamento (V), como variável de produção (m<sup>3</sup> ha<sup>-1</sup>), e as alturas dominantes ( $h_{dom}$ ), como medida da produtividade do sítio florestal.

Amostras de solo foram coletadas nos centros de cada unidade amostral, a uma profundidade de 0 a 20 cm, sendo determinados os atributos químicos em laboratório (CLAESSEN *et al.*, 1997): potencial hidrogeniônico (pH), fósforo (P), potássio (K), cálcio (Ca), magnésio (Mg), acidez potencial (H+Al), matéria orgânica (MO) e capacidade de troca catiônica (CTC).

### 3.2.3 Modelagens Geoestatísticas

As variáveis do povoamento e do solo foram submetidas à análise exploratória com o programa computacional R (R CORE TEAM, 2023). Essa análise consistiu em estatísticas descritivas, teste de normalidade de Shapiro-Wilk ( $\alpha = 0,05$ ), correlação linear de Pearson, histogramas de frequência e gráficos de dispersão. Foi utilizada a classificação proposta por Schober *et al.* (2018) para a análise do coeficiente de correlação linear, com a seguinte padronização para a correlação: baixa, para coeficientes inferiores a 0,39, moderada, entre 0,40 e 0,69; forte, entre 0,70 e 0,89 e muito forte para coeficientes superiores a 0,90. Com relação ao coeficiente de variação, foi utilizada a classificação proposta por Pimentel-Gomes (2023), em que, foram considerados como baixos, os cv% inferiores a 10%; moderados, os cv% entre 10 e 20%; altos, os cv% entre 20 e 30%; e muito altos, os cv% superiores a 30%.

A análise geoestatística foi aplicada para o modelo espacial, por meio das semivariâncias experimentais. Esses modelos de semivariâncias teóricas foram ajustados (TABELA 3.1) com auxílio do programa R (R CORE TEAM, 2023) e do pacote gstat (PEBESMA, 2004). A seleção do semivariograma foi baseada na menor soma de quadrados dos desvios (SQD), em que os semivariogramas foram determinados em quatro direções espaciais para verificar a isotropia: 0°, 45°, 90° e 135°.

TABELA 3.1 – MODELOS TEÓRICOS DE SEMIVARIOGRAMAS.

Modelo	Equação	Condição
Esférico	$\gamma(h) = C_0 + C \left[ 1,5 \left( \frac{h}{a} \right) - 0,5 \left( \frac{h}{a} \right)^3 \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Exponencial	$\gamma(h) = C_0 + C \left[ 1 - \exp \left( -\frac{h}{a} \right) \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Gaussiano	$\gamma(h) = C_0 + C \left[ 1 - \exp \left( -\frac{h^2}{a^2} \right) \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Pentaesférico	$\gamma(h) = C_0 + C \left[ \frac{15}{8} \left( \frac{h}{a} \right) - \frac{5}{4} \left( \frac{h}{a} \right)^3 + \frac{3}{8} \left( \frac{h}{a} \right)^5 \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Circular	$\gamma(h) = C_0 + C \left[ 7 \left( \frac{h}{a} \right)^2 - \frac{35}{4} \left( \frac{h}{a} \right)^3 + \frac{7}{2} \left( \frac{h}{a} \right)^5 - \frac{3}{4} \left( \frac{h}{a} \right)^7 \right]$	para $h < a$
	$\gamma(h) = C_0 + C$	para $h \geq a$
Nugget	$\gamma(h) = 0$	para $h = 0$
	$\gamma(h) = 1$	para $h > a$
Matérn	$\gamma(h) = C_0 + C \left[ 1 - \frac{2}{R(k)} \left( \frac{h\sqrt{k}}{a} \right)^k K_k \left( \frac{2h\sqrt{k}}{a} \right) \right]$	Para $h =$
		0 e $k > 0$

$\gamma(h)$  = semivariância;  $C_0$  = efeito pepita;  $C_0 + C$  = patamar;  $a$  = alcance (m);  $h$  = distância (m);  $R$  = função gama;  $k$  = parâmetro de suavização;  $K$  = função Bessel.

FONTE: (Yamamoto; Landim, 2013)

Após verificada a dependência espacial e selecionados os melhores ajustes, a interpolação espacial foi executada pela krigagem ordinária, bem como por cokrigagem ordinária, considerando os atributos químicos do solo como covariáveis. A krigagem ordinária (KO) é uma técnica de interpolação espacial usada para estimar valores em locais não amostrados considerando a estrutura espacial das observações, ao passo que a cokrigagem ordinária (OCK) é um método multivariado que envolve a interpolação de duas ou mais variáveis, avaliando suas relações espaciais e correlações cruzadas (YAMAMOTO; LANDIM, 2013).

Posteriormente, foram confeccionados mapas temáticos com o *software* R, utilizando cinco classes com intervalos constantes de amplitudes para cada variável, o que possibilita a avaliação visual da similaridade dos padrões espaciais. Adicionalmente, o método de validação cruzada *leave-one-out* foi usado para avaliar a capacidade preditiva dos modelos em cada cenário. Também foram aplicadas as seguintes estatísticas: MAE - erro absoluto médio (1), MPE - erro percentual médio (2), RMSE% - raiz percentual do erro quadrático médio (3), BIAS – viés (4) e  $r_{x\hat{x}}$  - correlação linear simples de Pearson entre os valores observados e estimados

$$MAE = \frac{\sum |x_i - \hat{x}_i|}{n} \quad (1)$$

$$MPE = \frac{MAE}{\bar{x}} 100 \quad (2)$$

$$RMSE\% = \frac{RMSE}{\bar{x}} 100, \text{ sendo } RMSE = \sqrt{\frac{(x_i - \hat{x})^2}{n}} \quad (3)$$

$$BIAS = \sum x_i - \hat{x}_i \quad (4)$$

### 3.2.4 Regressão por Componentes Principais

A regressão por componentes principais (*Principal Component Regression* – PCR) foi utilizada como uma abordagem multivariada ao combinar os métodos estatísticos de análise de componentes principais (PCA) e regressão linear. A PCR iniciou com a aplicação da PCA aos dados originais para determinar os componentes principais (PC), e o DAP (média dos diâmetros a 1,3 m) da parcela e os atributos químicos do solo como covariáveis. Em seguida, as componentes principais (PC) foram utilizadas como variáveis preditoras na regressão linear, em que a variável



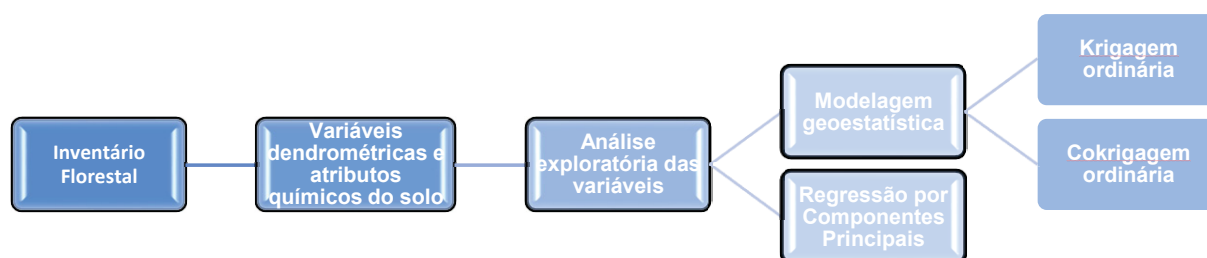
resposta foi modelada como uma combinação linear dos componentes principais (FEBRERO-BANDE; GALEANO; GONZÁLEZ-MANTEIGA, 2017; JOLLIFFE, 1982; KEITHLEY; HEIEN; WIGHTMAN, 2009). Essa etapa foi realizada com o auxílio do *software* R (R CORE TEAM, 2023) e do pacote *p/s* (MEVIK *et al.*, 2022).

Justificou-se a aplicação da PCR para a remoção da multicolinearidade entre as covariáveis do solo, mensurada pela estatística do Fator de Inflação de Variâncias (*Variance Inflation Factor* - VIF), sendo VIF superiores a 10 considerado como elevado grau de multicolinearidade (ROSA FILHO; PARISI; SOARES, 2018). Além disso, com a PCR foi possível reduzir a dimensão dos dados, uma vez que foram utilizados nove atributos do solo como covariáveis nos modelos, mantendo a informação relevante contida nos componentes principais (KEITHLEY; HEIEN; WIGHTMAN, 2009).

Uma vez que a escolha de um número ótimo de componentes principais (PC) na regressão é subjetiva, foi utilizada a estratégia de aleatorização (*randomization*), na qual é empregada uma abordagem de permutação e testada se a adição de um novo componente é benéfica (MEVIK; WEHRENS, 2022). Nesta técnica, avaliou-se os modelos com a diminuição gradativa de PCs, para identificar a perda significativa de desempenho do modelo testado e a seleção ótima de componentes principais.

A sequência metodológica para obtenção das variáveis do povoamento, dos atributos químicos do solo e das modelagens estatísticas e geoestatísticas, seguiram as seguintes etapas elencadas na Figura 3.8.

FIGURA 3.8 – SEQUÊNCIA METODOLÓGICA PARA OBTENÇÃO DAS VARIÁVEIS DO POVOAMENTO, DOS ATRIBUTOS QUÍMICOS DO SOLO E DA ANÁLISE ESTATÍSTICA E GEOESTATÍSTICA.



Fonte: O autor (2023).

### 3.3 RESULTADOS

#### 3.3.1 Análise Exploratória

Para o volume do povoamento (V) a amplitude foi de 248,74 m<sup>3</sup> ha<sup>-1</sup> entre o maior e menor valor observado nas unidades amostrais, resultando em um coeficiente moderado de 16,5% (TABELA 3.2). Com exceção do pH, com um valor baixo de cv% (8,2%), para as demais variáveis químicas do solo os valores de cv% foram altos, variando de 31,2% a 141,6%. A maior homogeneidade foi para a variável h<sub>dom</sub>, em razão do cv% inferior a 10% (TABELA 3.2).

TABELA 3.2 – ANÁLISE ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DO POVOAMENTO E DOS ATRIBUTOS QUÍMICOS DO SOLO.

Variável	Mínimo	Média	Máximo	cv (%)	Assimetria	Curtose	p-valor SW
V (m <sup>3</sup> ha <sup>-1</sup> )	209,84	360,58	458,49	16,5	-0,795	3,184	0,015 <sup>ns</sup>
h <sub>dom</sub> (m)	22,63	25,03	27,41	4,2	-0,087	3,221	0,279 <sup>ns</sup>
DAP (cm)	24,35	29,97	34,80	8,1	-0,193	3,083	0,202 <sup>ns</sup>
pH	4,60	5,66	6,60	8,2	-0,469	2,772	0,049 <sup>ns</sup>
P (mg dm <sup>-3</sup> )	0,80	2,32	23,20	141,6	5,773	37,149	0,000*
K (mg dm <sup>-3</sup> )	16,0	58,78	125,0	52,0	0,731	2,676	0,004*
Ca (cmolc dm <sup>-3</sup> )	0,58	3,78	7,06	44,2	-0,317	2,195	0,142 <sup>ns</sup>
Mg (cmolc dm <sup>-3</sup> )	0,38	1,35	3,11	51,1	0,828	3,069	0,011 <sup>ns</sup>
H+Al (cmolc dm <sup>-3</sup> )	0,75	2,64	4,75	35,8	0,335	3,107	0,176 <sup>ns</sup>
MO (g dm <sup>-3</sup> )	8,0	8,34	36,00	5,3	0,598	2,996	0,080 <sup>ns</sup>
CTC (cmolc dm <sup>-3</sup> )	4,0	7,94	14,00	31,2	0,254	2,629	0,266 <sup>ns</sup>

<sup>ns</sup> = não significativo (há distribuição normal); e \* = significativo a 5% pelo teste de Shapiro-Wilk (não há distribuição normal).

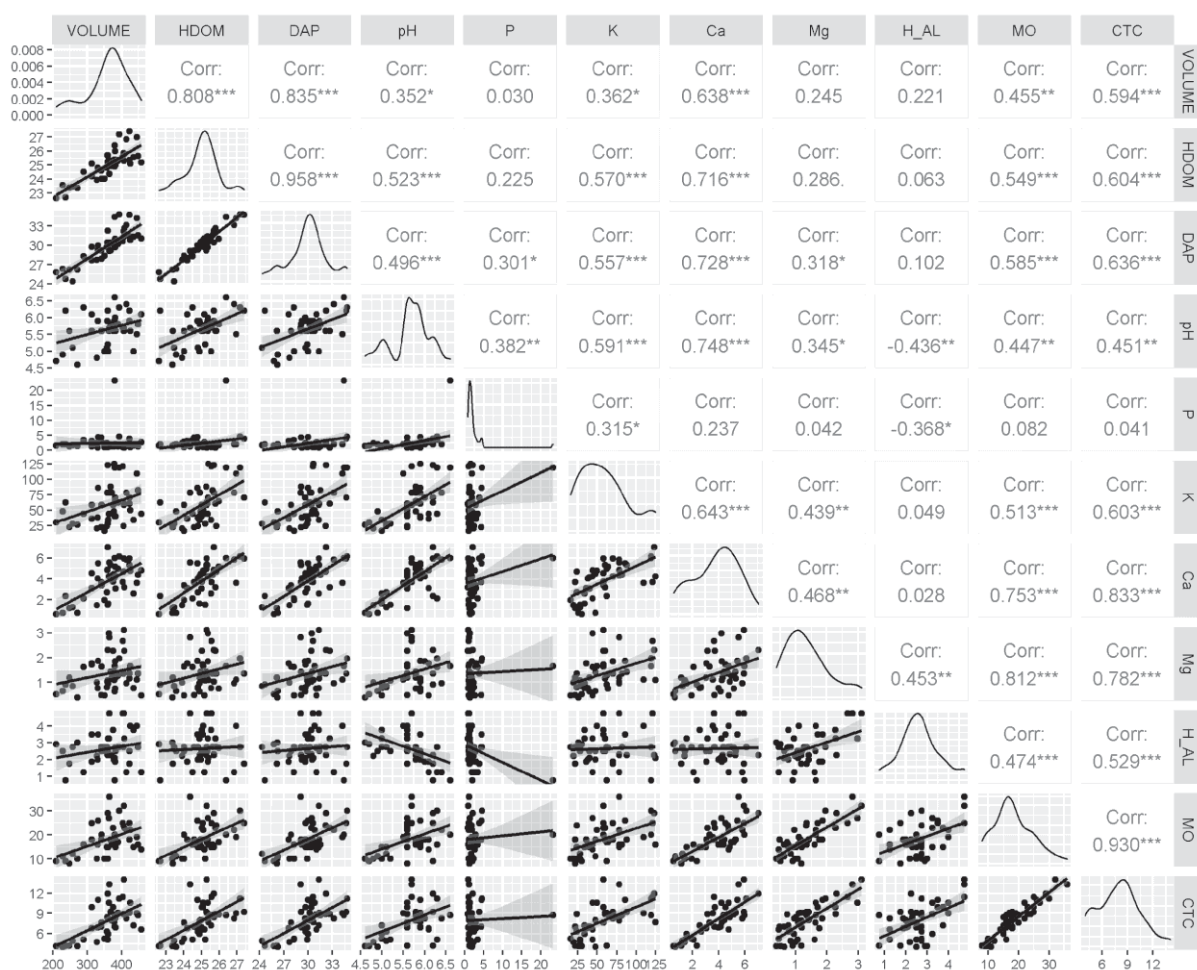
FONTE: O autor (2023).

Com o teste de Shapiro-Wilk (TABELA 3.2), verificou-se a normalidade para a maioria das variáveis, ao nível de 5% de significância, com exceção do P e K. Para a variável V a correlação linear foi positiva com todos os atributos químicos do solo. Os maiores valores positivos foram observados entre V e h<sub>dom</sub>, e a variável Ca, com correlações de 0,638 e 0,716, respectivamente.

As distribuições com assimetria negativa foram observadas para a variável V (FIGURA 3.2), na qual a classe de maior frequência se deslocou para a direita das distribuições, sendo uma evidência de mudanças causadas pelo desbaste em

povoamentos florestais de longa rotação. Além disso, é possível observar a tendência de distribuições bimodais para  $h_{dom}$  (FIGURA 3.2), o que pode ser indicativo da existência de, pelo menos, duas classes de locais com produtividades distintas. Para as variáveis químicas do solo P, K e Mg as distribuições foram com assimetria positiva, enquanto para o Ca foi assimetria negativa. Assim, optou-se pela transformação logarítmica das variáveis, visando reduzir a assimetria de suas distribuições.

FIGURA 3.2 – RELAÇÃO ENTRE AS VARIÁVEIS DO POVOAMENTO E DOS ATRIBUTOS QUÍMICOS DO SOLO



Fonte: O autor (2023)

### 3.3.2 Krigagem Ordinária

Para as variáveis V,  $h_{dom}$ , pH, K e Mg, o melhor ajuste foi com o modelo exponencial de semivariograma teórico, enquanto para as variáveis Ca, MO e CTC o melhor ajuste foi com o modelo circular (TABELA 3.3). Para as variáveis P e H+Al não houve ajuste, resultando em efeito pepita puro (nugget).

TABELA 3.3 – PARÂMETROS DOS SEMIVARIOGRAMAS AJUSTADOS E VALIDAÇÃO CRUZADA PARA AS VARIÁVEIS DO POVOAMENTO E DOS ATRIBUTOS QUÍMICOS DO SOLO.

Variável	Modelo	C <sub>0</sub>	C <sub>0</sub> +C	<i>a</i>	MAE	MPE	RMSE%	<i>r<sub>xx</sub></i>	BIAS
V	Exponencial	0	0,3815	251	0,111	1,9	2,7	0,476	-0,00297
h <sub>dom</sub>	Exponencial	0	0,0020	245	0,029	0,9	1,2	0,368	0,00003
pH	Exponencial	0	0,0080	218	0,053	3,1	4,1	0,527	0,00036
P	Nugget	0,303							
K	Exponencial	0	0,3401	335	0,344	8,7	10,8	0,616	-0,0006
Ca	Circular	0	0,5149	868	0,305	25,7	35,1	0,740	0,0046
Mg	Exponencial	0	0,2977	196	0,373	214,1	25	0,546	-0,0009
H+Al	Nugget	0,151							
MO	Circular	0	0,1678	845	0,207	7,3	9,0	0,700	-0,0032
CTC	Circular	0	0,1506	922	0,168	8,3	10,3	0,773	-0,0005

C<sub>0</sub> = efeito pepita; C<sub>0</sub>+C = patamar; *a* = alcance (m); MAE = erro médio absoluto; MPE = erro médio em porcentagem; RMSE% = raiz quadrada do erro médio quadrático em porcentagem; *r<sub>xx</sub>* = correlação linear entre valores observados e estimados; e BIAS = viés.

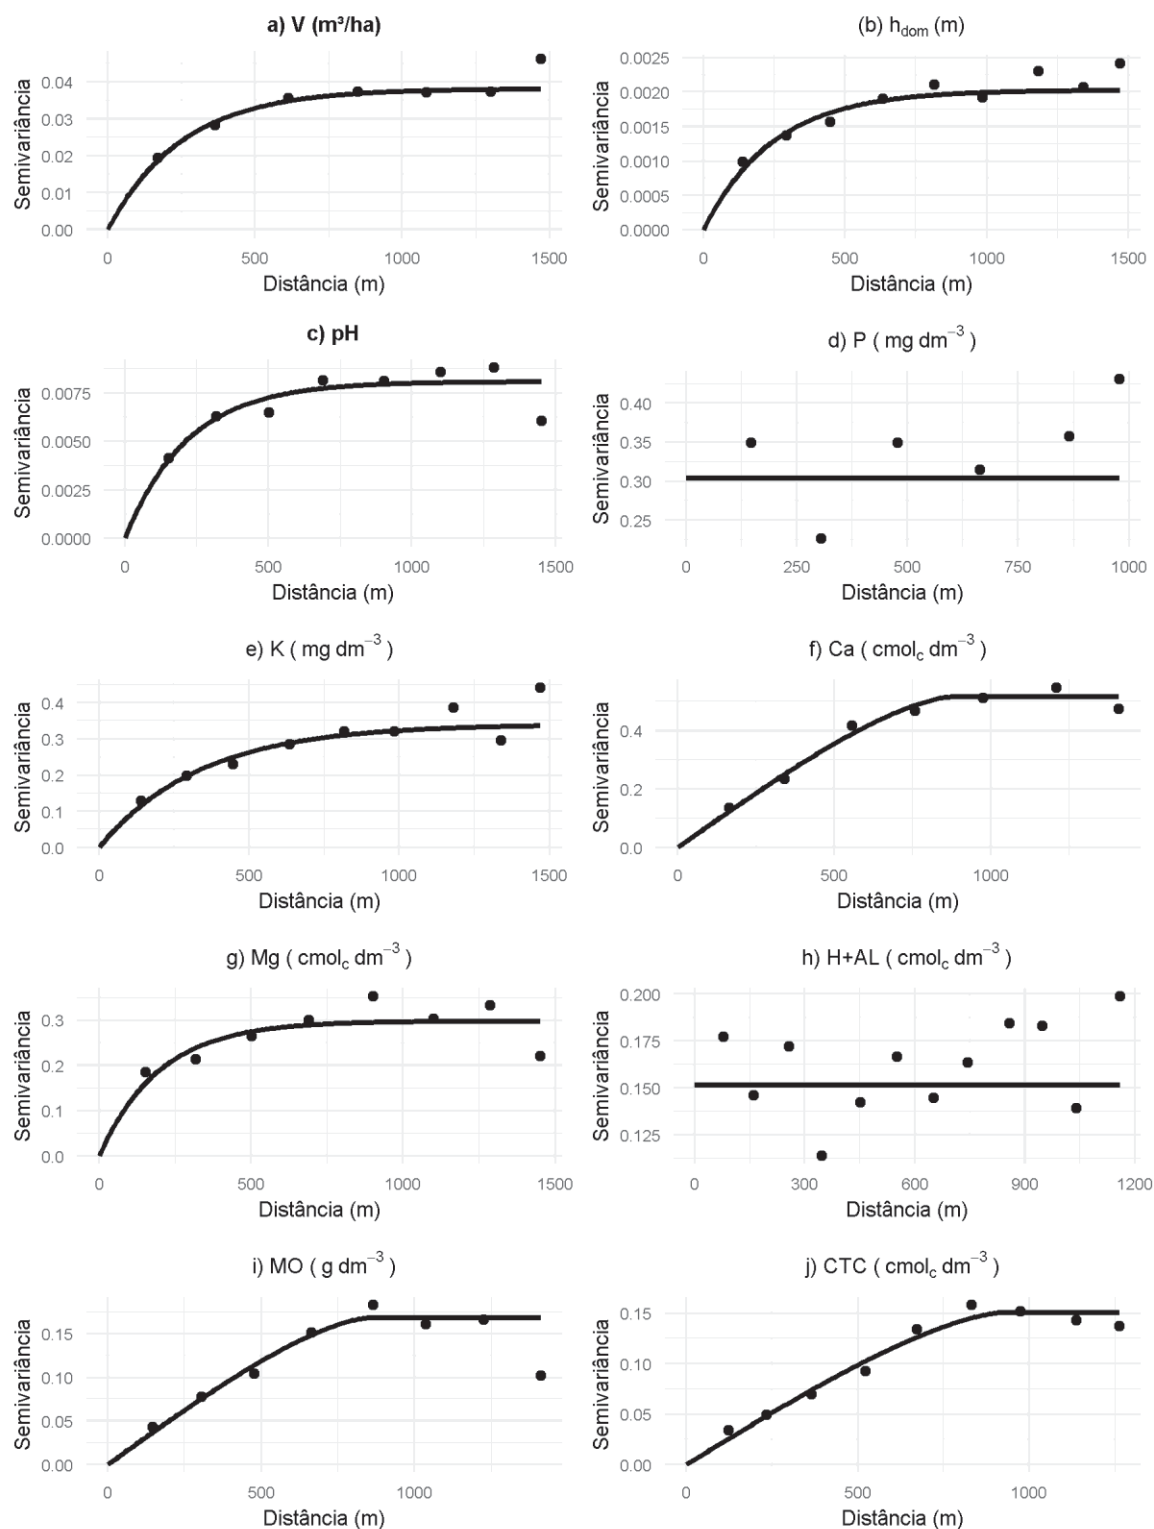
Fonte: O autor (2023)

Para os alcances estimados (*a*), o valor mínimo de 196 m foi para o Mg e o máximo de 922 m para o CTC (TABELA 3.3). As demais variáveis resultaram em alcances entre 218 e 868 m. A partir da validação cruzada, com o uso de krigagem ordinária foi possível gerar previsões com valores baixos para os erros médios de estimação, especialmente pelas medidas de erro médio em porcentagem (MPE) e raiz quadrada do erro médio quadrático em porcentagem (RMSE%). Para as variáveis Ca e Mg foram obtidos os maiores erros, com RMSE% superiores a 15%. Além disso, a correlação linear entre os valores estimados e observados (*r<sub>xx</sub>*) foi forte para as variáveis Ca, MO e CTC, e moderada para as variáveis V, pH, K e Mg. Ademais, com o BIAS foi constatada a ausência de tendências de super ou subestimativas para as variáveis que apresentaram ajustes.

Analisando os semivariogramas ajustados (FIGURA 3.3), observou-se que para as variáveis P e H+Al há ausência de dependência espacial, em que o comportamento de efeito pepita puro foi constatado. Além disso, notou-se dispersão reduzida das semivariâncias observadas em torno da linha média estimada para a maioria das variáveis, com exceção de h<sub>dom</sub>, K e Mg. A qualidade dos ajustes pode

ser evidenciada pela estabilização das semivariâncias em torno de uma distância máxima definida pelo alcance ( $\alpha$ ).

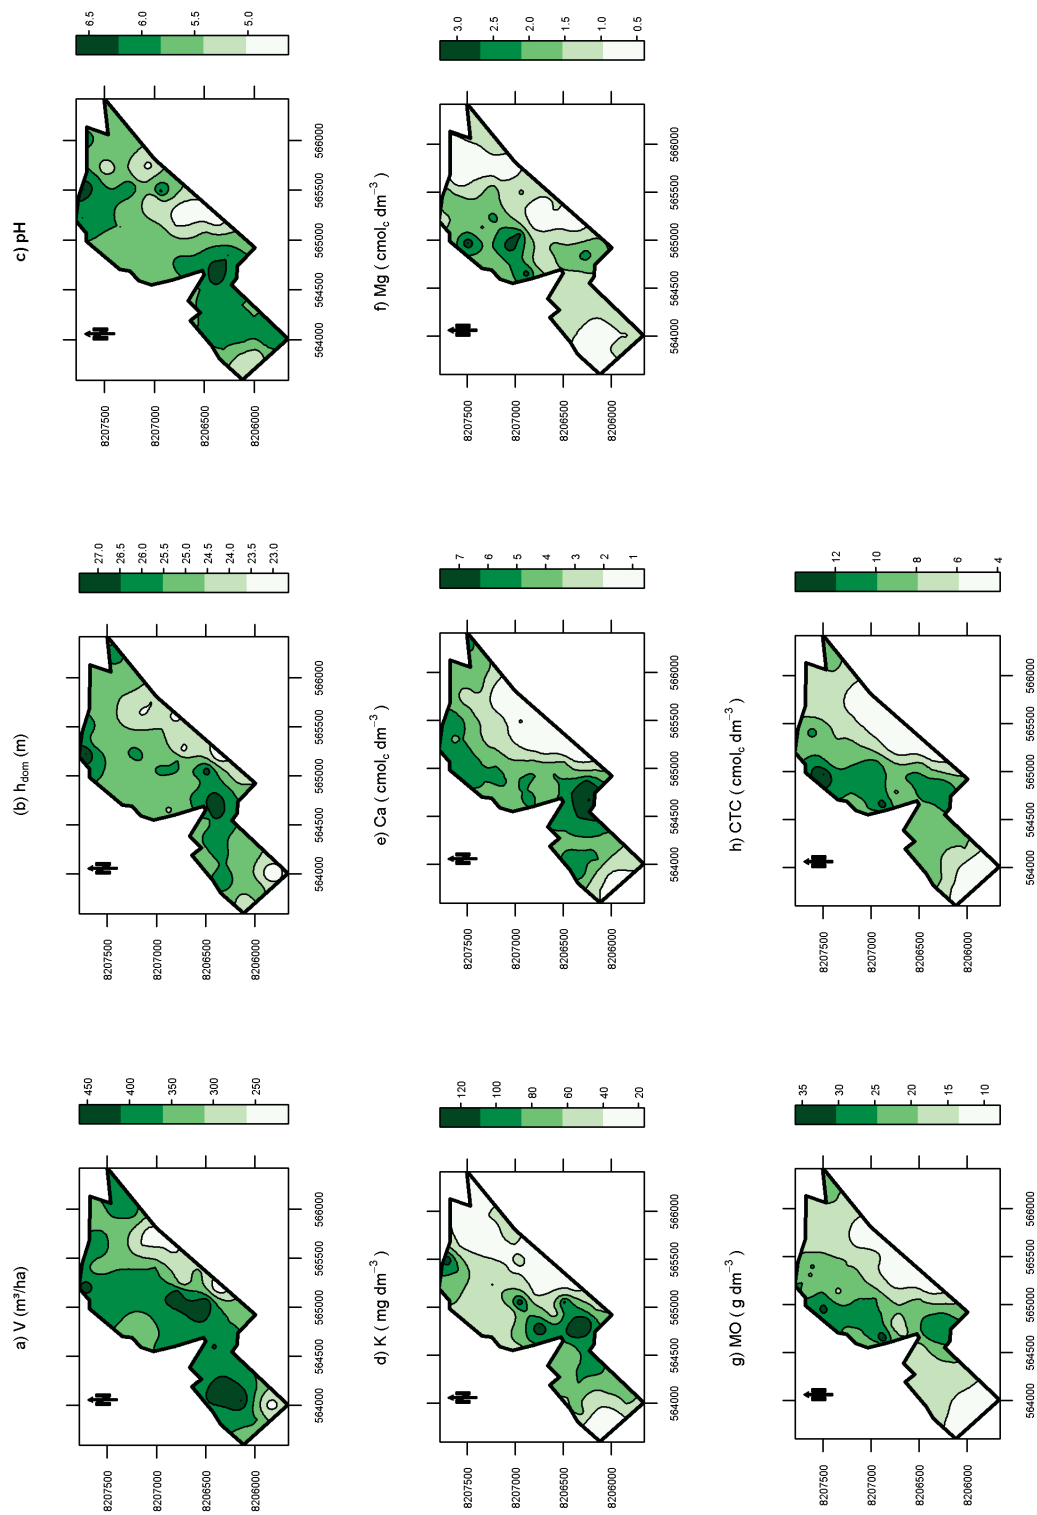
FIGURA 3.3 – SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO E DOS ATRIBUTOS QUÍMICOS DO SOLO.



FONTE: O autor (2023).

Após os ajustes dos semivariogramas e constatada a dependência espacial entre as amostras, os valores das variáveis foram interpolados por meio da krigagem ordinária e confeccionada a distribuição espacial do V e da  $h_{dom}$  (FIGURA 3.4). De maneira geral, para as variáveis foram obtidos padrões espaciais semelhantes entre si (FIGURA 3.4), no qual, na região norte e oeste estão os maiores valores, enquanto no Leste, os menores. No entanto, para os atributos químicos do solo e para  $h_{dom}$ , os menores valores estão na região sudoeste da área do povoamento florestal.

FIGURA 3.4 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO E DOS ATRIBUTOS QUÍMICOS DO SOLO.



FONTE: O autor (2023).

### 3.3.3 Cokrigagem ordinária

A partir do ajuste dos semivariogramas cruzados, foi possível observar correlação entre as variáveis  $V$  e  $h_{dom}$  com os atributos químicos do solo, com exceção de  $P$  e  $H+Al$ , onde foi observado efeito pepita puro (TABELA 3.4). Para a variável  $V$ , houve melhor ajuste com o modelo gaussiano, bem como pouca variação do parâmetro alcance, de 396 a 490 m, sendo indicativo de elevada homogeneidade nas estruturas espaciais dessa variável. Nos semivariogramas cruzados da variável  $V$ , foi constatada maior dispersão dos valores observados em torno da linha média, principalmente para as variáveis  $pH$ ,  $Mg$ ,  $MO$  e  $CTC$  (FIGURA 3.5).

Para a variável  $h_{dom}$ , houve predominância de melhor ajuste, para a maioria das variáveis, com o modelo gaussiano (TABELA 3.4), e para  $pH$  e  $K$ , o melhor ajuste foi com o modelo exponencial. Os alcances, com variação de 331 a 484 m, também foram associados à elevada homogeneidade espacial dessas variáveis. Nos semivariogramas cruzados da  $h_{dom}$  com  $pH$  e  $K$ , foi observada maior dispersão dos valores observados em torno da linha média, além da ausência de estabilização da semivariância em torno da distância máxima atribuída de 1.200 m (FIGURA 3.6).

TABELA 3.4 – PARÂMETROS DOS SEMIVARIOGRAMAS CRUZADOS AJUSTADOS PARA A VARIÁVEL DO POVOAMENTO EM FUNÇÃO DOS ATRIBUTOS QUÍMICOS DO SOLO.

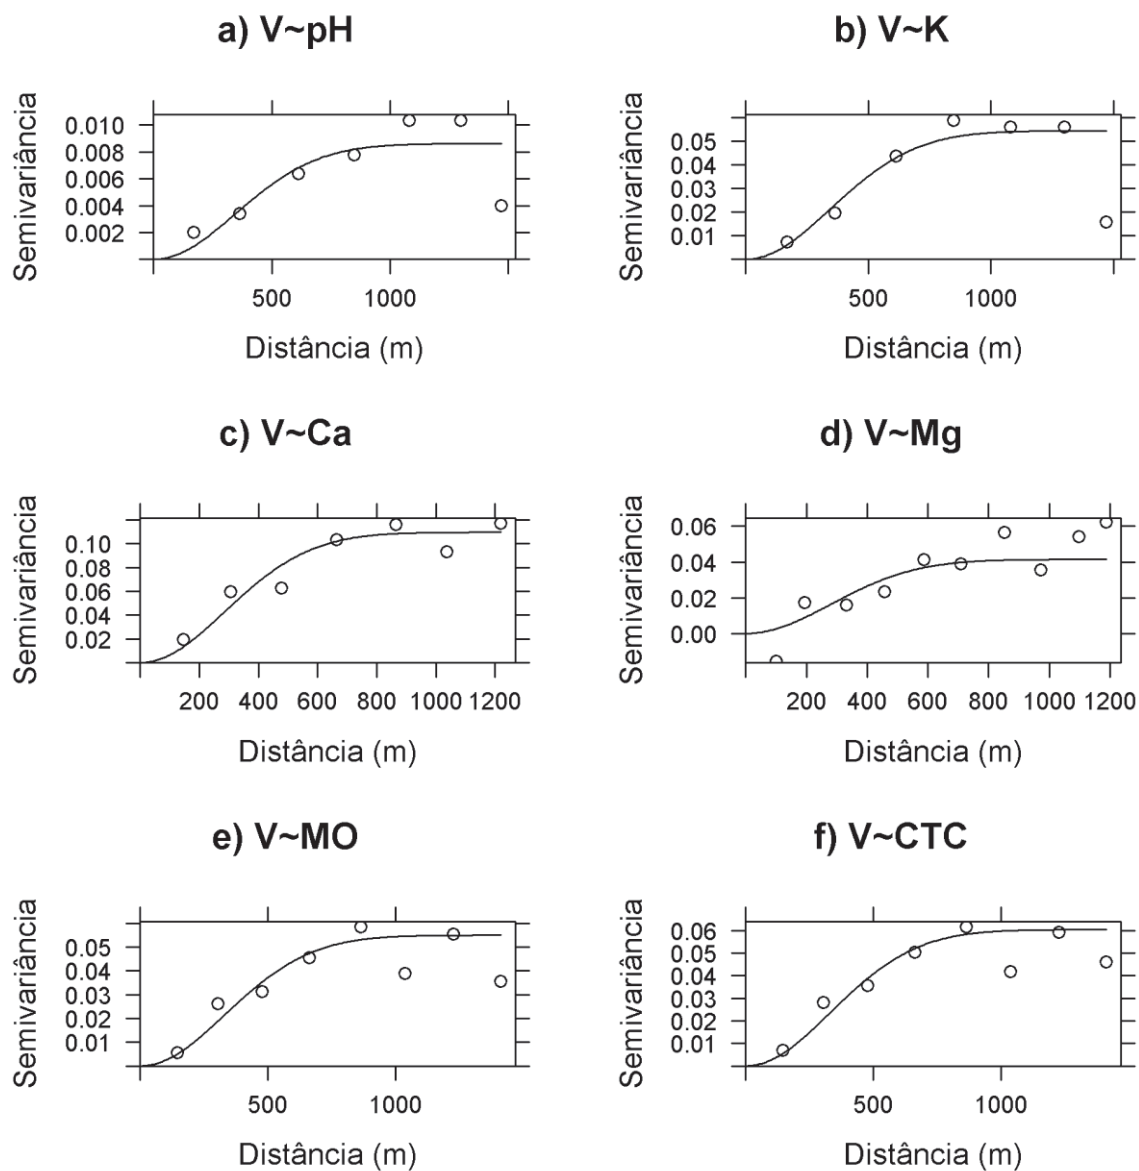
Variável primária	Variável secundária	Modelo	$C_0+C$	$a$
$V$	$pH$	Gaussiano	0,0086	490
$V$	$K$	Gaussiano	0,0544	490
$V$	$Ca$	Gaussiano	0,1095	406
$V$	$Mg$	Gaussiano	0,0414	396
$V$	$MO$	Gaussiano	0,0550	470
$V$	$CTC$	Gaussiano	0,0603	470
$h_{dom}$	$pH$	Exponencial	0,0029	484
$h_{dom}$	$K$	Exponencial	0,0171	384
$h_{dom}$	$Ca$	Gaussiano	0,0274	470
$h_{dom}$	$Mg$	Gaussiano	0,0095	331
$h_{dom}$	$MO$	Gaussiano	0,0110	340
$h_{dom}$	$CTC$	Gaussiano	0,0121	406

$C_0+C$  = patamar; e  $a$  = alcance (m).

Fonte: O autor (2023)

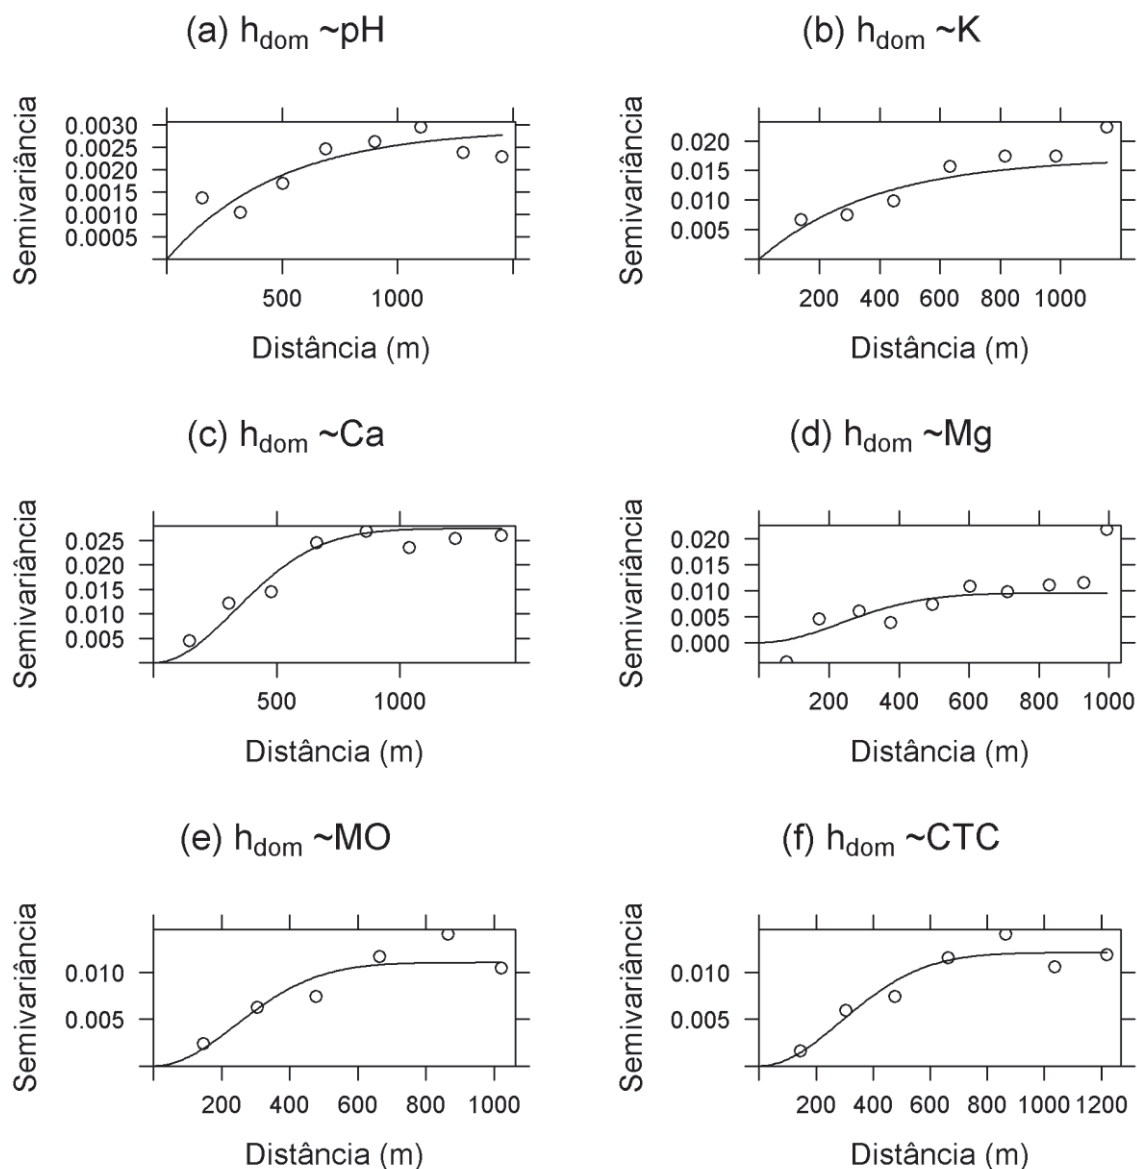


FIGURA 3.5 – SEMIVARIÓGRAMAS CRUZADOS AJUSTADOS PARA A VARIÁVEL VOLUME DO POVOAMENTO EM FUNÇÃO DOS ATRIBUTOS QUÍMICOS DO SOLO.



FONTE: O autor (2023).

FIGURA 3.6 – SEMIVARIOGRAMAS CRUZADOS AJUSTADOS PARA A VARIÁVEL ALTURA DOMINANTE EM FUNÇÃO DOS ATRIBUTOS QUÍMICOS DO SOLO.



FONTE: O autor (2023).

### 3.3.4 Regressão por Componentes Principais

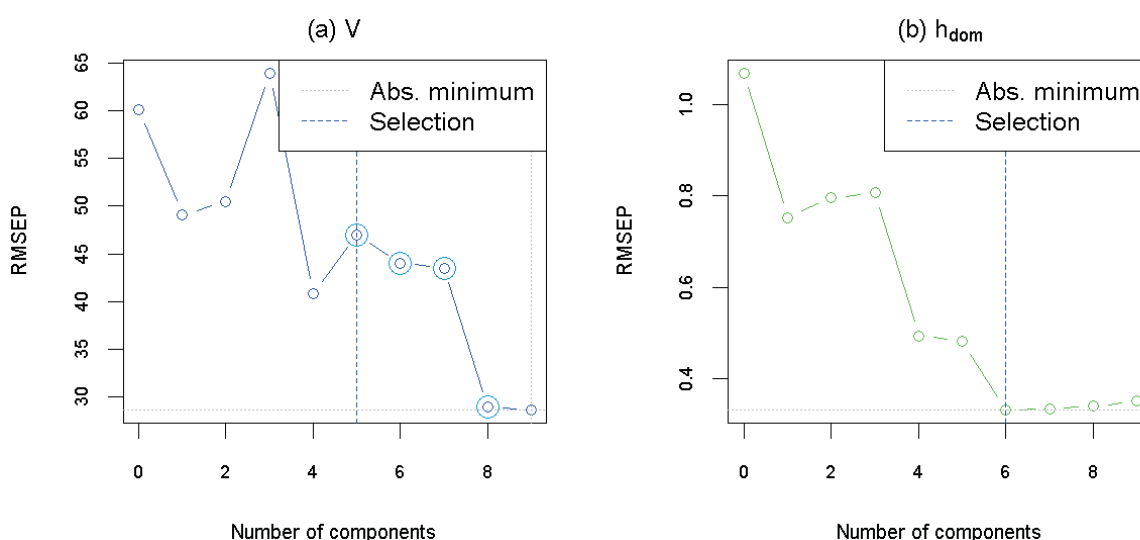
A PCR foi realizada com nove variáveis para V e  $h_{\text{dom}}$  (TABELA 3.5). Para a variável V, o primeiro componente principal (PC1) está associado à explicação de 37,4% da variabilidade total, em que, a partir da quarta componente principal, houve aumento expressivo, 70,4%, na explicação dessa variabilidade. A estimativa de ambas as variáveis V e  $h_{\text{dom}}$  foi ótima com a utilização de seis componentes principais, com os resultados do método de aleatorização (FIGURA 3.7).

TABELA 3.5 – PERCENTUAL DE VARIÂNCIA ACUMULADA EXPLICADA DAS VARIÁVEIS DO POVOAMENTO POR COMPONENTES PRINCIPAIS

Variável	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9
	Variância (%)								
V	37,44	37,45	39,05	70,40	72,94	76,56	79,09	83,65	84,74
$h_{dom}$	53,35	57,31	57,54	84,50	84,96	93,09	93,15	93,18	93,18

FONTE: O autor (2023).

FIGURA 3.7 – NÚMERO DE COMPONENTES PRINCIPAIS SELECIONADOS PARA VARIÁVEIS DO POVOAMENTO EM FUNÇÃO DOS ATRIBUTOS QUÍMICOS DO SOLO




FONTE: O autor (2023).

Para a estimativa da variável  $h_{dom}$ , a PC1 está associada a 53,35% da variabilidade total, em que, a partir do quarto componente principal, ocorreu aumento para 84,50% na explicação da variabilidade (TABELA 3.5). Houve tendência na estabilização da variabilidade explicada de  $h_{dom}$ , em torno de 93%, a partir do sexto componente principal.

Com o teste VIF foi evidenciada a ocorrência de elevado grau de multicolinearidade ( $VIF > 10$ ) entre as variáveis explicativas Ca, Mg, H+Al e CTC, com valores de 4270,9, 770,0, 1412,6 e 9479,8, respectivamente. Observando os gráficos de resíduos (FIGURA 3.8), foi possível concluir que, para a estimativa de V e  $h_{dom}$ , não houve tendências aparentes na distribuição residual.

FIGURA 3.8 – DISTRIBUIÇÃO DOS RESÍDUOS PERCENTUAIS PARA ESTIMATIVA DAS VARIÁVEIS DO POVOAMENTO POR MEIO DOS COMPONENTES PRINCIPAIS SELECIONADOS.



FONTE: O autor (2023).

As estimativas da variável volume do povoamento ( $V$ ), por meio dos seis primeiros componentes principais, resultaram em coeficiente de determinação ( $R^2$ ) de 0,875, bem como valores de raiz quadrada do erro médio quadrático absoluto (RMSE) e percentual (RMSE%) de  $28,475 m^3 ha^{-1}$  e 7,9%, respectivamente. Para a variável altura dominante ( $h_{dom}$ ), as medidas de qualidade do ajuste, igualmente para os seis primeiros componentes principais, foram  $R^2$  de 0,965, RMSE de 0,275 m e RMSE% de 1,1%.

De acordo com a metodologia da PCR, foram selecionados os maiores valores de coeficiente, em módulo, para cada um dos componentes principais, sendo denominados de autovetores. Para a variável  $V$ , na PC1 foram selecionadas as variáveis CTC, MO e CA como as de maiores autovetores (TABELA 3.6), sendo que essa componente isoladamente foi associada à explicação de 37,45%. Observou-se na PC2, as mesmas variáveis (CTC, MO e CA), bem como o mesmo percentual explicativo (TABELA 3.4). Na PC3, a variável pH foi adicionada, aumentando o percentual de explicação da variabilidade para 39,05%. Em seguida, na PC4, com as variáveis DAP e Mg de maiores autovetores, o percentual explicativo aumentou para 70,4%. Na última componente principal selecionada, a PC6, ocorreu o acréscimo da variável P, em que o percentual explicativo incrementou para 76,06.

Para a variável  $h_{dom}$ , na PC1 foram selecionadas as variáveis CTC, MO e Ca como as de maiores autovetores (TABELA 3.6), cuja componente principal foi

associada à explicação de 53,35% da variabilidade. Com as variáveis pH e K no PC2, o percentual da variabilidade explicada aumentou para 57,31%. Na PC3, manteve-se as variáveis pH, K e Ca como as de maiores autovetores, com a estabilidade no percentual explicativo de 57,54%. Na PC4, com a inclusão das variáveis DAP e Mg, houve aumento do percentual da variabilidade explicada para 84,50%. Em seguida, na última componente principal, PC6, com a variável P houve incremento no percentual explicativo para 93,09%.

TABELA 3.6 – COEFICIENTES DE REGRESSÃO PARA ESTIMATIVA DAS VARIÁVEIS DO POVOAMENTO POR MEIO DOS COMPONENTES PRINCIPAIS SELECIONADOS.

Variável	PC1	PC2	PC3	PC4	PC5	PC6
Volume do povoamento						
DAP	5,748	5,731	5,119	33,721	36,407	50,652
pH	5,118	5,065	8,364	-3,703	-2,861	-1,755
P	1,963	1,904	-5,618	-9,814	-7,384	-12,343
K	5,698	5,677	5,024	6,921	-5,767	-5,622
Ca	6,835	6,817	9,261	16,141	18,606	7,122
Mg	5,645	5,679	4,440	-20,617	-19,932	-7,961
H_AL	2,022	2,103	-0,442	8,340	6,676	1,951
MO	6,861	6,887	6,661	1,417	4,946	2,737
CTC	7,123	7,151	7,445	8,488	9,360	3,324
Altura dominante						
DAP	0,122	0,141	0,137	0,608	0,629	1,008
pH	0,109	0,170	0,192	-0,007	0,000	0,029
P	0,042	0,109	0,058	-0,011	0,008	-0,125
K	0,121	0,145	0,141	0,172	0,076	0,080
Ca	0,145	0,166	0,182	0,296	0,314	0,009
Mg	0,120	0,081	0,073	-0,340	-0,335	-0,016
H_AL	0,043	-0,049	-0,066	0,078	0,066	-0,060
MO	0,146	0,115	0,113	0,027	0,054	-0,005
CTC	0,151	0,120	0,122	0,139	0,146	-0,015

FONTE: O autor (2023)

### 3.4 DISCUSSÃO

O presente estudo objetivou investigar o potencial de aprimoramento na precisão nas estimativas de produção, pelo volume do povoamento ( $V$ ) de *T. grandis* e do sítio, dado pela altura dominante ( $h_{dom}$ ), por meio da inclusão de atributos químicos do solo como variáveis auxiliares no contexto das modelagens estatísticas e espaciais, os quais exibiram níveis moderados de correlação e padrões espaciais similares aos observados para alguns atributos químicos do solo. Para a variável  $V$ , a correlação linear foi moderada com as variáveis  $Ca$ ,  $CTC$  e  $MO$ , enquanto para a variável  $h_{dom}$ , a correlação foi forte com o  $Ca$ , bem como moderada com a  $CTC$ , o  $K$ , a  $MO$  e o  $pH$ .

Na literatura, observa-se que a *T. grandis* tem uma elevada necessidade por  $Ca$ , respondendo significativamente à adição deste nutriente ao solo (KAOSA-ARD, 1989; WATANABE *et al.*, 2010). Em geral, os melhores sítios para *T. grandis* estão associados a um teor de  $Ca$  no solo superior a  $10 \text{ cmolc dm}^{-3}$  para o primeiro horizonte (ALVARADO-HERNANDEZ *et al.*, 2014; MOLLINEDO *et al.*, 2005; VÁSQUEZ; UGALDE, 1996). O teor médio de  $Ca$  neste estudo foi de  $3,78 \text{ cmolc dm}^{-3}$  (TABELA 2), variando entre 1 e  $7 \text{ cmolc dm}^{-3}$  (FIGURA 4), o que está abaixo do limite crítico estabelecido. Resultados diferentes foram encontrados por Fernandez-Moya *et al.*, (2013), que analisaram a fertilidade de 23 áreas distintas de teca na América Central, e registraram média de  $13,22 \text{ cmolc dm}^{-3}$  para o  $Ca$ . Em comparação com o trabalho de Rosa *et al.* (2015), que identificaram valores médios de  $Ca$  de  $0,5 \text{ cmolc dm}^{-3}$  em uma área de teca em Mato Grosso, as concentrações de  $Ca$  no solo neste estudo são superiores. Considerando a deficiência desse nutriente no solo e que o atual ciclo de plantio está próximo do período final de rotação, é aconselhável realizar a reposição de  $Ca$  para futuros plantios.

Com relação ao  $K$ , o valor médio encontrado foi de  $58,7 \text{ mg dm}^{-3}$ , variando entre 20 e  $120 \text{ mg dm}^{-3}$ , acima do valor limítrofe considerado por Kollert e Kleine, (2017) de 15 a  $40 \text{ mg dm}^{-3}$ . O  $K$  está envolvido nas atividades enzimáticas do metabolismo das plantas, como na formação dos açúcares e dos amidos, além de proporcionar maior vigor e resistência às doenças e a seca (ABOD; SIDDIQUI, 2002; PELISSARI *et al.*, 2014).

A CTC variou de 4 a 12  $\text{cmolc dm}^{-3}$ , com média de 7,9  $\text{cmolc dm}^{-3}$ , valor classificado como adequado (de 4 a 10  $\text{cmolc dm}^{-3}$ ), segundo Kollert e Kleine (2017) para o desenvolvimento da *T. grandis*. O solo é considerado adequado para a nutrição das plantas, quando maior parte da CTC está ocupada por cátions essenciais como Ca, Mg e K. Por outro lado, a fertilidade do solo é considerada baixa, caracterizado pela escassez de nutrientes, se grande parte da CTC estiver ocupada por cátions potencialmente tóxicos, como H e Al (RONQUIM, 2010). A relação da CTC com os elementos Ca, Mg e K, pode ser observada pela distribuição espacial das variáveis (FIGURA 4), onde há maiores valores de CTC há também ocorrência dos maiores teores desses elementos.

A MO variou de 8 a 36  $\text{g dm}^{-3}$ , com média de 18,3  $\text{g dm}^{-3}$  (FIGURA 4), um valor que é considerado baixo, de acordo com Ribeiro et al. (1999). A MO exerce influência nos atributos físicos, químicos e biológicos do solo, e impacta a eficiência nutricional ao melhorar a taxa de infiltração da água, aumentar a disponibilidade de oxigênio, promover a melhor agregação de partículas e aumentar a microporosidade do solo (BASSO *et al.*, 2017). Características físicas mais favoráveis do solo, como solos de textura média, estão associadas ao melhor desenvolvimento da teca, uma vez que a aeração beneficia o crescimento das raízes e, por conseguinte, das árvores (WEHR; SMITH; MENZIES, 2017). Os baixos valores de MO provavelmente estão associados a uma degradação do carbono do solo superior ao acúmulo e ao aumento da mineralização da MO. Esse fenômeno pode ser atribuído ao fato de que a superfície do solo em povoamento florestais, após desbastes, fica mais exposta aos efeitos diretos da radiação solar e chuva (ALMEIDA; JÚNIOR; FINGER, 2010; PELISSARI; CALDEIRA; DOS SANTOS, 2014), bem como devido ao efeito da deciduidade foliar da *T. grandis* em povoamentos seminais, cujas copas das árvores perdem as folhas anualmente (REIS; OLIVEIRA; SANTOS, 2023).

O valor médio de P foi de 2,32  $\text{mg dm}^{-3}$ , considerado limítrofe para Kollert e Kleine (2017), que consideram a faixa entre 5 e 10  $\text{cmolc dm}^{-3}$  como valores ótimos de fósforo. Os baixos valores de P podem estar associados à idade do plantio, uma vez que a maior absorção e retenção desse elemento ocorre durante a fase juvenil para o desenvolvimento e formação do sistema radicular da espécie (MÁRQUEZ *et al.*, 1993; PELISSARI; CALDEIRA; DOS SANTOS, 2014).

O pH médio do solo foi de 5,7, com variação de 5,0 a 6,5, ou seja, os solos são levemente ácidos para a espécie. Apesar do melhor crescimento da *T. grandis* ocorrer em solos com pH situado entre 6,5 e 7,5 (GIL *et al.*, 2018), na análise da distribuição espacial do pH (FIGURA 4) foi observado que em solos com níveis superiores a 5,5 estão os valores mais elevados das variáveis V e hdom, que representam a produção e produtividade do povoamento, respectivamente. Esse resultado é condizente com o trabalho de Barbosa *et al.*, (2012), os quais concluíram que, do ponto de vista espacial, a produtividade de madeira pode ser estimada por meio do pH do solo.

Com os semivariogramas cruzados, ficou provado que a cokrigagem ordinária foi adequada para relacionar variáveis do povoamento com covariáveis, os atributos químicos do solo. Com isso, é possível a predição dos padrões espaciais do povoamento de *T. grandis* por meio do uso dessas covariáveis como informação auxiliar, uma vez que possibilitam estimativas mais adequadas em locais não medidos (PELISSARI *et al.*, 2017).

De maneira geral, as regiões central e noroeste do plantio de *T. grandis* estão os valores mais elevados para as variáveis volume do povoamento e altura dominante. Esses padrões exibiram similaridade com as distribuições espaciais observadas nos atributos químicos do solo, exceto para o Mg e K, com os maiores valores nas regiões noroeste e central, respectivamente. Nas regiões Leste e Sudoeste foram registrados os valores mais baixos para as variáveis V, hdom, e para os atributos químicos do solo.

Tais resultados são atribuídos à influência da qualidade de sítio, que se manifesta de forma mais favorável onde as variáveis do povoamento apresentam maiores valores (PELISSARI *et al.*, 2015). Essa associação pode ser corroborada pelos maiores valores de Ca e pH encontrados nas regiões central e noroeste, os quais são indicadores potenciais da qualidade do solo (KAOSA-ARD, 1989; KUMAR, 2005; LIMA *et al.*, 2010). Considerando as distintas condições edáficas do povoamento, evidenciada pelas distribuições espaciais dos atributos químicos do solo, é possível estabelecer zonas específicas para o manejo da fertilidade do solo. Com essa abordagem é possível a otimização do uso de insumos, uma vez que a aplicação de fertilizantes com precisão e em taxas variáveis propicia a diminuição de custos, redução dos impactos ambientais pelo uso da quantidade ideal de nutrientes, além de



homogeneizar a fertilidade do solo (CARVALHO *et al.*, 2012; GIL *et al.*, 2018; MACEDO NETO *et al.*, 2020; PELISSARI, 2012; PELISSARI; CALDEIRA; DOS SANTOS, 2014).

Foi observada elevada similaridade na distribuição espacial das variáveis V e hdom em relação aos atributos químicos do solo. O fato tem respaldo em descobertas anteriores, conforme documentado por Pelissari *et al.*, (2012), os quais apontaram para um aumento nas correlações entre os atributos químicos do solo, o DAP e a altura das árvores à medida que a plantação envelhece. Os autores ressaltaram que, na fase inicial do ciclo de crescimento, o desenvolvimento da floresta está mais intimamente associado às práticas de implantação, tais como preparo do solo e espaçamento utilizado. Segundo Basso *et al.*, (2017), durante o período de estabelecimento do plantio, a demanda por nutrientes por parte das árvores é relativamente menor, aumentando somente após a completa adaptação, momento em que ocorre um significativo acúmulo de nutrientes, com taxas de absorção elevadas, correlacionadas diretamente com a idade das árvores.

Nas áreas com maiores quantidades de Ca, K e pH foi observada correlação positiva com os valores de V e hdom de *T. grandis*. Nos mapas de variabilidade espacial foi possível evidenciar essa associação, destacando a relevância desses nutrientes para a produtividade e a produção nessa cultura. Silva *et al.*, (2019) obtiveram resultados similares ao avaliarem a produtividade de *Pinus sp.* e suas relações com atributos químicos do solo, e concluíram que o K, além de apresentar dependência espacial, é o melhor indicador para a estimativa da produtividade de *Pinus*. Gil *et al.*, (2018), ao compararem mapas de distribuição espacial de Ca e pH, observaram que os melhores locais para o plantio de *T. grandis* estão nas regiões com alta concentração de Ca e pH.

A precisão da análise de regressão por componentes principais é evidenciada pela qualidade do ajuste, considerados os elevados valores de  $R^2$  e baixos valores de RMSE%, bem como pela distribuição nos gráficos dos resíduos, onde não foram observadas tendências de sub ou superestimativa das variáveis V e hdom. Adicionalmente, com a aplicação da PCR foi identificada a importância dos elementos Ca, CTC, MO, Mg e a variável DAP (diâmetro a altura do peito) como componentes de maior contribuição significativa na variabilidade da produtividade e da produção dessas variáveis.

### 3.5 CONCLUSÃO

Existe correlação e dependência espacial entre as variáveis de produção e de produtividade do sítio com os atributos químicos do solo em povoamento de *T. grandise* que podem ser utilizados como covariáveis na modelagem geoestatística.

A regressão por componentes principais permite a predição das variáveis do povoamento, a partir das componentes principais, reduzindo a multicolinearidade e a dimensão dos dados.

## REFERÊNCIAS

- ABOD, S. A. L. I. SIDDIQUI, M. T. Growth Response of Teak (*Tectona grandis* L. f.) Seedlings to Nitrogen, Phosphorus and Potassium Fertilizers. **Pertanika J Trop Agric Sci**, v. 25, p. 107–113, 2002.
- ALMEIDA, E. M. JÚNIOR, J. H. C.; FINGER, Z. Determinação do estoque de carbono em teca (*Tectona grandis* L. F.) em diferentes idades. **Ciência Florestal**, v. 20, n. 4, p. 559–568, 2010.
- ALVARADO-HERNANDEZ, A. *et al.* Nutrient Management Improvements in Forestry Species. **Better Crops with plant food**, v. 98, n.4, p. 16-18, 2014.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2014.
- BARBOSA, C. E. M. *et al.* Inter-relação da produtividade de madeira do pinus com atributos físico-químicos de um latossolo do cerrado brasileiro. **Revista Árvore**, v. 36, n. 1, p. 25–35, 2012.
- BASSO, S. *et al.* Correlação entre atributos químicos do solo e variáveis produtivas de teca. **Nativa**, v. 5, p. 642–648, 2017.
- CLAESSEN, M. E. C. **Manual de Métodos de Análise de Solo**. Rio de Janeiro: EMBRAPA-CNPQ, 1997.
- DOLÁCIO, C. J. F. *et al.* Does using soil chemical variables in cokriging improve the spatial modelling of the commercial wood volume of Brazilian mahogany in an Amazonian agroforestry system? **Computers and Electronics in Agriculture**, v. 180, p. 105891, 2021.
- CARVALHO, M. P. *et al.* Produtividade de madeira do eucalipto correlacionada com atributos do solo visando ao mapeamento de zonas específicas de manejo. **Ciência Rural**, v. 42, n. 10, p. 1797–1803, 2012.
- FEBRERO-BANDE, M.; GALEANO, P.; GONZÁLEZ-MANTEIGA, W. Functional Principal Component Regression and Functional Partial Least-squares Regression: An Overview and a Comparative Study. **International Statistical Review**, v. 85, n. 1, p. 61–83, 2017.
- FERNANDEZ-MOYA, J. *et al.* Nutrient concentration age dynamics of teak (*Tectona grandis* L.f.) plantations in Central America. **Forest Systems**, v. 22, n. 1, p. 123–133, 2013.
- FERNÁNDEZ-MOYA, J. *et al.* Nutrient accumulation and export in teak (*Tectona grandis* L. f.) plantations of Central America. **IForest – Biogeosciences and Forestry**, v. 8, n. 1 p. 33–44, 2015.

GIL, R. L. *et al.* Modelling spatial variability of soil chemical attributes in *Tectona grandis* stands in central-west Brazil. **Journal of Tropical Forest Science**, v. 30, n. 3, p. 376–383, 2018.

JOLLIFFE, I. T. A Note on the Use of Principal Components in Regression. **Applied Statistics**, v. 31, n. 3, p. 300, 1982.

KAOSA-ARD, A. Teak its natural distribution and related factors. **Nat His Bull Siam Soc**, v. 29, p. 55–74, 1989.

KARAHAN, G.; ERŞAHIN, S. Geostatistics in characterizing spatial variability of forest ecosystems. **Eurasscience Journals Eurasian Journal of Forest Science**, v. 6, n. 1, p. 9–22, 2018.

KEITHLEY, R. B.; HEIEN, M. L.; WIGHTMAN, R. M. Multivariate concentration determination using principal component regression with residual analysis. **TrAC - Trends in Analytical Chemistry**, v. 28, n. 9, p. 1127–1136, 2009.

KOLLERT, W.; KLEINE, M. **The Global Teak Study. Analysis, Evaluation and Future Potential of Teak Resources**. v. 36, 2017.

BHAT, K. M *et al.* Quality Timber Products of Teak from Sustainable Forest Management. In: KUMAR, B. M. **Sustainable teak plantations in the tropics: the question of nutrient management. Kerala - India, 2005. p.179-187.**

LIMA, C. G. da R. *et al.* Atributos físico-químicos de um Latossolo do Cerrado brasileiro e sua relação com características dendrométricas do eucalipto. **Revista Brasileira de Ciência do Solo**, v. 34, n. 1, p. 163–173, 2010.

MACEDO NETO, A. A. L. *et al.* Diagnosis and spatial variability of soil fertility and crop production in a teak area in Eastern Pará State. **Cerne**, v. 26, n. 1, p. 37–47, 2020.

MÁRQUEZ, O. *et al.* Cambios en las propiedades físico-químicas de los euslos en una cronosecuencia de *Tectona grandis*. **Turrialba**, v. 43, n. 1, p. 37–41, 1993.

MEVIK, B.-H.; WEHRENS, R. (2022) pls: Introduction to the pls Package in R. R package version X.X.X. <https://cran.r-project.org/web/packages/pls/vignettes/pls-manual.pdf>

MIRANDA NETO, A. *et al.* Silvicultura de precisão: aplicações e implicações. **Revista Instituto Florestal**, v. 24, n. 2, p. 211–223, 2012.

MOLLINEDO, M. *et al.* Relación suelo-planta, factores de sitio y respuesta a la fertilización, en plantaciones jóvenes de teca (*Tectona grandis* L. f.), en la zona Oeste, Cuenca del canal de Panamá. **Agronomía Costarricense**, v. 29, n. 1, p. 10, 2005.

OLEA, R. A. **Geostatistics for engineers and earth scientists**. Springer Science & Business Media, 2012.

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

PEBESMA, E. J. Multivariable geostatistics in S: the gstat package. **Computers & Geosciences**, v. 30, n. 7, p. 683–691, ago. 2004.

PELISSARI, A. L. *et al.* Correlação espacial dos atributos químicos do solo com o desenvolvimento da teca em Mato Grosso. **Pesquisa Florestal Brasileira**, v. 32, n. 71, p. 247–256, 2012.

PELISSARI, A. L. *et al.* Geoestatística aplicada ao manejo de povoamentos florestais de teca, em períodos pré-desbaste seletivo, no estado do Mato Grosso. **Revista Brasileira de Biomassa**, v. 32, n. 3, p. 430–444, 2014.

PELISSARI, A. L. *et al.* Geostatistical modeling applied to spatiotemporal dynamics of successional tree species groups in a natural Mixed Tropical Forest. **Ecological Indicators**, v. 78, p. 1–7, 2017.

PELISSARI, A. L. *et al.* GEOSTATISTICAL MODELING OF TIMBER VOLUME SPATIAL VARIABILITY FOR *Tectona grandis* L. f. PRECISION FORESTRY. **CERNE**, v. 23, n. 1, p. 115–122, 2017.

PELISSARI, A. L. *et al.* Propostas de mapeamentos da capacidade produtiva de sítios florestais por meio de análises geoestatísticas. **Scientia Forestalis**, v. 43, n. 107, p. 601–608, 2015.

PELISSARI, A. L. Silvicultura de precisão aplicada ao desenvolvimento de *Tectona grandis* L. f. na região sul do Estado de Mato Grosso. 2012. 78 f. Dissertação (Mestrado em Ciências Florestais e Ambientais) – Universidade Federal do Mato Grosso.

PELISSARI, A. L.; CALDEIRA, S. F.; SANTOS, V. S. DOS. Variabilidade espacial dos atributos químicos do solo em povoamento de *Tectona grandis*. **Cerne**, v. 20, n. 3, p. 377–384, 2014.

PFUTZ, I. F. P. *et al.* Geostatistical modeling of below- And above-ground carbon stocks of teak stands at different ages. **Journal of Tropical Forest Science**, v. 33, n. 2, p. 105–112, 2021.

PIMENTEL-GOMES, F. **Curso de Estatística Experimental**. 15. ed. Piracicaba: FEALQ, Digitaliza Conteúdo, 2023.

QIN, Q. *et al.* Spatial variability in the amount of forest litter at the local scale in northeastern China: Kriging and cokriging approaches to interpolation. **Ecology and Evolution**, v. 10 n. 2, p. 778–790, 2020.

R CORE TEAM (2023). **R: A language and environment for statistical computing**. **R Foundation for Statistical Computing**, Vienna, Austria. Available in: <https://www.R-project.org>.

REIS, C. A. F.; OLIVEIRA, E. B. de; SANTOS, A. M. **Teca (*Tectona grandis* L. F.) no Brasil**. 2023 – Brasília, DF: Embrapa, 2023.

RIBEIRO, A. C. GUIMARÃES, P. T. G.; ALVAREZ V. V. H. **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**, 5ª Aproximação. Viçosa: Comissão de Fertilidade do Solo do Estado de Minas Gerais, 1999.

RONQUIM, C. C. **Conceitos de fertilidade do solo e manejo adequado para as regiões tropicais**. Campinas, SP: Embrapa Monitoramento por Satélite, 2010.

ROSA FILHO, C. de D.; PARISI, S. A.; SOARES, W. de A. Avaliação da distribuição estatística e elaboração de modelo de regressão múltipla linear da velocidade média do vento. **Journal of Environmental Analysis and Progress**, v. 01, p. 24–36, 2018.

ROSA, T. de F. de D.; PEREIRA SCARAMUZZA, W. L. M.; DA SILVA, R. G. Concentração e acúmulo de nutrientes em povoamentos de teca no estado de Mato Grosso, Brasil. **Cerne**, v. 21, n. 1, p. 51–57, 2015.

SCHOBER, P.; BOER, C.; SCHWARTE, L. A. Correlation coefficients: Appropriate use and interpretation. **Anesthesia and Analgesia**, v. 126, n. 5, p. 1763–1768, 2018.

SILVA, R. S. DA *et al.* Desempenho Silvicultural de *Tectona grandis* L. f. em Diferentes Espaçamentos em Cáceres, MT. **Floresta e Ambiente**, v. 23, n. 3, p. 397–405, 2016.

SILVA, V. E. *et al.* Productivity of *Pinus caribaea* VAR. *Hondurensis* and its relations with chemical attributes of soils in the Brazilian Cerrado region. **Ciência Florestal**, v. 29, n. 1, p. 292–307, 2019.

TEWARI, V. P.; SINGH, B. A first-approximation simple dynamic growth model for forest teak plantations in Gujarat state of India. **Southern Forests: A Journal of Forest Science**, v. 80, n. 1, p. 59–65, 2018.

TOMPALSKI, P. *et al.* Estimating Changes in Forest Attributes and Enhancing Growth Projections: A Review of Existing Approaches and Future Directions Using Airborne 3D Point Cloud Data. **Current Forestry Reports**, v. 7, p. 1–24, 2021.

VÁSQUEZ, W.; UGALDE, L. Rendimiento y Calidad de Sitio para *Gmelina arborea*, *Bombacopsis quinatum* y *Pinus caribaea* en Guanacaste, Costa Rica. **Turrialba, C.R.: CATIE**, 1996. Relatório Técnico.

WATANABE, Y. *et al.* Teak (*Tectona grandis*) growth as influenced by soil physicochemical properties and other site conditions in Ashanti region, Ghana. **Journal of Food, Agriculture and Environment**, v. 8, n. 2, p. 1040–1045, 2010.

WEHR, J. B.; SMITH, T. E.; MENZIES, N. W. Influence of soil characteristics on teak (*Tectona grandis* L. F.) establishment and early growth in tropical Northern Australia. **Journal of Forest Research**, v. 22, n. 3, p. 153–159, 2017.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. Oficina de textos, 2013.

ZECH, W.; DRECHSEL, P. Relationships between growth, mineral nutrition and site factors of teak (*Tectona grandis*) plantations in the rainforest zone of Liberia. **Forest Ecology and Management**, v. 41, n. 3–4, p. 221–235, 1991.

ZHOU, Z. *et al.* Effects of calcium, boron and nitrogen fertilization on the growth of teak (*Tectona grandis*) seedlings and chemical property of acidic soil substrate. **New Forests**, v. 43, n. 2, p. 231–243, 2012.

ZHOU, Z. *et al.* Growth and mineral nutrient analysis of teak (*Tectona grandis*) grown on acidic soils in south China. **Journal of Forestry Research**, v. 28, n. 3, p. 503–511, 2017.

#### 4 CONSIDERAÇÕES FINAIS

A relação espacial entre volume do povoamento de *T. grandis* e os índices de vegetação obtidos via sensoriamento remoto é útil para o manejo florestal, pois fornece informações que facilitam o monitoramento contínuo e a tomada de decisões que podem incrementar a produtividade dos plantios. Além disso, é uma ferramenta importante para um manejo mais preciso, eficiente e sustentável, levando a melhores resultados econômicos e ambientais. Isso é possível pois permite identificar quais nutrientes estão disponíveis e em quais quantidades, facilitando o planejamento da adubação eficiente para as necessidades do povoamento.

A variabilidade espacial dos atributos químicos do solo possibilita a criação de zonas de manejo específicas dentro do povoamento. O planejamento mais preciso do manejo do plantio pode reduzir custos operacionais, pois permite o uso mais racional de insumos e recursos. Além disso, solos que possuem os nutrientes essenciais em quantidades adequadas em proporções equilibradas contribuem para a saúde do povoamento, sustentando o desenvolvimento das árvores.

##### 4.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Para futuros estudos, recomenda-se a utilização de uma análise histórica dos índices para observar a evolução dos povoamentos de *T. grandis* com densidades de plantio diferentes, estabelecendo uma relação temporal de produtividade com índices de vegetação e biofísicos. Essa análise ajudará na avaliação da influência dos desbastes na produtividade dos povoamentos de *T. grandis*.

Recomenda-se, também, a implementação de análise temporal dos atributos químicos do solo, para compreender a exigência de nutrientes em distintas fases de

desenvolvimento de povoamentos de *T. grandis*. Além disso, sugere-se conduzir a análise do solo em diferentes profundidades, bem como os atributos físicos do solo.