



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE

**GRAU DE OCUPAÇÃO DE ESPÉCIES ARBÓREAS
DA FLORESTA COM ARAUCÁRIA A PARTIR DE
GEOESTATÍSTICA E SENSORIAMENTO
REMOTO**

RAMON DE SOUSA LEITE

SÃO JOSÉ DOS CAMPOS, SP

2020

RAMON DE SOUSA LEITE

**GRAU DE OCUPAÇÃO DE ESPÉCIES ARBÓREAS DA FLORESTA COM
ARAUCÁRIA A PARTIR DE GEOESTATÍSTICA E SENSORIAMENTO
REMOTO**

Trabalho de conclusão da disciplina SER
301 - Análise Espacial de Dados
Geográficos.

Dr. Antônio Miguel Vieira Monteiro

Dr. Eduardo G. Camargo

Professores

SÃO JOSÉ DOS CAMPOS, SP

2020

SUMÁRIO

RESUMO	iii
LISTA DE FIGURAS	iv
LISTA DE TABELAS.....	iv
1. INTRODUÇÃO	5
2. OBJETIVOS.....	6
2.1 Geral.....	6
2.2 Específicos	6
3. MATERIAL E MÉTODOS.....	7
3.1 Área de estudo.....	7
3.2 Variável alvo: área basal	7
3.2.1 Processo de amostragem	8
3.3 Covariáveis de Sensoriamento Remoto.....	9
3.3.1 Aquisição das imagens	9
3.3.2 Pré-processamento das imagens.....	10
3.3.3 Refletância e Índice de Vegetação	10
3.4 Análise estatística e exploratória dos dados	11
3.5 Análise geoestatística	11
3.5.1 Caracterização da dependência espacial.....	11
3.5.1.1 Dispersogramas h	11
3.5.1.2 Semivariogramas.....	12
3.5.2 Interpolação.....	14
3.5.3 Avaliação da interpolação	16
3.6 <i>Softwares</i> e pacotes utilizados.....	17
4. RESULTADOS E DISCUSSÃO	17
4.1 Estatística descritiva e exploratória.....	17
4.2 Variável alvo <i>versus</i> covariáveis.....	20
4.3 Caracterização da dependência espacial.....	21
4.3.1 Dispersogramas de h	21
4.3.2 Semivariogramas.....	21
4.4 Interpolação e validação.....	22
5. CONCLUSÕES	24
6. REFERÊNCIAS	24

RESUMO

A caracterização de um ecossistema por meio de inventário por censo envolve um trabalho intenso, demorado e dispendioso e, portanto, as medidas de campo não podem ser aplicadas em grande escala ou em extensas áreas. Por outro lado, a integração de técnicas geoestatísticas multivariadas com dados obtidos de plataformas espaciais e inventários florestais por amostragem pode fornecer com precisão e baixo custo um panorama de variáveis florestais importantes. E assim, proporcionar subsídios para práticas de conservação e restauração dos ecossistemas florestais, avaliação de impactos ambientais e manejo florestal. Nesse contexto, objetivou-se com o presente estudo avaliar o desempenho da cokrigagem ordinária (CKO) no mapeamento da variável área basal (G) em um remanescente de Floresta Ombrófila Mista (FOM), utilizando covariáveis derivadas de imagens do satélite Sentinel-2A. Para isso, foram utilizados dados do inventário florestal contínuo, realizado na Floresta Nacional de Irati (FLONA de Irati), sob o domínio de Floresta Ombrófila Mista, referentes às medições realizadas em 2017 em 400 unidades amostrais georreferenciadas de 25 m x 25 m (625 m²), totalizando uma área de 25 hectares. Embora o levantamento de campo contemple 400 unidades amostrais, apenas 100 parcelas, com a variável área basal, foram utilizadas, pois partiu-se do pressuposto que a variável alvo era subamostrada e as covariáveis superamostradas. Para obtenção das covariáveis foram obtidas imagens multiespectrais do satélite Sentinel-2A, com certo nível de processamento, sendo necessário apenas uma correção atmosférica. Após a correção atmosférica, obteve-se os valores de refletância das bandas (B2, 0,46 µm a 0,52 µm; B3, 0,54 µm a 0,58 µm; B4, 0,65 µm a 0,68 µm e B8, 0,78 µm a 0,90 µm) e o Índice de Vegetação da Diferença Normalizada (NDVI) de toda a área, 25 hectares e zona de influência ou *buffer* de 50 metros. Em seguida, foram obtidos os mapas, considerando duas técnicas de interpolação: uma univariada, a krigagem ordinária (KO), e outra multivariada, a CKO. Para avaliar a precisão dos mapas obtidos foi utilizado dados, com a variável alvo, de 50 parcelas extras, distribuídas aleatoriamente na área de estudo. A área basal foi negativamente correlacionada com a refletância das bandas e o NDVI, com baixos coeficientes de correlação. Os maiores coeficientes de correlação foram com as bandas 3 e 2. De modo geral, as duas técnicas de interpolação mapearam bem a variável alvo (área basal), no entanto, a hipótese considerada de que os dados derivados do Sentinel-2A combinados com técnicas geoestatísticas multivariadas melhoram a precisão do mapeamento da área basal, em Floresta Ombrófila Mista, foi rejeitada.

Palavras-Chaves: mapeamento; krigagem ordinária; cokrigagem; Sentinel-2A; inventário florestal; florestas subtropicais.

LISTA DE FIGURAS

Figura 1. Distribuição das 400 unidades amostrais sobre um composto de cores falsas das bandas 8(R), 3(G) ,2(B) do Sentinel-2A.	8
Figura 2. Distribuição das 100 unidades amostrais, utilizadas na modelagem geoestatística, sobre um composto de cores falsas das bandas 8(R), 3(G) ,2(B) do Sentinel-2A.	9
Figura 3. Distribuição das 50 unidades amostrais utilizadas na validação.	16
Figura 4. Histograma com a variável alvo, área basal (G). Dados de 100 parcelas de 625 m ² em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.	18
Figura 5. Dispersogramas de h para área basal (m ² ha ⁻¹), considerando quatro raios de distâncias: 0 m a 50 m, 50 m a 100 m, 100 m a 150 m e 150 m a 200 m. Dados de 100 parcelas de 625 m ² em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.....	21
Figura 6. Semivariograma e covariograma cruzado para krigagem ordinária (KO), usando a área basal, e cokrigagem ordinária (CKO), usando a área basal e refletância da banda 3 (verde, 0,54 µm a 0,58 µm) do satélite Sentinel-2A, respectivamente, em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.	22
Figura 7. Mapas de predição da área basal (m ² ha ⁻¹) em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil, obtidos por meio das técnicas krigagem ordinária e cokrigagem, considerando a refletância da banda 3, do satélite Sentinel-2A.	23

LISTA DE TABELAS

Tabela 1. Exemplificação da matriz das semivariância para uma direção no espaço.	12
Tabela 2. Estatísticas descritivas da variável alvo, área basal (m ² ha ⁻¹). Dados de 150 parcelas de 625 m ² , 100 parcelas utilizadas na modelagem geoestatística e 50 na validação, em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.....	18
Tabela 3. Estatística descritivas do NDVI e refletância das bandas 2 (0,46 µm a 0,52 µm), 3 (0,54 µm a 0,58 µm), 4 (0,65 µm a 0,68 µm) e 8 (0,78 µm a 0,90 µm) do satélite Sentinel-2A.	19
Tabela 4. Coeficientes de correlação de Pearson entre a variável área basal e informações derivadas de imagens do satélite Sentinel-2A (NDVI e refletância das bandas 2 (azul, 0,46 µm a 0,52 µm), 3 (verde, 0,54 µm a 0,58 µm), 4 (vermelho, 0,65 µm a 0,68 µm) e 8 (infravermelho próximo, 0,78 µm a 0,90 µm)). Dados de 100 parcelas de 625 m ² em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.	20
Tabela 5. Performance das técnicas geoestatísticas: krigagem ordinária, usando as variáveis alvo (S, H', G e N), e cokrigagem, usando as variáveis alvo (S, H', G e N) e covariáveis derivadas do satélite Sentinel-2A (n = 50).	23

1. INTRODUÇÃO

A Floresta Ombrófila Mista (FOM) é uma subdivisão da subclasse de formação da Floresta Ombrófila (MARTINS, 2012). O termo “Mista” refere-se a presença de espécies gimnospermas, principalmente *Araucaria angustifolia* (Bertol.) Kuntze (araucária) e *Podocarpus lambertii* Klotzsch ex Endl. (pinheiro-bravo), consorciadas com angiospermas de diversas famílias e gêneros. No Brasil, extensas áreas de FOM são encontradas no Sul do país (IBGE, 2012) e assim como boa parte das florestas tropicais e subtropicais, essa tipologia florestal está cada vez mais fragmentada (RIBEIRO et al., 2009; SCHAADT et al., 2012; VIBRANS et al., 2013; TAUBERT et al., 2018; WINAGRASKI et al., 2018), tornando necessários estudos que desenvolvam métodos para caracterizar espacialmente esse ecossistema, cujas ferramentas, mais cedo ou mais tarde, darão suporte às decisões ou ações relacionadas ao manejo e conservação desses remanescentes florestais.

A Geoestatística permite espacializar qualquer característica ou fenômeno, desde que haja dependência espacial. Havendo dependência espacial, pode-se estimar valores de uma característica estudada para locais não amostrados. Nesse contexto, o uso de técnicas geoestatísticas pode fornecer, com precisão e baixo custo, um panorama da distribuição espacial de informações relevantes nos ecossistemas florestais. Ademais, pode proporcionar subsídios para práticas de conservação e restauração dos ecossistemas florestais, avaliação de impactos ambientais e manejo florestal.

Dentre as técnicas geoestatísticas mais empregadas em estudos florestais está a krigagem ordinária (KO) (SANTOS et al., 2014; ROVEDA et al., 2016; PELISSARI et al., 2017; PELISSARI et al., 2018; ROVEDA et al., 2018), a qual permite calcular a autocorrelação espacial entre pontos amostrais e quantificar a incerteza (YAMAMOTO e LANDIM, 2013). Apesar da eficiência desse método, outras técnicas multivariadas vêm sendo exploradas e utilizadas nos últimos anos, como por exemplo a cokrigagem ordinária (CKO) (HERNÁNDEZ-STEFANONI et al., 2011; HERNÁNDEZ-STEFANONI et al., 2012; YADAV e NANDY, 2015; SCOLFORO et al., 2016). A cokrigagem ordinária é uma técnica geoestatística que pode ser requerida quando há duas ou mais variáveis que se correlacionam espacialmente (LI e HEAP, 2011; LI e HEAP, 2014) e uma é mais difícil ou mais cara para se medir no campo. Na cokrigagem, a dependência espacial entre duas variáveis no espaço pode ser expressa pelas covariâncias cruzadas (YAMAMOTO e LANDIM, 2013). Assim, havendo dependência espacial, a

cokrigagem pode ser utilizada para estimar aquela mais difícil de se medir, utilizando-se os dados de ambas.

Nas últimas décadas, se dispõe de uma vasta gama de sensores remotos com resolução espacial, temporal, espectral e radiométrica distinta. Além disso, não é novidade que há relação entre dados derivados de imagens de sensores, como os índices de vegetação e reflectância de algumas bandas específicas, com variáveis da vegetação (MENG et al., 2009; NAGENDRA, 2010; MENG et al., 2016; SANTOS et al., 2017; AREKHI et al., 2017; MADONSELA et al., 2017; MORLEY et al., 2019). Assim, o uso de informações auxiliares derivadas de imagens de satélites pode melhorar a precisão do mapeamento de métricas da vegetação quando as técnicas geoestatísticas forem requeridas.

Dentre os satélites de destaque, atualmente, pode-se citar o Sentinel-2, da missão Sentinel. As imagens possuem resolução espacial de até 10 metros e são distribuídas pela Agência Espacial Europeia (ESA, do inglês *European Space Agency*), a qual fornece produtos desde de 2015 com certo grau de processamento, tais como correções radiométricas e geométricas (incluindo ortorretificação e registro espacial). O Sentinel-2A carrega um sensor de imagens multiespectral com 13 faixas espectrais ou bandas, sendo quatro delas, com resolução espacial de 10 m, banda 2 (azul), 3 (verde), 4 (vermelho) e 8 (infravermelho próximo) (SUHET, 2015).

Diante disso, a presente pesquisa busca responder a seguinte questão: Dados derivados do satélite Sentinel-2A melhoram a precisão da estimação espacial de atributos estruturais em floresta com araucária quando técnicas geoestatísticas são utilizadas?

2. OBJETIVOS

2.1 Geral

Avaliar o desempenho cokrigagem ordinária no mapeamento da área basal de um remanescente de Floresta Ombrófila Mista, utilizando covariáveis derivadas de imagens do satélite Sentinel-2A.

2.2 Específicos

i) Obter a variável área basal de um remanescente de Floresta Ombrófila Mista; *ii)* Obter os valores de refletância das bandas 2 (azul, 0,46 μm a 0,52 μm), 3 (verde, 0,54 μm a 0,58 μm), 4 (vermelho, 0,65 μm a 0,68 μm) e 8 (infravermelho próximo, 0,78 μm a 0,90 μm) e o índice espectral: Índice de Vegetação da Diferença Normalizada (NDVI, do inglês *Normalized Difference Vegetation Index*); *iii)* Relacionar a variável alvo, área basal, com as covariáveis (dados derivados das imagens, refletância e NDVI); *iv)* Selecionar covariáveis com maior correlação com a variável alvo; *v)* Mapear a variável alvo pela krigagem ordinária e cokrigagem ordinária; *vi)* Avaliar o desempenho da cokrigagem, em relação a krigagem ordinária, no mapeamento da área basal usando as covariáveis.

3. MATERIAL E MÉTODOS

3.1 Área de estudo

O presente estudo foi realizado em um fragmento de Floresta Ombrófila Mista, localizada no município de Fernandes Pinheiro, no estado do Paraná, região Sul do Brasil. A área de estudo está inserida na Floresta Nacional de Irati - Flona de Irati (25°20'24,818" Sul e 50°33'44,889" Oeste), estando a uma altitude que varia de 787 a 900 metros. A Flona de Irati é uma Unidade de Conservação de Uso Sustentável, abrange uma área de 3.495 hectares, sendo 78% da área total pertencente ao município de Fernandes Pinheiro e 22% ao município de Teixeira Soares, Paraná, Brasil. O remanescente de floresta estudado encontra-se em estágio sucessional secundário avançado, de acordo com Pelissari et al. (2017).

3.2 Variável alvo: área basal

Foi utilizado no presente uma variável estrutural, a área basal (G) (Equação 1). As informações da variável área basal foram obtidas do inventário contínuo realizado na Flona de Irati, referente as medições realizadas em 2017. Estes são provenientes de uma malha sistemática de 400 unidades amostrais georreferenciadas de 25 m x 25 m, nas quais foram desmembradas das 100 parcelas de 50 m x 50 m ou dos 25 blocos (Figura 1).

$$G = \sum_{i=1}^N g_i \times F \quad (1)$$

Em que: G = Área basal ($\text{m}^2 \text{ha}^{-1}$); N = número total de árvores amostradas na i-ésima unidade amostral; g = área da seção transversal ($\frac{\pi \times \text{DAP}^2}{40.000}$) das árvores amostradas na i-ésima unidade amostral; F = fator de proporcionalidade, ou seja, $\frac{10.000}{a}$; DAP = Diâmetro à Altura do Peito; a = área da unidade amostral (m^2).



Figura 1. Distribuição das 400 unidades amostrais sobre um composto de cores falsas das bandas 8(R), 3(G), 2(B) do Sentinel-2A.

3.2.1 Processo de amostragem

Embora o levantamento de campo contemple 400 unidades amostrais, apenas 100 parcelas, com a métrica área basal, foram utilizadas (Figura 2), pois partiu-se do pressuposto que a variável alvo é subamostrada e as covariáveis superamostradas. Para tal, foi empregado o processo de amostragem sistemática para escolha das 100 parcelas. Assim, uma unidade amostral foi selecionada aleatoriamente entre as 400 unidades amostrais, enquanto as demais 99 parcelas foram alocadas equidistantes a cada 25 m.



Figura 2. Distribuição das 100 unidades amostrais, utilizadas na modelagem geoestatística, sobre um composto de cores falsas das bandas 8(R), 3(G) ,2(B) do Sentinel-2A.

3.3 Covariáveis de Sensoriamento Remoto

3.3.1 Aquisição das imagens

As imagens multiespectrais do satélite Sentinel-2A, sensor *Multi Spectral Instrument* (MSI), foram obtidas no endereço eletrônico <<https://earthexplorer.usgs.gov/>>, do Serviço Geológico dos Estados Unidos (USGS, do inglês *United States Geological Survey*), fornecidas e processadas pela ESA. A data do imageamento foi às 13:32:21 (Horário de Brasília, DF) de 17 de fevereiro de 2017, sendo próxima a data do levantamento de campo.

Os produtos obtidos corresponderam as ortoimagens com valores de refletância para o Topo da Atmosfera (TOA, do inglês *Top-of-Atmosphere Reflectance*) e especificado como produtos de Nível-1C. O processamento de produtos de Nível-1C pela ESA inclui correções radiométricas e geométricas, incluindo ortorretificação e registro espacial em um sistema de referência global, Universal Transversa de Mercator/*World Geodetic System* (UTM/WGS84), com precisão de *subpixel*.

3.3.2 Pré-processamento das imagens

Os subprodutos ou imagens dos satélites Sentinel-2, operados pela ESA, são fornecidos com os valores de refletância TOA (Nível-1C) e/ou *Bottom-of-Atmosphere* (BOA), quando produtos de Nível-2A. Os valores de refletância TOA representam a refletância "bruta" da Terra, medida a partir do espaço, e corresponde a uma mistura de luz refletida na superfície da Terra e na atmosfera. O BOA, por sua vez, representa a refletância real das áreas na superfície da Terra e pode ser obtido, quando necessário, a partir dos valores TOA (SOLA et al., 2018).

Assim, as imagens obtidas foram submetidas a correção atmosférica para minimizar o efeito da dispersão atmosférica. A dispersão atmosférica refere-se as modificações exercidas pela atmosfera da Terra quando a radiação entra e sai da superfície. Como consequência, o número digital registrado em um *pixel* de uma determinada imagem pode não representar verdadeiramente as propriedades reflexivas do objeto no *pixel* (BANSKOTA et al., 2014). Para a correção foi empregado o método *Dark Object Subtraction* - DOS (CHAVEZ, 1988; CHAVEZ, 1989; CHAVEZ, 1996). Logo, os valores gravados nos *pixels* das ortoimagens após a correção atmosférica correspondem a refletância dos objetos ou BOA.

3.3.3 Refletância e Índice de Vegetação

Após a correção atmosférica, obteve-se o NDVI (Equação 2) a partir da refletância das bandas espectrais vermelho (B4, 0,65 μm a 0,68 μm) e infravermelho próximo (B8, 0,78 μm a 0,90 μm) (CAMPBELL e WYNNE, 2011).

$$\text{NDVI} = \frac{\rho_{\text{NIR}} - \rho_{\text{R}}}{\rho_{\text{NIR}} + \rho_{\text{R}}} \quad (2)$$

Em que: NDVI = Índice de Vegetação de Diferença Normalizada; NIR = é o fluxo radiante refletido na região do infravermelho próximo; R = é o fluxo radiante refletido no vermelho da região do visível; ρ = reflectância.

A refletância das quatro bandas (B2, 0,46 μm a 0,52 μm ; B3, 0,54 μm a 0,58 μm ; B4, 0,65 μm a 0,68 μm e B8, 0,78 μm a 0,90 μm), o NDVI e as coordenadas do centroide de cada *pixel* foram extraídas. Considerou ainda, para obtenção das covariáveis, um *buffer* de aproximadamente 50 metros, além dos limites da área de estudo.

3.4 Análise estatística e exploratória dos dados

Os dados, da vegetação e das covariáveis, foram submetidos à análise estatística descritiva, como média, mediana, variância, desvio padrão, coeficiente de variação, coeficiente de assimetria e valores máximo e mínimo. Além disso, obteve-se os histogramas com a distribuição de frequência em porcentagem para variável alvo. A normalidade dos dados foi avaliada por meio do teste de Kolmogorov-Smirnov (KS), a 5% de significância. Uma transformação em logaritmo neperiano foi aplicada aos dados, quando esses não apresentaram distribuição normal ($p \leq 0,05$).

A relação entre a variável de interesse e os valores de refletância das bandas e o NDVI foi avaliada por meio do coeficiente de correlação de Pearson (r). Para isso, usou-se os dados das 100 parcelas e os valores dos *pixels* vizinhos. A variável utilizada como covariável na análise geoestatística foi aquela com maior coeficiente de correlação.

3.5 Análise geoestatística

3.5.1 Caracterização da dependência espacial

3.5.1.1 Dispersogramas h

Os gráficos de dispersogramas de distância ou de h não são requisitos na análise geoestatística, porém são interessantes para se estabelecer a presença de tendência e autocorrelação espacial das variáveis modeladas, suposição essa, fundamental nas análises geoestatísticas (YAMAMOTO e LANDIM, 2013). O dispersograma de h é um gráfico dos valores observados da variável para raios de distâncias definidos. Neste estudo, considerou-se os seguintes raios de distâncias 0 a 50 m, 50 a 100 m, 100 a 150 m e 150 a 200 m.

O comportamento típico esperado do dispersograma de h é que a nuvem de pontos se disperse cada vez mais com o aumento dos raios, isso equivale a afirmar que pares de medidas tomados mais próximos se parecem mais do que pares de medidas tomados mais distantes (BRAGA, 2014). O ideal é que os dispersogramas apresentem coeficientes de

correlação mais próximos de 1,0 (um) para raios de distâncias menores e menores à medida que o valor do raio aumenta.

3.5.1.2 Semivariogramas

A autocorrelação espacial da variável alvo (área basal) foi examinada e quantificada por meio do semivariograma (Equação 3). Esse mede a dissimilaridade da variável de interesse (Z) em função de todos os intervalos de h (CLARK, 2001). Para a modelagem do semivariograma, obtém-se inicialmente um gráfico dos valores médios do semivariograma no eixo y e a distância no eixo x, denominado de semivariograma empírico. Na Tabela 1 está uma exemplificação de uma matriz com as semivariâncias, em função de intervalos de distância, bem como, o número de observação em cada intervalo de h.

$$\gamma(h) = \frac{1}{2N} \sum_{i=1}^N [Z(x_{i+h}) - Z(x_i)]^2 \quad (3)$$

Em que: γ = semivariâncias para N pares de dados separados por uma distância h; Z = a variável em consideração nas posições x_i e $x_i + h$.

Tabela 1. Exemplificação da matriz das semivariância para uma direção no espaço.

Distância (h)	Semivariâncias	Pares de pontos amostrais
d1	$\gamma(d1)$	N1
d2	$\gamma(d2)$	N2
d3	$\gamma(d3)$	N3
Dn	$\gamma(dn)$	Nn

Em que: d_i = distância (m) entre pares de pontos amostrais; $\gamma(d_i)$ = semivariância média para uma distância d_i .

Fonte: Pelissari (2015)

Quando as covariáveis foram consideradas, a autocorrelação espacial foi avaliada pelas covariâncias cruzadas ou covariograma cruzado (Equação 4).

$$C_{12}(h) = \frac{1}{2N} \sum_{i=1}^N [Z_1(x_{1i}+h) - Z_1(x_{1i})] [Z_2(x_{2i}+h) - Z_2(x_{2i})] \quad (4)$$

Em que: $\gamma_{1,2}(h)$ = covariâncias das variáveis Z_1 (variáveis alvo) e Z_2 (covariáveis); h = distância entre pontos medidos; N = número de pares de pontos medidos de Z_1 e Z_2 , separados por uma distância h .

A anisotropia, efeito da direção na autocorrelação espacial, não foi considerada, pois esta exige um número maior de amostras para o ajuste de semivariogramas estáveis em cada direção. De acordo com Davidson e Csillag (2003), quando o número de amostras é limitado, uma caracterização isotrópica ou omnidirecional da autocorrelação espacial é mais recomendável.

Depois de obter as semivariâncias e/ou covariância empírica, ajustou-se modelos teóricos aos pontos que formam o semivariograma e/ou covariograma empírico. O ajuste dos modelos foi semelhante ao de uma regressão por mínimos quadrados, ou seja, ajustou-se uma linha média de modo que a diferença quadrática ponderada entre cada ponto e a linha fosse a menor possível. Para tal, foram ajustados os modelos esféricos (Equação 5), exponencial (Equação 6) e gaussiano (Equação 7) (WEBSTER e OLIVER, 2007) pelo método dos Mínimos Quadrados Ponderados.

$$\gamma(h) = \begin{cases} C_0 + C_1 \left[1,5 \left(\frac{h}{a}\right) - 0,5 \left(\frac{h}{a}\right)^3 \right], & 0 < h \leq a \\ C_0 + C_1, & h > a \end{cases} \quad (5)$$

$$\gamma(h) = \left\{ C_0 + C_1 \left[1 - \exp\left(-\frac{h}{a}\right) \right] \right\}, \quad h \geq 0 \quad (6)$$

$$\gamma(h) = \left\{ C_0 + C_1 \left[1 - \exp\left(-\frac{h}{a}\right)^2 \right] \right\}, \quad h \geq 0 \quad (7)$$

Em que: C_0 = efeito pepita; $C_0 + C_1$ = patamar; a = alcance.

Após o ajuste dos modelos, a razão entre pepita e patamar foi determinada para caracterizar as dependências espaciais das variáveis. Segundo Cambardella et al. (1994), uma razão $< 25\%$ indica uma forte dependência espacial, de 25 a 75% uma dependência moderada e $> 75\%$ uma dependência fraca.

Os modelos teóricos, simples e cruzados, foram escolhidos com base na Raiz do Erro Quadrático Médio (RMSE, do inglês *Root Mean Square Error*) da validação cruzada *leave-one-out* (ISAAKS e SRIVASTAVA, 1989). Esse método de validação consiste em avaliar os erros da interpolação removendo sucessivamente um ponto Z_i de cada vez e depois estimando a partir do restante de pontos, produzindo um valor estimado (Z_i^*).

Assim, os modelos teóricos escolhidos foram aqueles que apresentaram menores RMSE (Equação 8).

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (Z_i - Z_i^*)^2}{n}} \quad (8)$$

Em que: RMSE = Raiz do Erro Quadrático Médio; Z_i = Valor observado na posição x_0 ; Z_i^* = Valor estimado na posição x_0 ; n = Número de observações.

Embora a validação cruzada avalie a interpolação, tem-se a partir dos erros de predição um panorama de quais modelos teóricos se ajustaram melhor no semivariograma empírico e/ou covariograma empírico.

3.5.2 Interpolação

A previsão para os locais não amostrados foi efetuada pela técnica de interpolação krigagem ordinária (Equação 9). Essa técnica consiste em estimar valores em locais não amostrados por uma média ponderada de amostras vizinhas. Para uma comparação justa entre ambas as técnicas de interpolação, KO e CKO, padronizou-se o número de amostras vizinhas para 16. O número de amostras vizinhas foi escolhido após um pré-teste, com números inteiros múltiplos de quatro, indicar que esse resultava em mapas mais precisos. Todos os múltiplos de quatro entre 7 (sete) e 25 foram testados, assim como sugerido por Oliver e Webster (2014).

$$Z_{KO}^*(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) \quad (9)$$

Em que: Z_{KO}^* = é o valor estimado da variável no ponto de interesse x_0 , considerando a técnica krigagem ordinária, KO; Z = é o valor observado no ponto vizinho x_i ; λ_i = é o peso atribuído ao ponto vizinho; N = representa o número de pontos vizinhos usados para estimar o ponto de interesse ou não amostrado.

As equações para krigagem estão contidas em matrizes e vetores que dependem da autocorrelação espacial entre os locais de amostra medidos e o local de previsão. Os valores das matrizes vêm do modelo de semivariograma e/ou covariograma. As matrizes e os vetores determinam os pesos de krigagem atribuídos a cada valor medido na vizinhança de pesquisa. Assim, minimizando a variância do erro sob a condição de não

viés $\sum_{i=1}^N \lambda_i = 1$, os pesos λ_i são obtidos a partir do seguinte sistema de equações, $A\lambda = b$ (WEBSTER e OLIVER, 2007; YAMAMOTO e LANDIM, 2013).

$$\begin{array}{c}
 \begin{array}{ccccc}
 & \text{A} & & & \\
 \gamma(Z_1, Z_1) & \gamma(Z_1, Z_2) & \dots & \gamma(Z_1, Z_n) & 1 \\
 \gamma(Z_2, Z_1) & \gamma(Z_2, Z_2) & \dots & \gamma(Z_2, Z_n) & 1 \\
 \gamma(Z_3, Z_1) & \gamma(Z_3, Z_2) & \dots & \gamma(Z_3, Z_n) & 1 \\
 \gamma(Z_n, Z_1) & \gamma(Z_n, Z_2) & \dots & \gamma(Z_n, Z_n) & 1 \\
 1 & 1 & \dots & 1 & 0
 \end{array}
 & \left| \right. & & \left| \right. & \begin{array}{c}
 \lambda \\
 \lambda_1 \\
 \lambda_2 \\
 \dots \\
 \lambda_n \\
 \Psi(x_0)
 \end{array}
 & = & \left| \right. & \begin{array}{c}
 \text{B} \\
 \gamma(Z_1, Z_0) \\
 \gamma(Z_2, Z_0) \\
 \dots \\
 \gamma(Z_n, Z_0) \\
 1
 \end{array}
 \end{array}$$

Em que: $\gamma(Z_n, Z_n)$ = semivariâncias estimadas entre os pontos amostrais observados; λ_n = peso; ψ = multiplicador de Lagrange; $\gamma(Z_n, Z_0)$ = semivariâncias estimadas entre os pontos amostrais observados e os locais não amostrados (x_0).

A matriz A é obtida com base nas semivariâncias entre os pontos amostrais vizinhos utilizados na estimativa do ponto não amostrado. Para isso faz-se o uso dos modelos teóricos ajustados. A matriz B é obtida com base nas semivariâncias entre as amostras vizinhas usadas na interpolação e o ponto a ser estimado $Z(x_0)$. Como tem-se o conhecimento das distâncias entre os pontos $Z(x_i)$ e o ponto $Z(x_0)$, é possível determinar, pelo modelo teórico ajustado, as semivariâncias.

Obtidas as matrizes A e B, o processo de solução matricial envolveu a inversão da matriz A e a sua multiplicação por B ($\lambda = A^{-1} B$), para a determinação dos pesos (λ) e o multiplicador de Lagrange (WEBSTER e OLIVER, 2007), respeitando a condição de $\sum_{i=1}^N \lambda_i = 1$. Esse procedimento é repetido em todos os locais a serem estimados. Em seguida, a partir dos pesos de krigagem para os pontos vizinhos, calcula-se uma previsão para o local com o valor desconhecido (Equação 9).

Na cokrigagem, a solução do sistema de equações normais produzirá N1 pesos λ_{1i} e N2 pesos λ_{2i} e os multiplicadores de Lagrange, ψ_1 e ψ_2 . Um exemplo das equações e as matrizes pode ser visualizado nas páginas 30 a 38 da revisão de Vieira (2000). A estimativa de Z^*_{CKO} , para qualquer local x_0 , é dada pela combinação linear de ambas as variáveis Z_1 e Z_2 e é expressa a seguir (Equação 10).

$$Z^*_{CKO}(x_0) = \sum_{i=1}^N \lambda_{1i} Z(x_{1i}) + \sum_{i=1}^N \lambda_{2i} Z(x_{2i}) \quad (10)$$

Em que: Z^*_{CKO} = estimativa da variável primária na posição x_0 ; Z_1 e Z_2 = variáveis primária e secundária, respectivamente; N = é o número de pontos de amostragem de vizinhos utilizados

para a previsão do valor não amostrado; λ_{1i} e λ_{2i} = são os pesos atribuídos a cada i - observação das variáveis $Z(x_{1i})$ (variável primária) e $Z(x_{2i})$ (covariável).

Portanto, a variável de interesse, área basal, foi espacializada considerando a krigagem e a cokrigagem ordinária, utilizando como covariável na cokrigagem a variável de maior correlação a variável alvo.

3.5.3 Avaliação da interpolação

Foram utilizados dados de 50 parcelas (não utilizadas na modelagem geostatística) escolhidas aleatoriamente para avaliação dos métodos de interpolação (Figura 3). A partir dos erros entre os valores observados e estimados, foi obtido a Raiz do Erro Quadrático Médio (RMSE). O método de interpolação mais preciso foi aquele que apresentou o menor RMSE. A melhoria relativa (MR) da cokrigagem sobre a krigagem ordinária foi determinada para avaliar a mudança na precisão dos mapas temáticos considerando as covariáveis (Equação 11).

$$MR = \frac{RMSE(KO) - RMSE(COK)}{RMSE(KO)} \times 100 \quad (11)$$

Em que: MR = Melhoria relativa (%); KO = Krigagem ordinária; CKO = Cokrigagem ordinária; RMSE = Raiz do Erro Quadrático Médio.

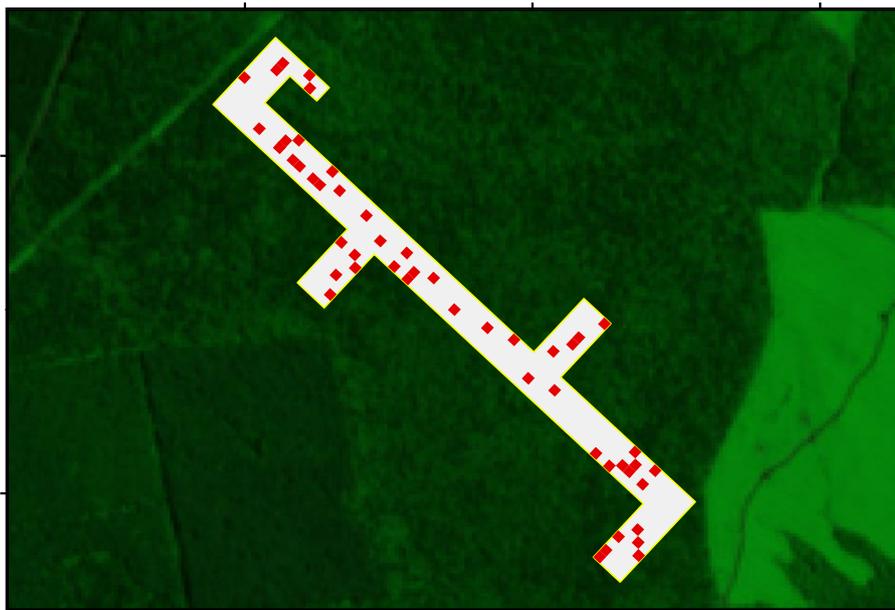


Figura 3. Distribuição das 50 unidades amostrais utilizadas na validação.

3.6 Softwares e pacotes utilizados

As estatísticas descritivas, exploratórias e dispersogramas de distâncias foram obtidas no *software* R (R CORE TEAM, 2018). O teste de normalidade foi obtido utilizando o pacote *nortest* (GROSS e LIGGES, 2015), o histograma, da variável alvo, com o pacote *lattice* (SARKAR, 2008) e os dispersogramas de distâncias com o pacote *sp* (PEBESMA e BIVAND, 2005). As demais estatísticas foram obtidas utilizando os pacotes básicos do *software* R.

Quanto ao processamento das imagens, a correção atmosférica foi realizada utilizando o *Plugin Semi-Automatic Classification - SCP* (CONGEDO, 2016) do *software* do QGIS (EQUIPE DE DESENVOLVIMENTO QGIS, 2019). As covariáveis e centroides dos *pixels* foram obtidos (as) usando ferramentas básicas desse mesmo *software*.

As análises geoestatísticas e os cálculos das estatísticas de validação, considerando os pontos extras, foram realizadas no *software* ArcGIS e Excel, respectivamente.

4. RESULTADOS E DISCUSSÃO

4.1 Estatística descritiva e exploratória

As estatísticas obtidas para a variável área basal, considerando os dados das duas amostras, 100 parcelas utilizadas na modelagem geoestatística e 50 parcelas para avaliação, são apresentados na Tabela 2. Em média, os valores das duas amostras não diferiram muito, o que significa que a amostra de 50 parcelas usadas para avaliar a precisão da interpolação é adequada.

O coeficiente *z* indica que a variável alvo é assimétrica em ambas as amostras, com assimetria positiva ou à direita. O que é confirmado pelos valores médios e mediano. Quando a média é maior que a mediana, os dados apresentam assimetria positiva. O histograma obtido para área basal pode ser visualizado na Figura 4. Não houve necessidade de transformação dos dados, pois de acordo com o teste de KS, a variável apresenta distribuição normal ($p > 0,05$).

Tabela 2. Estatísticas descritivas da variável alvo, área basal ($\text{m}^2 \text{ha}^{-1}$). Dados de 150 parcelas de 625 m^2 , 100 parcelas utilizadas na modelagem geoestatística e 50 na validação, em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.

	(n = 100)	(n = 50)
Mínimo	13,92	18,02
Máximo	54,54	64,11
Amplitude	40,62	46,08
Mediana	29,48	32,09
Média	30,46	34,26
Variância	59,99	125,03
Desvio Padrão	7,75	11,18
Coefficiente de Variação (%)	25,44	32,63
z	0,70	0,75
D	0,088 (p = 0,06)	0,112 (p = 0,12)

z = Coeficiente de assimetria; D = Estatística de Kolmogorov-Smirnov (KS); $p > 0,05$ = Os dados são normais pelo teste de KS; $p \leq 0,05$ = os dados não são normais pelo teste de KS.

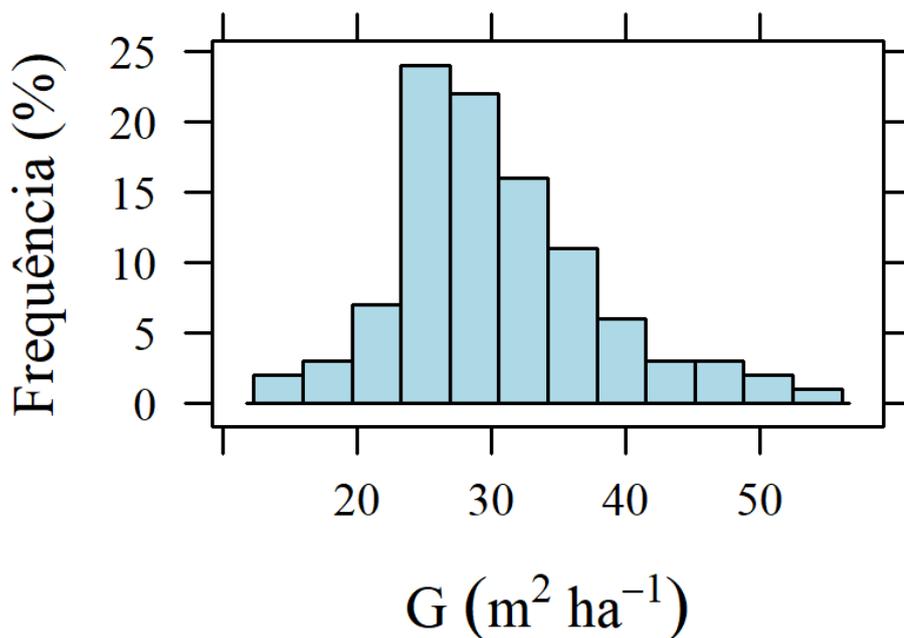


Figura 4. Histograma com a variável alvo, área basal (G). Dados de 100 parcelas de 625 m^2 em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.

As estatísticas obtidas para as covariáveis podem ser visualizados na Tabela 3. Os valores de refletância foram maiores nas bandas correspondentes à faixa do espectro

vermelho (banda 4, 0,65 μm a 0,68 μm) e infravermelho próximo (banda 8, 0,78 μm a 0,90 μm). A baixa refletância na região do visível (RGB), bandas 2, 3 e 4, faixa de 0,46 μm a 0,68 μm , do Sentinel-2A, e alta refletância na região do infravermelho próximo, banda 8, faixa de 0,78 μm a 0,90 μm , era esperada, uma vez que na região do visível ocorre maior absorção da radiação incidente pelos pigmentos, encontrados geralmente nos cloroplastos, para realização da fotossíntese: clorofila (65%), carotenos (6%) e xantofilas (29%). Enquanto que, na região do infravermelho próximo, ocorre absorção pequena da radiação e considerável espalhamento interno da radiação na folha, incitada pela interação da radiação incidente nessa região do espectro eletromagnético com a estrutura do mesófilo, pois esse tecido vegetal tem pouca capacidade de absorção (CAMPBELL e WYNNE, 2011; PONZONI et al., 2012).

Foi observado um baixo coeficiente de variação para o NDVI, evidenciando uma homogeneidade dessa covariável, na área de estudo (Tabela 3). A variável escolhida para ser utilizada como covariável, na análise geostatística, foi transformada em logaritmo neperiano, pois, os dados não apresentaram distribuição normal pelo teste de KS ($p \leq 0,05$).

Tabela 3. Estatística descritivas do NDVI e refletância das bandas 2 (0,46 μm a 0,52 μm), 3 (0,54 μm a 0,58 μm), 4 (0,65 μm a 0,68 μm) e 8 (0,78 μm a 0,90 μm) do satélite Sentinel-2A.

	Banda 2	Banda 3	Banda 4	Banda 8	NDVI
Mínimo	0,0160	0,0196	0,0271	0,1471	0,6790
Máximo	0,0278	0,0407	0,043	0,3756	0,8198
Amplitude	0,0118	0,0211	0,0159	0,2285	0,1408
Mediana	0,0206	0,0278	0,0323	0,2219	0,7448
Moda	0,0201	0,0274	0,032	0,2388	0,75
Média	0,0207	0,0279	0,0324	0,2227	0,7440
s^2	$1,78 \times 10^{-6}$	$7,20 \times 10^{-6}$	$2,54 \times 10^{-6}$	0,0006	0,0004
s	0,0013	0,0027	0,0016	0,0252	0,0204
CV (%)	6,4556	9,6046	4,9110	11,3082	2,7416
z	0,54	0,25	0,75	0,27	-0,14
D	0,041 (p=0,00)	0,030 (p=0,00)	0,049 (p=0,00)	0,020 (p=0,00)	0,028 (p=0,00)

s^2 = variância; s = Desvio Padrão; CV = Coeficiente de Variação; z = Coeficiente de assimetria; D = Estatística de Kolmogorov-Smirnov (KS); $p > 0,05$ = Os dados são normais pelo teste de KS; $p \leq 0,05$ = os dados não são normais pelo teste de KS; e NDVI = Índice de Vegetação por Diferença Normalizada.

4.2 Variável alvo *versus* covariáveis

Os coeficientes de correlação entre a variável alvo, área basal, e as covariáveis, informações obtidas das imagens, estão apresentadas na Tabela 4. A área basal foi negativamente correlacionada com as covariáveis. Embora baixos, os coeficientes foram significativos ($p < 0,05$). Os maiores coeficientes de correlação foram observados com as bandas 3 e 2, respectivamente.

Tabela 4. Coeficientes de correlação de Pearson entre a variável área basal e informações derivadas de imagens do satélite Sentinel-2A (NDVI e refletância das bandas 2 (azul, 0,46 μm a 0,52 μm), 3 (verde, 0,54 μm a 0,58 μm), 4 (vermelho, 0,65 μm a 0,68 μm) e 8 (infravermelho próximo, 0,78 μm a 0,90 μm)). Dados de 100 parcelas de 625 m^2 em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.

	Área Basal
Banda 2**	-0,336*
Banda 3**	-0,349*
Banda 4**	-0,283*
Banda 8**	-0,332*
NDVI**	-0,281*

**Dados transformados em Logaritmo Neperiano; * = p-valor $< 0,05$.

Chama atenção, a baixa capacidade de explicação da banda do vermelho (banda 4, 0,65 μm a 0,68 μm), pois, observando os resultados obtidos em outros trabalhos, ainda que sensores distintos, apontam a banda do vermelho com alta capacidade de explicação da área basal (MENG et al., 2009; MENG et al., 2016; SANTOS et al., 2017).

Quanto ao tipo de relação, positiva ou negativa, resultados semelhantes e contrários, foram relatados. Meng et al. (2009) e Meng et al. (2016) encontraram relação negativa entre a área basal e a faixa do vermelho (0,63 μm a 0,69 μm) do Landsat 7 e vermelho (0,61 μm a 0,68 μm) do SPOT 5, respectivamente, o que corrobora com os resultados observados. Já Santos et al. (2017) encontraram relação positiva entre a área basal e a faixa do vermelho (0,64 μm a 0,67 μm) do Landsat 8 OLI em áreas de Cerrado.

4.3 Caracterização da dependência espacial

4.3.1 Dispersogramas de h

Os dispersogramas de distâncias, para a variável alvo, em quatro raios de distâncias, 0 m a 50 m, 50 m a 100 m, 100 m a 150 m e 150 m a 200 m, podem ser visualizados na Figura 5. Foi observado baixos coeficientes de correlação para a variável, fato este, que pode limitar a sua espacialização por técnicas geoestatísticas. Uma peculiaridade observada é que o maior coeficiente de correlação está no raio de 100 m a 150 m, e não no raio de 0 m a 50 m, embora negativo.

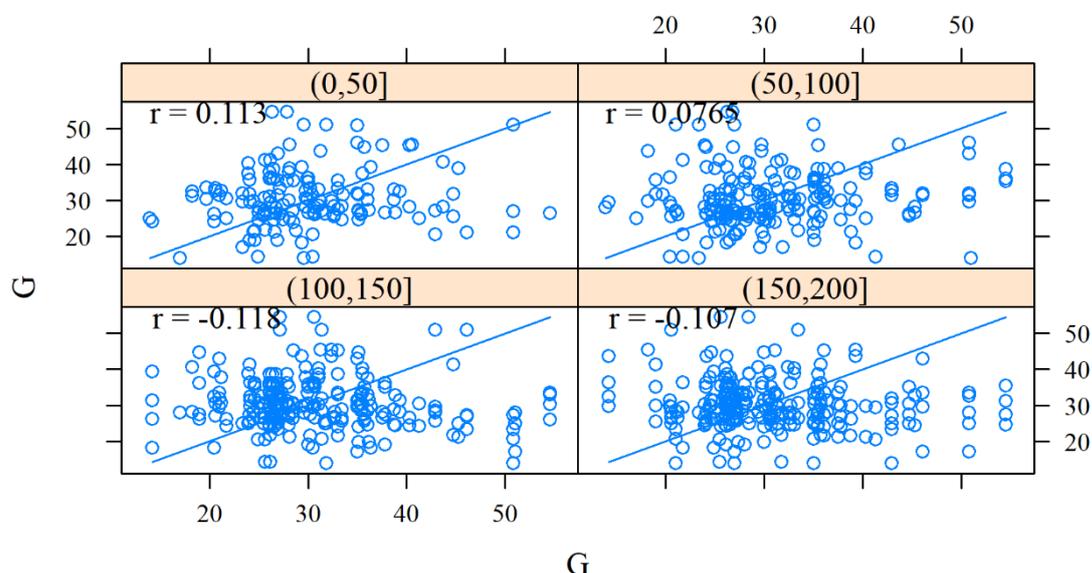


Figura 5. Dispersogramas de h para área basal ($m^2 ha^{-1}$), considerando quatro raios de distâncias: 0 m a 50 m, 50 m a 100 m, 100 m a 150 m e 150 m a 200 m. Dados de 100 parcelas de $625 m^2$ em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.

4.3.2 Semivariogramas

Com base no RMSE da validação cruzada, o modelo exponencial foi o mais preciso para ambas as técnicas de interpolação, krigagem ordinária e cokrigagem ordinária (Figura 6). A contribuição ou *Partial Sill* na cokrigagem ordinária foi negativa, sendo comum quando se considera covariâncias cruzadas, preferencialmente quando a variável alvo e a covariável são inversamente proporcionais. O efeito pepita ou *nugget* obtido na krigagem ordinária, foi elevado e o *range* ou distância que a variável está com certo grau de dependência espacial foi de aproximadamente 150 m. De acordo com a

classificação de Cambardella et al. (1994), a variável apresenta um grau de dependência espacial (GD) moderado, 51%.

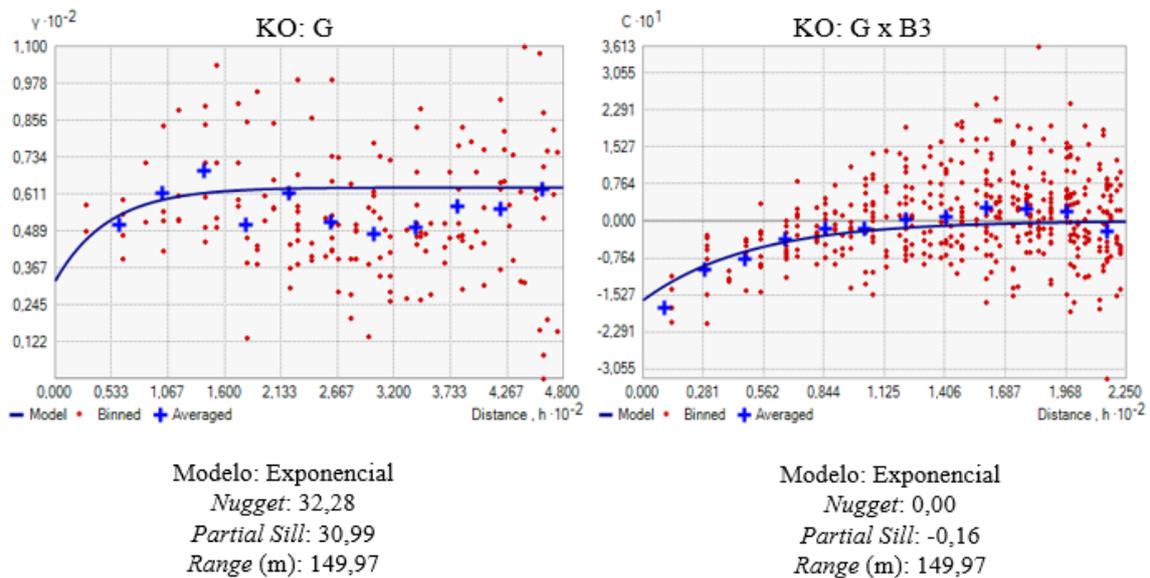


Figura 6. Semivariograma e covariograma cruzado para krigagem ordinária (KO), usando a área basal, e cokrigagem ordinária (CKO), usando a área basal e refletância da banda 3 (verde, 0,54 μm a 0,58 μm) do satélite Sentinel-2A, respectivamente, em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil.

4.4 Interpolação e validação

O mapa temático obtido pela cokrigagem ordinária demonstra uma maior heterogeneidade da variável alvo, na área de estudo, com maior número de *clusters* com áreas menores. Diferentemente do mapa temático obtido pela krigagem ordinária (Figura 7).

Com base no RMSE da validação considerando as parcelas extras, não foi observada melhora na precisão dos mapas com a inclusão das covariáveis na modelagem (Tabela 5). Mas, ambas as técnicas de interpolação, krigagem ordinária e cokrigagem ordinária, apresentaram baixos erros nas estimativas da variável alvo, área basal, considerando uma intensidade de amostragem de 0,25 (25%), ou seja, 6,25 ha de 25 há. Evidenciando, assim, a eficiência das técnicas no mapeamento de métricas da vegetação, bem como a qualidade dos ajustes dos semivariogramas e covariogramas cruzados. Pelissari et al. (2017) considerando uma intensidade de amostragem maior que a do presente estudo, 0,625, obtiveram um RMSE maior, para estimativas da área basal.

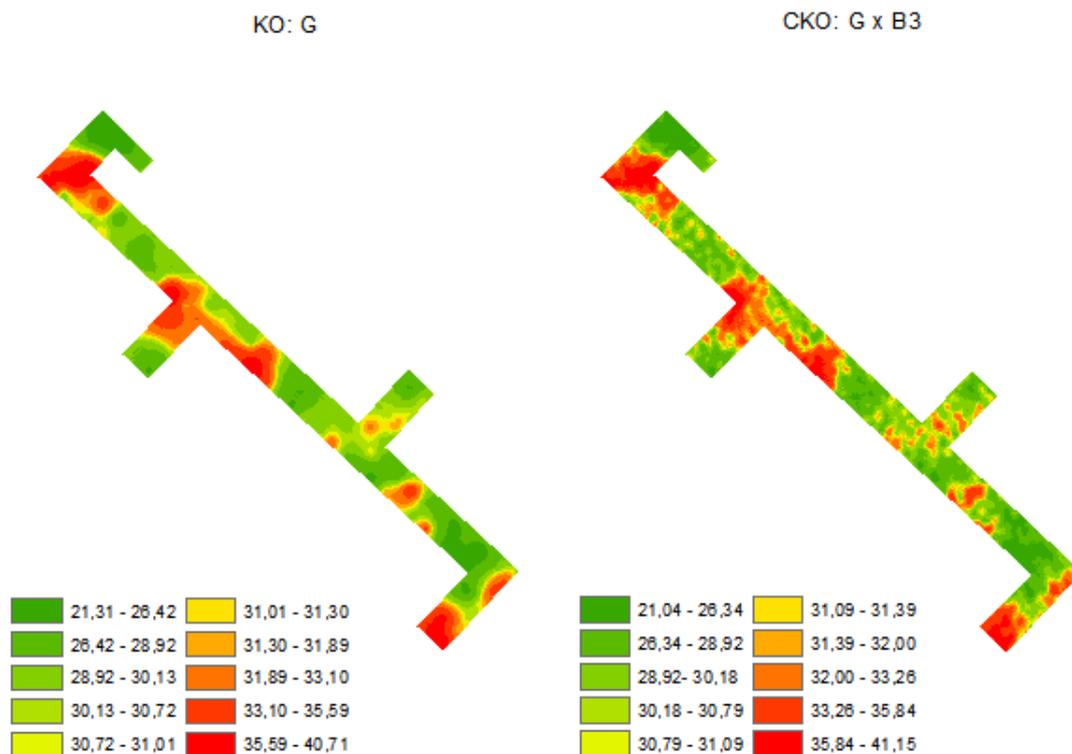


Figura 7. Mapas de predição da área basal ($\text{m}^2 \text{ha}^{-1}$) em fragmento de Floresta Ombrófila Mista no Paraná, região Sul do Brasil, obtidos por meio das técnicas krigagem ordinária e cokrigagem, considerando a refletância da banda 3, do satélite Sentinel-2A.

Tabela 5. Performance das técnicas geoestatísticas: krigagem ordinária e cokrigagem ($n = 50$).

Método	Variáveis	Modelo	RMSE	MR (%)
KO	G	Exponencial	11,3991	
CKO	G + B3	Exponencial	11,4151	-0,14

KO = Krigagem ordinária; CKO = Cokrigagem ordinária; G = Área basal ($\text{m}^2 \text{ha}^{-1}$); RMSE = Raiz do Erro Quadrático Médio; MR = Melhoria Relativa; B3 = banda 3 (verde, $0,54 \mu\text{m}$ a $0,58 \mu\text{m}$).

É conhecido que o potencial dos métodos geoestatísticos multivariados é alto somente se as associações entre as variáveis alvo e covariáveis forem altas. Assim, acredita-se que as baixas associações entre a variável alvo, área basal, com as variáveis auxiliares (covariáveis), refletância das bandas e o NDVI, tenha limitado o desempenho da cokrigagem. Meng et al. (2009), por exemplo, obtiveram coeficientes de correlação maiores e obtiveram estimativas pela cokrigagem mais precisas para a variável área basal.

Esses autores conseguiram uma melhoria relativa de 24,85%, considerando dados derivados de imagens.

5. CONCLUSÕES

A área basal foi negativamente correlacionada com a refletância das bandas e o NDVI. Os maiores coeficientes de correlação foram com as bandas 3 e 2, respectivamente.

De modo geral, as duas técnicas de interpolação mapearam bem a variável alvo (área basal), no entanto, a hipótese considerada de que os dados derivados do Sentinel-2A combinados com técnicas geoestatísticas multivariadas melhoram a precisão do mapeamento da variável área basal, em Floresta Ombrófila Mista, foi rejeitada..

6. REFERÊNCIAS

- AREKHI, M.; YILMAZ, O. Y.; YILMAZ, H.; AKYÜZ, Y. F. Can tree species diversity be assessed with Landsat data in a temperate forest?. **Environmental monitoring and assessment**, v. 189, n. 11, p. 586, 2017.
- BRAGA, L. **Introdução à Geoestatística: com programas em R**. 2015.
- CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of America Journal**, v. 58, n. 5, p. 1501-1511, 1994.
- CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. Guilford Press, 2011.
- CHAVEZ JR., P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, p. 459-479, 1988.
- CHAVEZ JR., P. S. Image-based atmospheric corrections – revisited and improved. **Photogrammetric Engineering and Remote Sensing**, v. 62, n. 9, p. 1025-1036, 1996.

- CHAVEZ JR., P. S. Radiometric calibration of Landsat thematic mapper multispectral images. **Photogrammetric Engineering and Remote Sensing**, v. 55, p. 1285-1294, 1989.
- CLARK, I. **Practical Geostatistics**. Geostokos Limited, Alloa Business Center, 2001.
- CONGEDO, L. **Semi-automatic classification plugin documentation**. Release, 2016.
- DAVIDSON, A.; CSILLAG, F. A comparison of nested analysis of variance (ANOVA) and variograms for characterizing grassland spatial structure under a limited sampling budget. **Canadian Journal of Remote Sensing**, v. 29, n. 1, p. 43-56, 2003.
- EQUIPE DE DESENVOLVIMENTO DO QGIS. **Sistema de Informações Geográficas do QGIS**. Projeto Código Aberto Geospatial Foundation, 2019. Disponível em: <<http://qgis.osgeo.org>>.
- GROSS, J.; LIGGES, U. **Nortest: Tests for Normality** (version 1.0-3). 2015. Disponível em: <<http://CRAN.R-project.org/package=nortest>>.
- HERNÁNDEZ-STEFANONI, J. L.; GALLARDO-CRUZ, J. A.; MEAVE, J. A.; DUPUY, J. M. Combining geostatistical models and remotely sensed data to improve tropical tree richness mapping. **Ecological Indicators**, v. 11, n. 5, p. 1046-1056, 2011.
- HERNÁNDEZ-STEFANONI, J. L.; GALLARDO-CRUZ, J. A.; MEAVE, J. A.; ROCCHINI, D.; BELLO-PINEDA, J.; LÓPEZ-MARTÍNEZ, J. O. Modeling α - and β -diversity in a tropical forest from remotely sensed and spatial data. **International journal of applied earth observation and geoinformation**, v. 19, p. 359-368, 2012.
- IBGE (Instituto Brasileiro de Geografia e Estatística). **Manual Técnico da Vegetação Brasileira: Sistema fitogeográfico Inventário das formações florestais e campestres Técnicas e manejo de coleções botânicas Procedimentos para mapeamentos**. Rio de Janeiro, Brasil, 2012.
- ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. Oxford university press, 1989.
- LI, J.; HEAP, A. D. A review of comparative studies of spatial interpolation methods in environmental sciences: performance and impact factors. **Ecological Informatics**, v. 6, p. 228-241, 2011.

- LI, J.; HEAP, A. D. A. Spatial interpolation methods applied in the environmental sciences: A review. **Environmental Modelling and Software**, v. 53, p.173-189, 2014.
- MADONSELA, S.; CHO, M. A.; RAMOELO, A.; MUTANGA, O. Remote sensing of species diversity using Landsat 8 spectral variables. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 133, p. 116-127, 2017.
- MARTINS, S. V. **Ecologia de Florestas Tropicais do Brasil**. Editora UFV, Universidade Federal de Viçosa, 2012. 371 p.
- MENG, J.; LI, S.; WANG, W.; LIU, Q.; XIE, S.; MA, W. Estimation of forest structural diversity using the spectral and textural information derived from SPOT-5 satellite images. **Remote Sensing**, v. 8, n. 2, p. 125, 2016.
- MENG, Q.; CIESZEWSKI, C.; MADDEN, M. Large area forest inventory using Landsat ETM+: a geostatistical approach. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 1, p. 27-36, 2009.
- MORLEY, P. J.; DONOGHUE, D. N.; CHEN, J. C.; JUMP, A. S. Quantifying structural diversity to better estimate change at mountain forest margins. **Remote sensing of environment**, v. 223, p. 291-306, 2019.
- NAGENDRA, H.; ROCCHINI, D.; GHATE, R.; SHARMA, B.; PAREETH, S. Assessing plant diversity in a dry tropical forest: Comparing the utility of Landsat and IKONOS satellite images. **Remote Sensing**, v. 2, n. 2, p. 478-496, 2010.
- PEBESMA, E. J.; BIVAND, R. S. **Classes and methods for spatial data in R**. R News 5 (2), 2005. Disponível em: <URL <http://CRAN.R-project.org/doc/Rnews>>.
- PELISSARI, A. L.; FIGUEIREDO FILHO, A.; EBLING, A. A., SANQUETTA, C. R.; CYSNEIROS, V. C.; CORTE, A. P. D. Spatial variability of tree species diversity in a mixed tropical forest in Southern Brazil. **Anais da Academia Brasileira de Ciências**, v. 90, n. 2, p. 2491-2500, 2018.
- PELISSARI, A. L.; FIGUEIREDO FILHO, A.; NETTO, S. P.; EBLING, A. A.; ROVEDA, M.; SANQUETTA, C. R. 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.

- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. São Paulo: Oficina de textos, 2012. 176 p.
- RIBEIRO, M. C.; METZGER, J. P.; MARTENSEN, A. C.; PONZONI, F. J.; HIROTA, M. M. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. **Biological conservation**, v. 142, n. 6, p. 1141-1153, 2009.
- ROVEDA, M.; FIGUEIREDO FILHO, A.; PELISSARI, A. L.; GENUÍ, A. M.; ROIK, M. Modelagem geoestatística da estrutura espacial arbórea e dos atributos do solo em Floresta Ombrófila Mista. **FLORESTA**, v. 48, n. 1, p. 67-76, 2018.
- ROVEDA, M.; PELISSARI, A. L.; SANTOS, R. M. M. D. Spatial continuity in a Mixed Ombrophilous Forest with different size and shape of sample units. **Cerne**, v. 22, n. 2, p. 189-196, 2016.
- SANTOS, M. M.; MACHADO, I. E. S.; CARVALHO, E. V.; VIOLA, M. R.; GIONGO, M. Estimativa de parâmetros florestais em área de Cerrado a partir de imagens do sensor Landsat 8. **FLORESTA**, v. 47, n. 1, p. 75-84, 2017.
- SANTOS, P. C.; SANTANA, A. C.; QUEIROZ, J. C. B.; BARROS, P. L. C.; SANTANA, Á. L. Estimativa volumétrica de resíduos lenhosos de madeira em uma Floresta Tropical através da krigagem ordinária, Paragominas, Estado do Pará. **Ciência Florestal**, v. 24, n.4, p. 957-966, 2014.
- SARKAR, D. **Lattice: multivariate data visualization with R**. Springer Science & Business Media, 2008.
- SCHAADT, S. S. **A fragmentação da Floresta Ombrófila Mista em Santa Catarina, analisada a partir de dados do inventário florístico florestal, fotografias aéreas e mapa temático**. 2012. 175 f. Dissertação (Mestrado em Engenharia Ambiental) - Universidade Regional de Blumenau, Blumenau, 2012.
- SCOLFORO, H. F.; SCOLFORO, J. R. S.; MELLO, J. M.; DE MELLO, C. R.; MORAIS, V. A. Spatial interpolators for improving the mapping of carbon stock of the arboreal vegetation in Brazilian biomes of Atlantic forest and Savanna. **Forest Ecology and Management**, v. 376, p. 24-35, 2016.
- SUHET. **Sentinel -2 User Handbook**. ESA Standard Document, 2015.

- TAUBERT, F.; FISCHER, R.; GROENEVELD, J.; LEHMANN, S.; MÜLLER, M. S.; RÖDIG, E.; HUTH, A. **Global patterns of tropical forest fragmentation**. *Nature*, v. 554, n. 7693, p. 519, 2018.
- VIBRANS, A. C.; MCROBERTS, R. E.; LINGNER, D. V., NICOLETTI, A. L.; MOSER, P. Extensão e remanescente de Floresta Ombrófila Mista em Santa Catarina. In: VIBRANS, A. C.; SEVEGNANI, L.; GASPER, A. L.; LINGNER, D. V. **Floresta Ombrófila Mista: Inventário Florístico Florestal de Santa Catarina**. Blumenau: Edifurb, 2013, cap. 2, p. 25-31.
- VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. **Tópicos em ciência do solo**. Viçosa: **Sociedade Brasileira de Ciência do Solo**, v. 1, p. 1-53, 2000.
- WEBSTER, R.; OLIVER, M. A. **Geostatistics for Environmental Scientists**. Chichester: John Wiley and Sons, 2007. 332 p.
- WINAGRASKI, E.; DEUS, K. H. P.; MARCELINO, V. R.; FILHO, P. C. O. Fragmentação florestal do entorno da Floresta Nacional de Irati. **Revista do Centro de Ciências Naturais e Exatas**, v.40, e14, 2018.
- YADAV, B. K.; NANDY, S. Mapping aboveground woody biomass using forest inventory, remote sensing and geostatistical techniques. **Environmental monitoring and assessment**, v. 187, n.5, p. 308, 2015.
- YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de textos, 2013. 215 p.