

MODELO DE REGRESSÃO ESPACIAL PARA ESTIMATIVA DO VOLUME DE UM POVOAMENTO DE TECA

Iasmin Fernanda Portela Pfutz¹

¹Universidade Federal do Paraná - Curitiba, Paraná, Brasil – iasminportela@gmail.com

Resumo

A variável volume é uma das informações de maior importância para a avaliação do potencial produtivo de um povoamento florestal constituindo a principal ferramenta de planejamento da colheita e abastecimento florestal. A análise de regressão linear tem sido muito utilizada quando se pretende obter estimativas de parâmetros da floresta, entretanto os métodos clássicos de regressão não levam em consideração as relações espaciais existentes entre as unidades amostrais. Assim, a utilização de modelos de regressão espacial faz-se necessária para incorporar as relações espaciais no comportamento de fenômeno. Desse modo, o objetivo desse trabalho foi aplicar o modelo de regressão espacial para a estimativa do volume de um povoamento de teca. Para isso, primeiramente foi desenvolvida uma matriz de correlação para identificar as variáveis explicativas mais correlacionadas com o volume do povoamento, posteriormente foi aplicada uma Regressão Linear Múltipla com as variáveis selecionadas. Foi desenvolvido também matrizes de vizinhança para o cálculo da autocorrelação espacial pelo índice Global e Local de Moran. Constatada a dependência espacial foi realizada a regressão espacial pelo modelo definido pelo processo de decisão e multiplicadores de Lagrange. Apenas dois modelos apresentaram dependência espacial pelo índice global de Moran pela matriz 3 de vizinhança, em seguida foi calculada a regressão espacial pelo modelo SAR. Os modelos de regressão foram levemente superiores aos modelos de regressão linear múltipla.

1.INTRODUÇÃO

A *Tectona grandis* L. f., popularmente conhecida como teca, é uma espécie originária do continente asiático, que apresenta rápido crescimento, e cuja madeira é considerada nobre em função da sua durabilidade, resistência ao fogo, pragas e doenças e, por isso, muito utilizada na confecção de móveis de luxo e na construção naval ((KOLLERT; KLEINE, 2017; TEWARI; SINGH, 2017). A expansão da indústria de base

florestal brasileira e consequente aumento na demanda de matéria-prima de qualidade, proporcionaram que os povoamentos de teca se tornassem uma alternativa às espécies de elevado valor econômico como Mogno (*Swetenia macrophylla* G. King) e a Cerejeira (*Torresia acreana* Ducke), fornecendo madeira de qualidade às indústrias (DRESCHER et al., 2014; PELISSARI et al., 2014). No Brasil, os plantios de teca tiveram início na década de 1970 e atualmente há aproximadamente 94 mil hectares de plantios comerciais, localizados principalmente no Estado do Mato Grosso (IBÁ, 2019).

Embora os plantios de teca tenham ganhado destaque no setor florestal brasileiro, muitas vezes os conhecimentos do manejo da espécie são insuficientes e inadequados, devido ao crescimento elevado das espécies na América Central e do Sul, assim como características edafoclimáticas particulares, que dificultam a realização de comparações com regimes de manejo de outras regiões (PELISSARI et al., 2014). Desse modo, é fundamental a elaboração de estudos que venham conhecer a floresta sob a ótica de sua estrutura, principalmente relacionados ao seu crescimento e a produção florestal.

A variável volume é uma das informações de maior importância para a avaliação do potencial produtivo de um povoamento florestal constituindo a principal ferramenta de planejamento, pois, além de dimensionar o estoque e a produtividade da floresta, gera informações que irão direcionar a atividade de colheita e o abastecimento de madeira. Por essa razão, é essencial buscar a obtenção de maneira confiável de parâmetros biométricos da floresta (PEREIRA et al., 2016).

Segundo Schneider et al. (2009), a análise de regressão linear tem sido muito utilizada quando se pretende obter estimativas de parâmetros da floresta, utilizando-se de relações biométricas que possibilitem obter valores estimados de forma direta através de equações de regressão. Entretanto os métodos clássicos de regressão não levam em consideração as relações espaciais existentes entre as unidades amostrais. Assim, a utilização de modelos de regressão espacial faz-se necessária para incorporar as relações espaciais no comportamento do fenômeno.

Desse modo, o objetivo desse trabalho foi aplicar o modelo de regressão espacial para a estimativa do volume de um povoamento de teca.

HIPÓTESES:

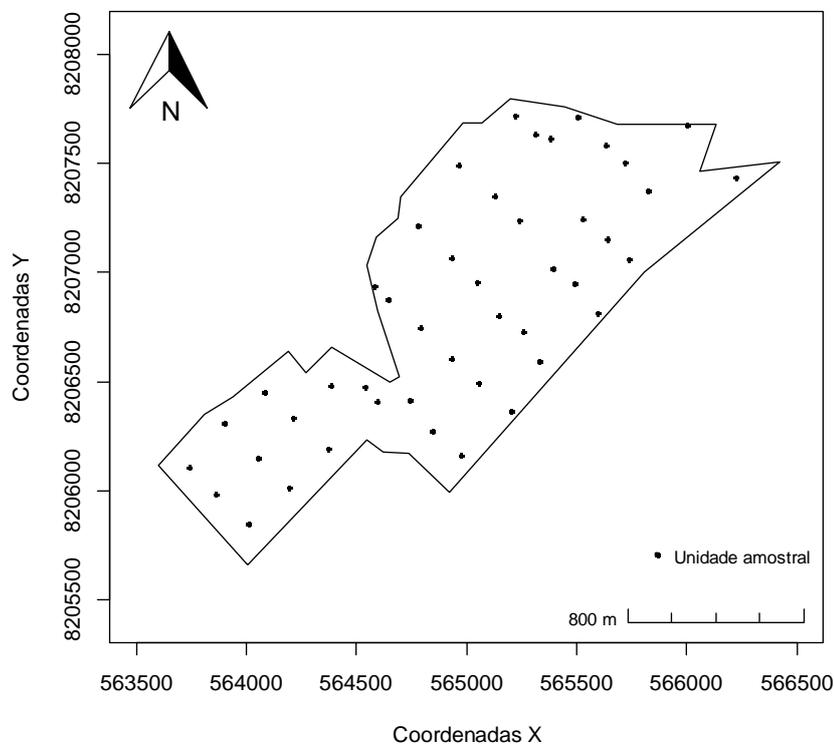
- Há autocorrelação espacial entre as variáveis dendrométricas?
- A inclusão da dependência espacial nos modelos de regressão melhora a estimativa do volume do povoamento de teca?

2.MATERIAL E MÉTODOS

Área de Estudo

As informações utilizadas nesse estudo foram adquiridas em um povoamento de teca (*Tectona grandis* L. f), no município de Nossa Senhora do Livramento, estado de Mato Grosso. O plantio tem 19 anos de idade, foi implantado em 1999 no espaçamento inicial de 3 m x 3 m em 213 ha (FIGURA 1).

FIGURA 1 – COORDENADAS GEOGRÁFICAS DO POVOAMENTO DE TECA E DISTRIBUIÇÃO ESPACIAL DAS UNIDADES AMOSTRAIS.



FONTE: O autor (2020).

Foram realizados 6 desbastes do tipo seletivo, aos seis, nove, doze, quatorze, dezessete e dezenove anos de idade, com remoção média de 35 % do plantio inicial, e 17%, 11%, 5%, 9%, 3% do total de árvores remanescentes, respectivamente nos demais anos. Também foram executadas desramas no segundo, terceiro e quarto ano, seguidas por desramas de manutenção nas idades seguintes.

Variáveis do Povoamento

Para a coleta das variáveis do povoamento, foram alocadas 46 parcelas (FIGURA 1) georreferenciadas de 900 m² (30 m x 30 m), correspondendo a uma densidade inicial de 100 árvores por unidade amostral. Nessas parcelas, os valores das seguintes variáveis dendrométricas foram obtidos, após a realização do desbaste: V – volume do povoamento (m³ ha⁻¹), G – área basal (m² ha⁻¹), \bar{d} – média aritmética dos diâmetros a 1,3 m do solo (cm), \bar{d}_g - diâmetro médio quadrático (cm), \bar{d}_{dom} – diâmetro dominante (cm); \bar{h} – média aritmética das alturas (m); e \bar{h}_{dom} – altura dominante (m). As árvores dominantes foram definidas de acordo com o critério de Assmann (1970).

Seleção das variáveis independentes

As variáveis independentes dos modelos serão escolhidas segundo dois critérios: no primeiro deles a variável deve apresentar elevada correlação com a variável dependente (volume do povoamento) e no segundo critério, as variáveis devem estar pouco relacionadas entre si para evitar multicolinearidade. Para realizar essas escolhas será elaborada uma matriz de correlação de Pearson em que serão consideradas altamente correlacionadas as variáveis que apresentarem $r > 0,9$. Por outro lado, serão considerados pouco correlacionadas as variáveis que apresentarem $r < 0,8$.

Modelos de regressão linear

O modelo de regressão é uma ferramenta que utiliza a relação linear entre duas ou mais variáveis, de modo que uma delas possa ser descrita ou o seu valor estimado a partir das demais. Os modelos de regressão envolvem uma variável resposta dependente e uma ou mais variáveis explicativas independentes (1) (TACHIBANA et al., 2007)

$$Y = \beta_0 + \beta_1 X + \dots + \beta_n X_n + \varepsilon \quad (1)$$

Em que Y = variável dependente; X = variável independente; β_0 e β_1 = coeficientes; ε = erro.

Após a seleção das variáveis independentes foram processadas as regressões lineares múltiplas com o auxílio do software OpenGeoDA 1.16.0.12 (OPENGEODA, 2020) obtendo-se para os modelos, todos os parâmetros β_n das variáveis independentes, a constante do modelo, e os indicadores clássicos de avaliação do modelo, tais como: coeficiente de determinação (R^2 e R^2 ajustado) e teste F.

O coeficiente de determinação é uma medida descritiva da qualidade do ajuste, ou seja, o quanto da variabilidade dos dados é explicado pelo modelo ajustado. Quanto maior o R^2 mais explicativo é o modelo linear. O teste F é utilizado para analisar a variância entre dois conjuntos de dados diferentes e compará-los utilizando o teste de hipóteses.

Em seguida, será realizada uma análise de resíduos para checar a adequabilidade dos dados às premissas do modelo de regressão linear, incluindo:

- I. Normalidade da distribuição dos resíduos da regressão pelo teste de Jarque-Bera;
- II. Constância da variância dos resíduos, medida através do teste de Breusch-Pagan para heteroscedasticidade;
- III. Número da condição de multicolinearidade, que verifica se não há dependência linear perfeita entre as variáveis independentes;

Matriz de Vizinhaça

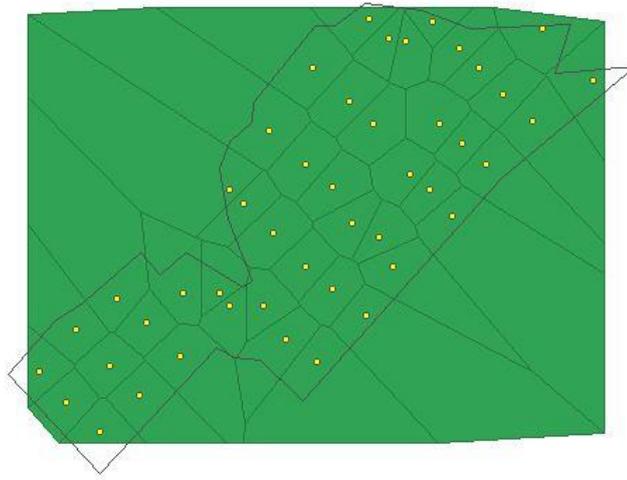
Também chamada de matriz de proximidade espacial, é uma ferramenta para estimar a variabilidade espacial de dados de área. Dado um conjunto de n áreas $\{A_1, \dots, A_n\}$, construímos a matriz $\mathbf{W}^{(1)}$ ($n \times n$), onde cada um dos elementos W_{ij} representa uma medida de proximidade entre A_i e A_j . Esta medida de proximidade pode ser calculada a partir de um dos seguintes critérios (CÂMARA et al., 2004; ARAÚJO et al., 2014):

- I. Critério da Distância entre centroides
 $W_{ij} = 1$, se o centroide de A_i está a uma determinada distância de A_j ; caso contrário $W_{ij} = 0$;
- II. Critério de Contiguidade (torre e rainha)
 $W_{ij} = 1$, se A_i compartilha um lado comum com A_j ; caso contrário $W_{ij} = 0$;
- III. Critério de número de vizinhos
 $W_{ij} = l_{ij}/l_i$, onde l_{ij} é o comprimento da fronteira entre A_i e A_j e l_i é o perímetro de A_i ;

Foram construídas matrizes de vizinhança pelo método de distância entre centroides e pelo método de contiguidade da rainha. Para o método de distância entre centroides, foram testadas três matrizes com parâmetros diferentes, o primeiro foi com os parâmetros padrões do software, chamado de matriz 1. O segundo, chamado de matriz 2, foi alterada a distância entre os centroides, com um valor de 842 metros; e por último além da distância de 842 metros foi habilitado o inverso da distância euclidiana, chamado de matriz 3.

Para o método da contiguidade da rainha, foi construída uma matriz com os parâmetros padrões do software, chamado de matriz 4. Como os dados estão em formato de ponto, foi necessária a conversão em polígono por meio de um mosaico de polígonos Thiessen. Segundo Anselin (2005) a representação poligonal costuma ser útil para a visualização da distribuição espacial de uma variável e permite a construção de pesos espaciais com base na contiguidade (FIGURA 2).

FIGURA 2 – CONVERSÃO DA ÁREA DE ESTUDO EM POLÍGONOS PELO MOSAICO DE POLÍGONOS DE THIESSSEN.



FONTE: O autor (2020).

Autocorrelação Espacial

A autocorrelação espacial mede quanto o valor observado de um atributo em uma região é independente dos valores dessa mesma variável em localidades vizinhas (UPTON & FINGLTON, 1985). Para o desenvolvimento da modelagem estatística espacial utilizou-se do Índice Global de Moran (I) (2) e Indicador Local de Associação Espacial (LISA) para estimar o nível de autocorrelação espacial entre as áreas.

$$I = \frac{n \sum_{i=j}^n \sum_{j=1}^n W_{ij} (Z_i - \bar{Z})(Z_j - \bar{Z})}{(\sum_{i=1}^n (Z_i - \bar{Z})^2)(\sum \sum_{i \neq j} W_{ij})}, \text{ para } i \neq j \quad (2)$$

Em que n = número de populações (n polígonos); Z_i = valor do atributo considerado na área i ; \bar{Z} = valor médio do atributo na região de estudo; W_{ij} = elemento na matriz normalizada de vizinhança para o par i e j ;

Valores de índice de Moran próximos a 1 indicam forte nível de autocorrelação espacial positiva, nesse caso valores atribuídos às áreas adjacentes estão fortemente correlacionados. Os valores de índice de Moran próximos a -1 sugerem forte nível de autocorrelação negativa, conhecida como perfeita dispersão. Por fim, valores de índice de Moran próximos de 0 demonstram ausência de autocorrelação espacial (FARBER, 2013).

Além disso, foi calculado o LISA (3) (*Local Indicators of Spatial Association*) que busca captar padrões de associação local, dessa forma, é possível verificar se o fenômeno se distribui em todos o espaço de forma estacionária ou se existem regiões de não-estacionariedade com características próprias diferentes do restante das zonas (ANSELIN, 1995; DRUCK et al., 2004).

$$I = \frac{x_i - \mu}{\sigma_0^2} \sum_{j=1}^n (x_j - \mu), i = 1, \dots, n \quad (3)$$

Em que: σ_0^2 = variância populacional da variável em estudo; x_i = observação de uma variável de interesse; μ = média da população

A estatística LISA pode ser interpretada da seguinte forma: valores positivos de I_i (autocorrelação espacial positiva) significa que valores semelhantes são encontrados em locais vizinhos. Quando valores diferentes são encontrados em locais vizinhos, é dito que ocorre a associação espacial negativa. Associação zero implica um conjunto de observações espacialmente aleatórias (PAEZ, 2005; ARAÚJO et al., 2014).

O LISA produz um valor específico para cada unidade de análise, observando seus vizinhos sendo possível identificar os agrupamentos espaciais onde o LISA é significativo (ANSELIN, 1995). A vantagem desse método é que o resultado irá indicar os agrupamentos, isto é, clusters indicando regiões com objetos de valores semelhantes,

assim como áreas de transição e outliers indicando regiões com objetos anômalos (CAMARGO; FELGUEIRAS, 2015).

Regressão Espacial

A inclusão de efeitos espaciais em modelos de regressão pode ser feita, a partir de modelos com efeitos espaciais globais que supõem que é possível capturar a estrutura de correlação espacial em um único parâmetro, que é adicionado ao modelo de regressão tradicional (DRUCK et al., 2004). Têm-se duas opções: a primeira é pelo modelo SAR (4) (*Spatial Autoregressive Model* ou *Spatial Lag Model*) que atribui a autocorrelação espacial a variável dependente (Y).

$$Y = X\beta + \rho WY + \varepsilon \quad (4)$$

Em que: W = matriz de proximidade espacial; WY = expressa a dependência espacial em Y; ρ = coeficiente espacial autorregressivo

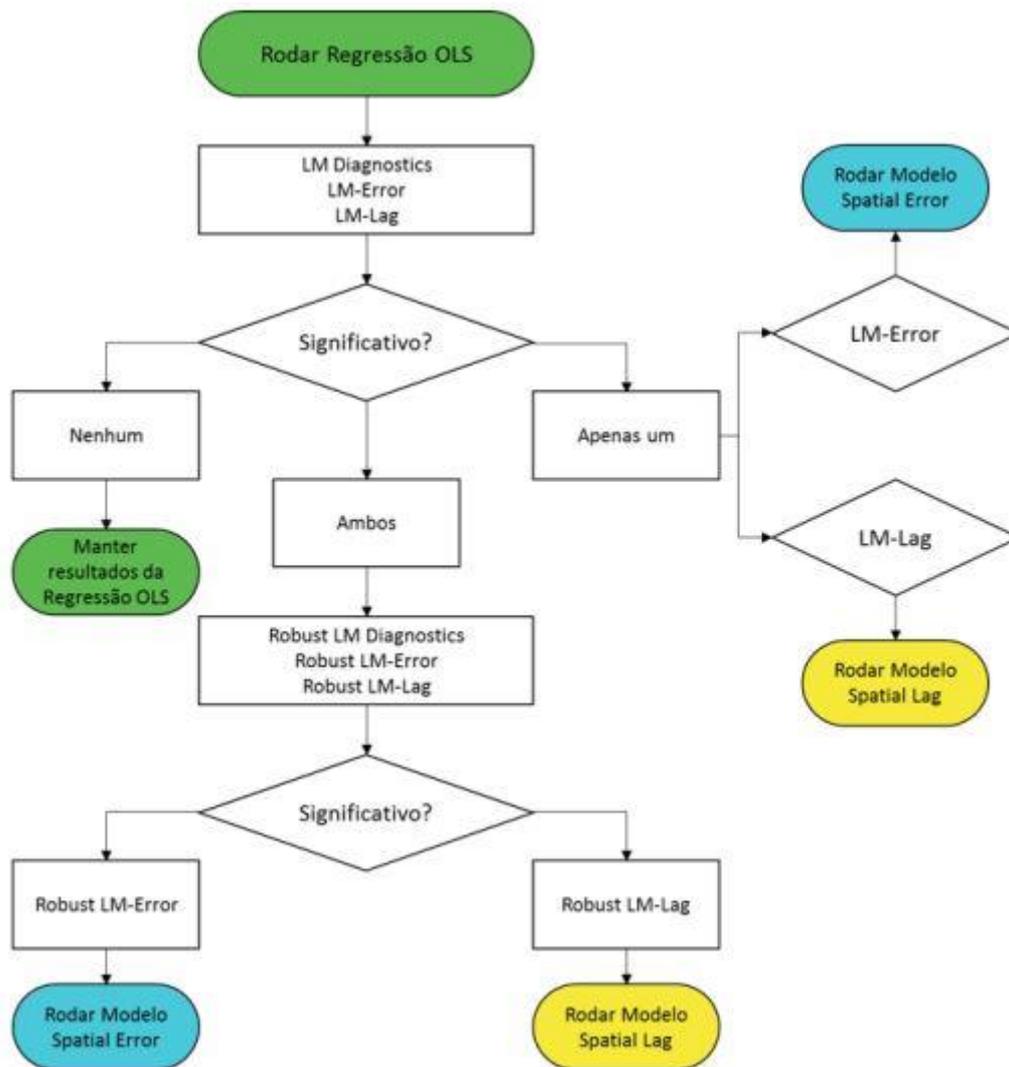
A segunda alternativa, é pelo modelo CAR (4) (*Conditional Autoregressive Model* ou *Spatial Error Model*), que considera os efeitos espaciais como um ruído deve ser removido.

$$Y = X\beta + \lambda W\varepsilon + \xi \quad (5)$$

Em que: $W\varepsilon$ = componente do erro com efeito espacial; λ = coeficiente autorregressivo; ξ = componente do erro com variância constante e não correlacionada;

As estimativas dos parâmetros das equações 3 e 4 são obtidos pelo método da Máxima Verossimilhança. Para a distinção de qual modelo utilizar, utilizou-se o processo de decisão para regressão espacial (FIGURA 3) e o teste de Multiplicadores de Lagrange (LM) (ANSELIN, 2005).

FIGURA 3 – PROCESSO DE DECISÃO REGRESSÃO ESPACIAL.



FONTE: ANSELIN (2005).

Comparação Regressão Linear e Regressão Espacial

Constatada a autocorrelação espacial e realizada a regressão espacial, é necessário comparar os modelos de regressão linear com os modelos de regressão espacial, para avaliar o desempenho e atestar se o modelo de regressão espacial aperfeiçoou a estimativa do volume do povoamento.

Serão utilizadas três medidas para manter a comparabilidade com o ajuste dos modelos de regressão espacial: log da vizinhança, Critério de Akaike e Critério de Schwarz. Essas medidas são baseadas em uma suposição de normalidade multivariada e a função de verossimilhança correspondente para o modelo de regressão padrão. Quanto maior o log da vizinhança melhor será o ajuste (alto na linha real, portanto menos negativo

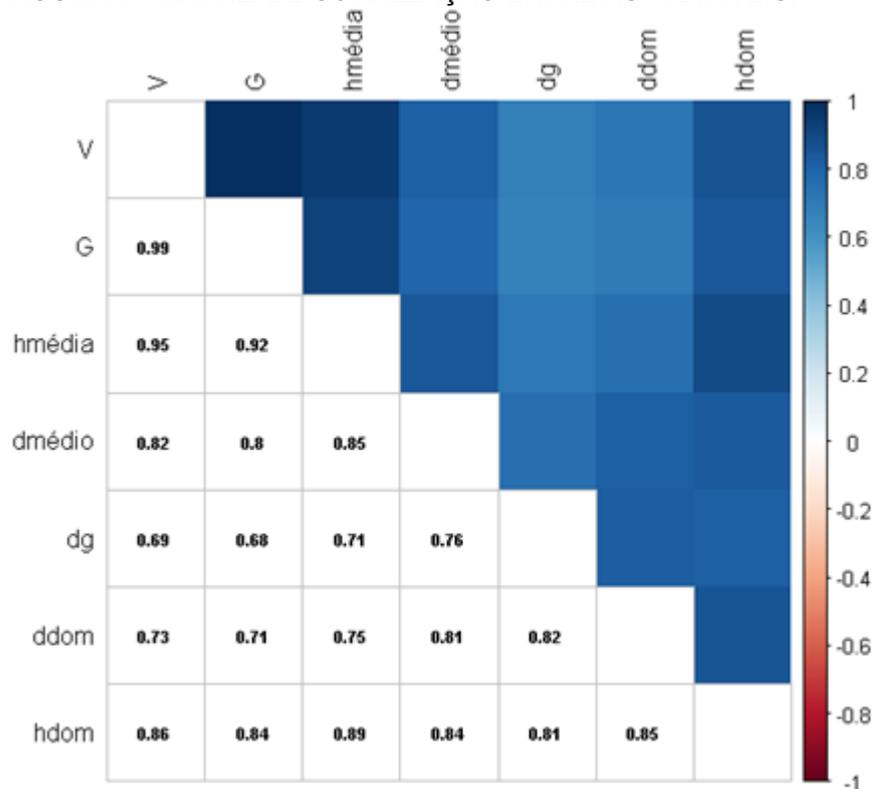
é melhor). Para os critérios de Akaike e de Schwarz, quanto menor a medida melhor o ajuste (ANSELIN, 2005).

3. RESULTADOS E DISCUSSÕES

Seleção das variáveis independentes

Primeiramente, foi realizada uma matriz de correlação (FIGURA 4) entre as variáveis do povoamento, para verificar quais variáveis se correlacionam melhor com a variável dependente volume do povoamento.

FIGURA 4 – MATRIZ DE CORRELAÇÃO ENTRE AS VARIÁVEIS.



Fonte: O autor (2020).

Pela matriz de correlação (FIGURA 3) observa-se que a variável área basal (G) apresentou maior coeficiente de correlação de Pearson (0,99) com a variável volume do povoamento. Em seguida, verificou-se que as variáveis, diâmetro médio quadrático (d_g) e diâmetro dominante (d_{dom}) apresentaram a menor correlação com a variável G , assim os

modelos de regressão foram construídos utilizando as variáveis independentes selecionadas (6 e 7).

$$Y = \beta_0 + \beta_1 G + \beta_2 d_g \quad (6)$$

$$Y = \beta_0 + \beta_1 G + \beta_2 d_{dom} \quad (7)$$

Outra variável que apresentou alto coeficiente de correlação de Pearson (0,95) foi a variável média aritmética das alturas (\bar{h}), e as variáveis que apresentaram os menores valores de correlação com a \bar{h} foram o diâmetro médio quadrático (d_g) e o diâmetro dominante (d_{dom}), assim os modelos de regressão foram construídos utilizando as variáveis independentes selecionadas (8 e 9)

$$Y = \beta_0 + \beta_1 \bar{h} + \beta_2 d_g \quad (8)$$

$$Y = \beta_0 + \beta_1 \bar{h} + \beta_2 d_{dom} \quad (9)$$

Modelos de regressão linear

Em seguida, foi realizada a análise de regressão linear multivariada com os modelos acima. Primeiramente foi observado se os resíduos atenderam as premissas da regressão (linearidade, multicolinearidade e normalidade) (TABELA 1).

TABELA 1 – DIAGNÓSTICO DA REGRESSÃO.

Modelo	Teste de Multicolinearidade	Teste Jarque-Bera	Teste Breusch-Pagan	Teste White
$V = \beta_0 + \beta_1 G + \beta_2 d_g$	31,28	0,601	0,818	0,327
$V = \beta_0 + \beta_1 G + \beta_2 d_{dom}$	33,33	0,588	0,892	0,419
$V = \beta_0 + \beta_1 \bar{h} + \beta_2 d_g$	35,04	0,961	0,646	0,171
$V = \beta_0 + \beta_1 \bar{h} + \beta_2 d_{dom}$	38,22	0,603	0,637	0,230

Fonte: O autor (2020).

Segundo Anselin (2005), o número da condição de multicolinearidade acima de 30 sugere problemas com a estabilidade dos resultados da regressão. A Tabela 1 mostra que todas as variáveis apresentaram valores de multicolinearidade acima de 30, indicando que as variáveis estão correlacionadas entre si.

O teste de normalidade de Jarque-Bera apresentou significância para todos os modelos, p-valor maior que 0,05, indicando que os resíduos apresentam distribuição normal. Já o teste de Breusch-Pagan testa a homoscedasticidade dos dados, cuja significância (p-valor) foi maior que 0,05, logo os resíduos apresentam homoscedasticidade.

Matriz de Vizinhaça e Autocorrelação Espacial

As matrizes de vizinhaça foram construídas no GeoDA no Menu \rightarrow *Tool* \rightarrow *Weights Manager*, compondo um total de 4 matrizes (matriz 1, 2, 3 e 4). Com as matrizes foi possível calcular o índice Global de Moran (TABELA 2) para verificar a presença de autocorrelação espacial.

TABELA 2 – ÍNDICE GLOBAL DE MORAN.

Modelo	Índice Global de Moran			
	Matriz 1	Matriz 2	Matriz 3	Matriz 4
$V = \beta_0 + \beta_1 G + \beta_2 d_g$	0,0819 (0,9347)	1,3760 (0,1688)	1,9971 (0,0458)	-0,1853 (0,8530)
$V = \beta_0 + \beta_1 G + \beta_2 d_{dom}$	0,1964 (0,8442)	1,7443 (0,0811)	1,9854 (0,0471)	0,1932 (0,8468)
$V = \beta_0 + \beta_1 \bar{h} + \beta_2 d_g$	0,2070 (0,8359)	-1,9316 (0,0534)	-0,8473 (0,3968)	0,1651 (0,8688)
$V = \beta_0 + \beta_1 \bar{h} + \beta_2 d_{dom}$	0,2032 (0,8389)	-1,9185 (0,0550)	-0,8517 (0,3944)	0,1432 (0,8861)

Em que: matriz 1: distância entre centroides parâmetros padrões; matriz 2: distância entre centroides com 842 metros; matriz 3: distância entre centroides de 842 metros e inverso da distância; matriz 4: contiguidade rainha; entre parêntesis tem-se o nível descritivo p-valor.

Fonte: O autor (2020)

Pode-se observar que os níveis descritivos (p-valor) são menores que 0,05 (nível de significância) apenas para os dois primeiros modelos e com a matriz 3 (distância entre centroides de 842 m e inverso da distância), indicando autocorrelação espacial significativa a 5% de probabilidade. Além disso as maiores autocorrelações espaciais ($I > 1,3$) foram encontradas para esses dois modelos pela matriz de proximidade 2 e 3.

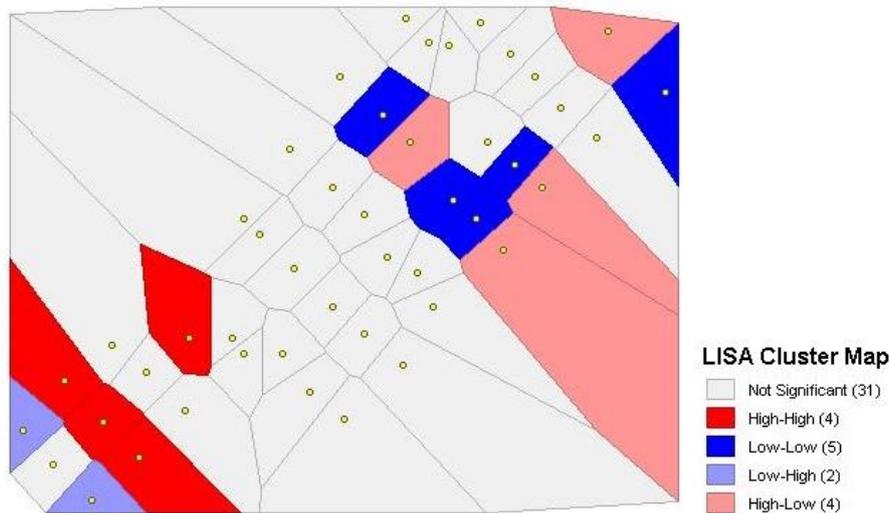
Os menores valores de autocorrelação espacial ($I < 0,20$) foram verificados para todos os modelos com as matrizes de vizinhaça 1 e 4. Além disso, valores de

autocorrelação negativo foram observados para os modelos $V = \beta_0 + \beta_1 G + \beta_2 d_g$, $V = \beta_0 + \beta_1 \bar{h} + \beta_2 d_g$ e $V = \beta_0 + \beta_1 \bar{h} + \beta_2 d_{dom}$, com as matrizes de vizinhança 2, 3 e 4, indicando o fenômeno de perfeita dispersão.

Em seguida, foi calculado o LISA para identificar melhor os agrupamentos dos dados, revelando assim padrões locais de associação espacial. Com o LISA Cluster Map (FIGURA 5 e 6) foi possível visualizar a ocorrência de agrupamentos de elevados e baixos valores (high-high e low-low) de volume do povoamento para ambos os modelos que apresentaram dependência espacial.

FIGURA 5 - MAPA DE RESÍDUOS DA ANÁLISE DE REGRESSÃO MÚLTIPLA DO MODELO

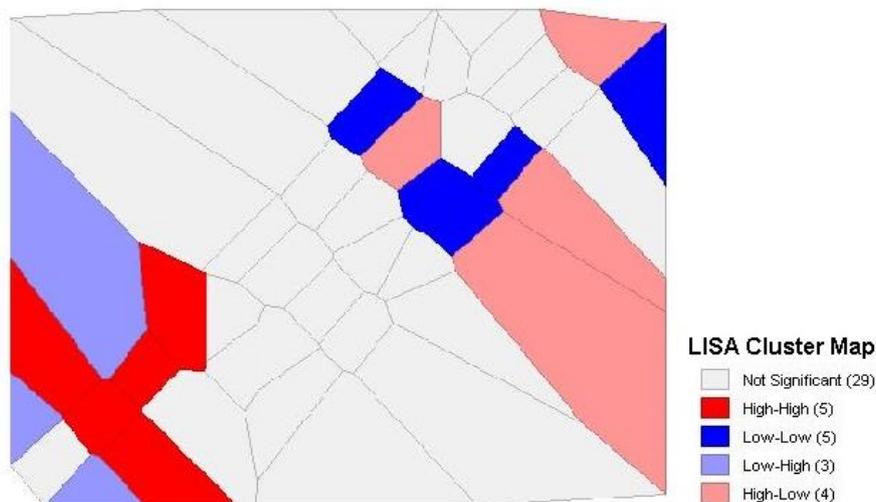
$$V = \beta_0 + \beta_1 G + \beta_2 d_g$$



FONTE: O autor (2020).

FIGURA 6 – MAPA DE RESÍDUOS DA ANÁLISE DE REGRESSÃO MÚLTIPLA DO MODELO

$$V = \beta_0 + \beta_1 G + \beta_2 d_{dom}$$



Fonte: O autor (2020).

Regressão Espacial

Constatada a dependência espacial pelo índice de Moran para os modelos $V = \beta_0 + \beta_1 G + \beta_2 d_g$ e $V = \beta_0 + \beta_1 G + \beta_2 d_{dom}$ pela matriz 3 de vizinhança, utilizou-se dos testes multiplicadores de Lagrange para averiguar qual modelo de regressão espacial (Lag ou Error) proporcionam os melhores ajustes (TABELA 3).

TABELA 3 – DIAGNÓSTICO DA DEPENDÊNCIA ESPACIAL.

Modelo	<i>I Moran</i> <i>Matriz 3</i>	<i>LM Lag</i>	<i>Robusto</i> <i>LM Lag</i>	<i>LM Error</i>	<i>Robusto</i> <i>LM Error</i>
$V = \beta_0 + \beta_1 G + \beta_2 d_g$	1,9971 (0,0458)	7,7404 (0,0054)	7,1555 (0,0074)	0,7886 (0,3745)	0,2037 (0,6517)
$V = \beta_0 + \beta_1 G + \beta_2 d_{dom}$	1,9854 (0,0471)	8,8162 (0,0029)	8,2046 (0,0041)	0,8076 (0,3688)	0,1959 (0,6580)

Fonte: O autor (2020).

A Tabela 3, demonstra a partir da análise do p-valor do Multiplicadores de Lagrange, que para ambos os modelos se recomenda a utilização do modelo SAR (*Spatial Lag*) pois apresentaram significância estatística a 5%. No modelo 1 e 2 o p-valor 0,0054 e 0,0029, respectivamente, foi menor que 0,05 (nível de significância).

Por fim, no software GeoDA foi executada a regressão espacial pelo modelo SAR no Menu → *Regression*.

Comparação Regressão Linear e Regressão Espacial

Na Tabela 4, pode-se observar a comparação entre os modelos de regressão linear e regressão espacial, utilizando os parâmetros: coeficiente de determinação, log da vizinhança, Critério de Akaike e de Schwarz.

TABELA 4 – INDICADORES DE QUALIDADE DA REGRESSÃO LINEAR E ESPACIAL.

$V = \beta_0 + \beta_1 G + \beta_2 d_g$	Regressão Linear	Regressão Espacial - SAR
R ²	0,9843	0,9869
Log da Vizinhança	-170,58	-167,50
AIC	347,16	343,00
SC	352,65	350,32

$V = \beta_0 + \beta_1 G + \beta_2 d_{dom}$	Regressão Linear	Regressão Espacial - SAR
R ²	0,9850	0,9876
Log da Vizinhança	-169,54	-166,18
AIC	345,09	340,37
SC	350,57	347,69

Em que: AIC: Critério de Akaike; SC: Critério de Schwarz.

FONTE: O autor (2020).

Comparando o desempenho do SAR ao da análise de regressão linear múltipla (TABELA 4), é possível constatar um desempenho levemente superior dos modelos SAR pois este apresentou valores menos negativos do log da vizinhança e menores valores do Critério de Akaike (AIC) e de Schwarz (SC).

4. CONCLUSÃO

Verificou-se de autocorrelação espacial do volume do povoamento e as variáveis dendrométricas G , D_g e D_{dom} pelo índice de Moran. Os modelos aplicados de regressão espacial (SAR) com efeitos globais apresentaram resultados levemente melhores quando comparados ao modelo de regressão múltipla clássica, indicando que a inclusão da dependência espacial nos modelos melhora a estimativa do volume do povoamento de teca, porém não de uma forma tão significativa.

Sendo assim, sugere-se que outros métodos de matrizes de vizinhança sejam testados para observar e comparar qual representa melhor a estrutura de dependência espacial das variáveis, e resultaria numa estimativa com resultados mais significativos

REFERÊNCIAS

ANSELIN, L. Local Indicators of Spatial Association—LISA. *Geographical Analysis*, v. 27, n. 2, p. 93–115, 1995

ANSELIN, L. Exploring Spatial Data with GeoDa: A Workbook Center for Spatially Integrated Social Science. **Center for Spatially Integrated Social Science**, p. 244, 2005.

ARAÚJO, E. C.; URIPE-OPAZO, M. A.; JOHANN, J. A. Modelo de regressão espacial para estimativa da produtividade da soja associada a variáveis agrometeorológicas na região oeste do estado do Paraná. **Engenharia Agrícola Jaboticabal**, v. 34, n. 2, p. 286-299, 2014.

CÂMARA, G.; MONTEIRO, A. M. V. Conceitos básicos em ciência da geoinformação. São José dos Campos: INPE, 2004. 346 p.

CAMARGO, E.; FELGUEIRAS, C. Análise de padrão de áreas. São José dos Campos: INPE, 2015. Notas de aula. 5, 7

DRESCHER, R.; GAVA, F. H.; PELISSARI, A. L.; ACOSTA, F. C.; SILVA, V. S. M. Equações volumétricas para *Tectona grandis* Linn F. em povoamentos jovens no estado de Mato Grosso. **Advances in Forestry Science**, v. 1, n. 2, p. 65-70, 2014.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. Análise Espacial de Dados Geográficos. Brasília: EMBRAPA, 2004. ISBN 85-7383-260-6.

FARBER, S. **GEOG 3020 Lecture 23-4 Spatial Autocorrelation**. Disponível em: <<https://www.youtube.com/watch?v=O2W9IbVIUbE>>.

IBÁ – INSTITUTO BRASILEIRO DE ÁRVORES. **Anuário estatístico do IBÁ 2019, ano base 2018**. Brasília: IBÁ, 2019. 80 p.

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. 108 p.

OPENGEODA. GeoDa center for geospatial analysis and computation. 2020. Disponível em: <https://geodacenter.github.io/download.html>

PÁEZ. Spatial statistics for urban analysis: A review of techniques with examples. **GeoJournal**, v. 61, n. 1, p. 53, 2005.

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.

PEREIRA, A. R. S.; CORDEIRO, M. A.; ABREU, J. C.; SANTOS, R. O.; SILVA, J. N. M. Modelagem volumétrica para *Eucalyptus urograndis* no município de Porto Grande, Amapá, Brasil. **Biota Amazônia**, v. 6, n. 4, p. 10-14, 2016.

SCHNEIDER, P. R.; SCHNEIDER, P. S. P; SOUZA, C. A. M. **Análise de Regressão aplicada à Engenharia Florestal**. 2. Ed- Santa Maria: FACOS, 2009. 294p.

TACHIBANA, V. M. Aplicação De Técnicas Utilizando Regressão Classica E Espacial Na Cidade De Presidente Prudente – Sp. p. 24–27, 2007.

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.

UPTON, G.; FINGLETON, B. Spatial data analysis by example. New York: Wiley, 1985.