

ROGÉRIO ALVES SANTANA

**AVALIAÇÃO DE TÉCNICAS GEOESTATÍSTICAS NO INVENTÁRIO DE
POVOAMENTOS DE *Tectona grandis* L.f.**

Dissertação apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação em
Estatística Aplicada e Biometria,
para obtenção do título de *Magister
Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2011

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

S232a
2011

Santana, Rogério Alves, 1978-
Avaliação de técnicas geoestatísticas no inventário de
povoamentos de *Tectona grandis* L.f. / Rogério Alves
Santana. – Viçosa, MG, 2011.
x, 43f. : il. ; 29cm.

Orientador: Nerilson Terra Santos.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 46-49

1. Geoestatística. 2. Inventário florestal. 3. Biometria.
4. Predição (Matemática) – Métodos. 5. Dendrometria.
I. Universidade Federal de Viçosa. II. Título.


CDD 22. ed. 519.5

ROGÉRIO ALVES SANTANA

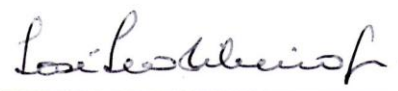
**AVALIAÇÃO DE TÉCNICAS GEOESTATÍSTICAS NO INVENTÁRIO DE
POVOAMENTOS DE *Tectona grandis* L.f.**

Dissertação apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação em
Estatística Aplicada e Biometria,
para obtenção do título de *Magister
Scientiae*.

APROVADA: 20 de junho de 2011.



Prof. Carlos Pedro Boechat Soares



Prof. José Ivo Ribeiro Júnior



Prof. Nerilson Terra Santos
(Orientador)

Simplesmente a Deus.

AGRADECIMENTOS

Ao meu orientador professor Nerilson Terra Santos, pela boa vontade e maneira como me orientou; e aos professores coorientadores Antônio Policarpo Souza Carneiro e Helio Garcia Leite, pela boa vontade em me receber e me orientar.

Aos professores Carlos Pedro Boechat Soares e José Ivo Ribeiro Júnior, pelas valiosas sugestões ao participarem da banca de aprovação deste trabalho.

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

Aos meus colegas e amigos do Departamento de Estatística Diana Campos, Elisângela de Oliveira, Karla Celeste Menezes, Gemma Lúcia Dubock, Liliane Lopes Cordeiro, Fernanda Vidal, Luciane da Silva; aos meus grandes amigos (gaúchos) André Mendes e Luiz Carlos Damasceno; e aos meus colegas do Departamento de Informações Espaciais Wellington Donizete, Leila, Inês e Giovani Egg.

E aos meus grandes amigos Tiago Otávio, Valéria Rosado e Maria das Graças (Graça do xerox), pelo companheirismo.

Enfim, a todas as pessoas que, de certa maneira, participaram da realização deste trabalho.

BIOGRAFIA

ROGÉRIO ALVES SANTANA, filho de Anesiana Santana Ferreira e Batista Alves Ferreira, nasceu em Santa Helena de Goiás, em 11 de maio de 1978.

Em março de 2000, iniciou o curso de Licenciatura Plena em Ciências - Habilitação em Matemática - na Universidade de Rio Verde (FESURV), Goiás, concluindo-o em dezembro de 2003.

Em março de 2004, matriculou-se no curso de especialização (*Lato Sensu*) em Matemática e Estatística pela FESURV, Goiás, finalizando-o em fevereiro de 2005.

Em março de 2009, ingressou no Programa de Pós-Graduação,, em nível de Mestrado, em Estatística Aplicada e Biometria da Universidade Federal de Viçosa, em Viçosa, Minas Gerais, submetendo-se à defesa da Dissertação em 20 de junho de 2011.

SUMÁRIO

	Página
RESUMO	vii
ABSTRACT	ix
1. INTRODUÇÃO.....	1
2. REFERÊNCIAL TEÓRICO.....	4
2.1. Inventário florestal.....	4
2.2. Estatística clássica.....	5
2.3. Geoestatística	6
2.4. Semivariograma.....	8
2.5. Modelos teóricos de semivariogramas.....	11
2.6. Interpolação espacial (krigagem)	12
2.7. Validação cruzada	14
2.7.1. Média dos erros preditos (M)	15
2.7.2. Média do erro padronizada (MS)	15
2.7.3. Raiz quadrada da média do erro ao quadrado (RMS)	16
2.7.4. Média da variância dos erros padronizados (ASE)	16
2.7.5. Raiz Quadrada da média dos erros padronizados ao quadrado (RMSS).....	16
2.8. Índice de dependência espacial (IDE)	17
2.9. Erro de amostragem	17

	Página
3. MATERIAL E MÉTODOS.....	19
3.1. Softwares utilizados	19
3.2. Região.....	19
3.3. Análise exploratória dos dados	20
3.4. Métodos de estimação de parâmetros da estatística clássica	21
3.5. Estudo semivariográfico.....	22
3.6. Modelos de semivariograma avaliados	22
3.7. Ajuste do modelo de semivariograma	23
3.8. Seleção do modelo de semivariograma	24
3.9. Predição por geoestatística.....	25
3.10. Erro de amostragem num inventário florestal	26
4. RESULTADOS E DISCUSSÃO	28
4.1. Análise exploratória dos dados	28
4.2. Modelos de semivariograma ajustados.....	29
4.3. Escolha do modelo de semivariograma	32
4.4. Predições geoestatísticas do inventário florestal	33
4.5. Estimativas clássicas do inventário florestal	36
4.6. Comparação das predições geoestatísticas <i>versus</i> clássicas	36
5. CONCLUSÃO	39
6. REFERÊNCIAS	40

RESUMO

SANTANA, Rogério Alves, M. Sc., Universidade Federal de Viçosa, junho de 2011. **Avaliação de técnicas geoestatísticas no inventário de povoamentos de *Tectona grandis* L.f.** Orientador: Nerilson Terra Santos. Coorientadores: Antônio Policarpo Souza Carneiro e Helio Garcia Leite.

Este trabalho teve por objetivos geral avaliar se as estimativas do volume de madeira obtidas a partir de técnicas geoestatísticas são mais precisas do que as obtidas a partir de técnicas da estatística clássica. O estudo foi realizado em povoamentos de *Tectona grandis* L.f. com a característica dendrométrica de volume mensurada em 101 parcelas lançadas ao longo de uma malha de amostragem com coordenadas UTM, distribuídas em 17 talhões, com uma área total de 391,87 ha. Com o ajuste do modelo semivariograma experimental, do índice de dependência espacial e das estatísticas da validação cruzada, foram obtidas duas estimativas do inventário florestal: uma utilizando estatística clássica e a outra, geoestatística. Na realização da estimação clássica, foi considerada a metodologia de amostragem sistemática, com a intensidade de amostragem de uma parcela para cada 4 ha. Na predição por geoestatística, foi ajustado o modelo de semivariograma, utilizado para avaliar a estrutura de dependência espacial da variável volume por ha na área de estudo. Em

seguida, utilizou-se a krigagem em blocos para obter as predições do volume médio de cada talhão. A comparação das estimações dos dois métodos foi feita com base no erro de amostragem, sendo encontrado um menor erro com a geoestatística. Conclui-se, assim, o uso da geoestatística para realização de inventário florestal, quando existir estrutura de dependência espacial na região em estudo, uma vez que ela fornece predições mais precisas.

ABSTRACT

SANTANA, Rogério Alves, M. Sc., Universidade Federal de Viçosa, June of 2011. **Evaluation of geostatistics in inventory of *Tectona grandis* L.f. stands.** Adviser: Nerilson Terra Santos Land. Co-Advisers: Antonio Policarpo Souza Carneiro and Helio Garcia Leite.

The general objective of this work was to evaluate if estimates of wood volume obtained from geostatistics techniques are more accurate than those obtained from classical statistical techniques. The study was conducted in stands of *Tectona grandis* L.f. with the dendometric volume trait measured in 101 plots laid along a sampling spacing with UTM coordinates, distributed in 17 plots with a total area of 391.87 ha. By adjusting the experimental semivariogram model, index of spatial dependence and cross-validation statistics it was obtained two estimates of the forest inventory: one by using the classical statistics and the other by using geostatistics. Methodology of systematic sampling with intensity of sampling of one plot for every 4 ha was used in the conduction of the classical estimation. A semivariogram model, used to assess the structure of spatial dependence of the variable volume per ha in the study area was adjusted in the prediction by geostatistics. Then, block kriging was used to obtain predictions of the average volume of each plot. Comparison of the two methods of estimation was made based on the

sampling error, in which a minor error with geostatistics was found. Therefore, it is concluded geostatistics should be used for forest inventory when there is spatial dependence structure in the region under study inasmuch as it provides more accurate predictions.

1. INTRODUÇÃO

O sucesso no estabelecimento de um plano de manejo para uma floresta equiânea depende muito do nível de conhecimento sobre os três elementos essenciais do manejo: a classificação de terras e da capacidade produtiva, o estabelecimento de prescrições e a prognose (DAVIS; JOHNSON, 1987). O primeiro e o terceiro elemento envolvem o emprego de modelos e sistemas de equações lineares e não lineares, quando as pressuposições da análise de regressão são verificadas, ou por meio de equações diferenciais. Dados dessa modelagem podem ser oriundos de parcelas permanentes específicas de parcelas de inventário florestal contínuo (IFC) ou de análises parcial e completa de tronco (CAMPOS; LEITE, 2009). Em qualquer caso, os dados das parcelas são obtidos por meio de delineamentos de amostragens seletiva (melhor opção), aleatória (usual em IFC) ou sistemática (usual em inventários de pré-corte-IFPC).

Quando a amostragem é feita visando ao estudo do crescimento e da produção, não é necessário atender a um erro de amostragem específico, sendo mais importante a representatividade das variações no povoamento. Entretanto, no caso do IFC e do IFPC o atendimento de um erro de amostragem preestabelecido é um dos principais objetivos ao definir um plano de amostragem (CAMPOS; LEITE, 2009). Esse erro é definido de acordo com órgãos ambientais e as empresas florestais.

Ao realizar um inventário por meio de amostragem, sempre irão ocorrer dois tipos de erros: o de amostragem (EA) e o de não amostragem (ENA). O primeiro ocorre pelo fato de se utilizarem dados de apenas parte do povoamento (conjunto de parcelas ou de unidades de amostra que a constitui). O segundo pode ocorrer devido a equívocos na medição, na transcrição de dados, na compilação ou, ainda, na escolha do método de amostragem (LÖETSCH et al., 1964; LÖETSCH et al., 1973; HUSCH et al., 1982; CAMPOS; LEITE, 2009).

O erro de amostragem é expresso pelo erro-padrão da média, associado a uma distribuição t, de Student, em um nível de probabilidade desejado. Portanto, o EA pode ser administrado com certa facilidade, alterando o tamanho e o número de unidades de amostra. Como a variância entre parcelas aumenta com o aumento da área das parcelas e a variância da média, bem como o valor de t, diminuem com o aumento do número de unidades de amostra, é necessário encontrar um meio termo entre muitas parcelas, pequenas ou poucas parcelas grandes. O setor florestal já tem uma definição muito precisa em relação ao tamanho e forma ideal de parcelas para diferentes tipos de inventário e de regimes e objetivos de manejo (CAMPOS; LEITE, 2009).

Inventários de pré-corte que visam à obtenção de dados e subsídios para o planejamento das atividades relacionadas com a colheita de madeira geralmente são feitos com intensidade de amostragem relativamente alta. Conforme Assis (2005), saber a localização adequada das unidades amostrais dentro dos povoamentos é imprescindível para garantir a representatividade da floresta e a qualidade das estimativas.

Em alguns tipos de povoamentos podem ocorrer autocorrelações entre parcelas de inventário, e, nesse caso, métodos geoestatísticos podem ser mais apropriados para obter as predições da produção. Um dos métodos de predição espacial é a krigagem (WANG et al., 2005). Esse método permite prever pontos não amostrados a partir de pontos amostrados, considerando-se a dependência do fenômeno em estudo (LEGLEITER; KYRIAKIDIS, 2008).

Apesar de a geoestatística ter sido definida na década de 1960 e difundida para várias áreas na década de 1980, ainda existem poucos

trabalhos publicados no setor florestal. No setor florestal, boa parte de suas publicações usando geoestatística envolve sensoriamento remoto. No setor florestal, a realização de inventário florestal utilizando técnicas geoestatísticas envolve a krigagem e o inverso do quadrado da distância. Assis (2005), Guedes (2009) e Mello (2004) empregaram a krigagem para predizer o volume de madeira produzida em povoamento florestal. Mello et al. (2006) utilizaram a krigagem em bloco para reduzir a intensidade amostral num povoamento de *Eucalyptus* sp. Na literatura, grande parte das publicações abrange a krigagem, para predizer volume total e definição de estratos. No entanto, nem sempre um povoamento florestal apresentará estrutura de dependência espacial adequada para se utilizar a krigagem.

Mediante o exposto, este trabalho foi desenvolvido em povoamentos de *Tectona grandis* L.f. localizados na Região Centro-Oeste do Brasil. Tem-se a hipótese de que inventários realizados com técnicas geoestatísticas são mais precisos que os inventários realizados utilizando estatística clássica.

Este trabalho teve por objetivo geral avaliar se as estimativas do volume de madeira obtidas a partir de técnicas geoestatísticas são mais precisas do que as conseguidas a partir de técnicas da estatística clássica.

Especificamente, os objetivos foram:

- Modelar a estrutura de continuidade espacial da característica dendrométrica volume da espécie *Tectona grandis* L.f.
- Estimar o volume de madeira utilizando a estatística clássica e a geoestatística em uma região de estudo.

2. REFERÊNCIAL TEÓRICO

2.1. Inventário florestal

As informações necessárias para o manejo e planejamento da produção florestal são obtidas por meio do inventário florestal. Essas informações podem ser qualitativas, como em aspectos ambientais da região, o estado fitossanitário, as qualidades dos fustes e as quantitativas, a exemplo de volume de madeira, área basal, diâmetro médio e frequência de árvores por hectare. Tais informações são necessárias para o desenvolvimento do inventário florestal e a realização da colheita de madeira (SILVA et al., 2008).

No inventário florestal são utilizadas técnicas de amostragem para estimar características quantitativas e qualitativas da floresta (MELLO, 2004). Diferentes procedimentos de amostragem podem ser empregados, sendo a amostragem casual simples realizada quando a população é homogênea ou casual estratificada quando a população é heterogênea. Nesse caso, a população é dividida em subpopulações homogêneas. A amostragem pode ser ainda sistemática, com ou sem pré-estratificação. Os procedimentos ACS, ACE e AS são utilizados tanto na estatística clássica quanto na espacial (CRESSIE, 1993). Em alguns casos, é feita uma pós-estratificação com base na própria característica avaliada.

O sucesso do inventário florestal está ligado à definição correta do processo de amostragem e do tamanho e forma das unidades amostrais (UBIALLI et al., 2009). Na teoria de amostragem da estatística clássica, supõe-se que os valores da variável sejam independentes, não levando em consideração, portanto, a autocorrelação entre os valores dessa variável.

Técnicas de geoestatística, entretanto, consideram a existência de dependência entre os valores observados e têm sido empregadas no setor florestal. Rufino et al. (2006) utilizaram a análise geoestatística combinada com o geoprocessamento para mapear a variabilidade espacial da produtividade da população de *Eucalyptus* sp. para realizar inventário florestal.

2.2. Estatística clássica

As informações referentes à biometria florestal são obtidas com a realização de inventário florestal. Essas informações consistem, na maioria das vezes, em estimar o parâmetro volume médio e seu intervalo de confiança em determinado povoamento. Tais estimações são obtidas por meio de procedimentos de amostragem utilizando a estatística clássica, em que ela supõe que a variável em estudo seja aleatória e sua variação seja espacialmente independente, isto é, não leve em consideração a sua estrutura espacial, mas, sim, a sua variação ou dispersão. A estrutura de autocorrelação espacial da variável pode ser neutralizada pelo princípio da casualização utilizado na estatística clássica, pois seu objetivo é apenas avaliar a sua dispersão em torno da média pelo desvio-padrão e não a sua estrutura espacial.

Com isso se espera que o valor médio de um fenômeno amostrado em dado local de uma região seja igual ao valor médio esperado do fenômeno para qualquer local dentro dessa região, associado a um erro de predição correspondente à variância dos dados amostrados (COCHRAN, 1977; MELLO, 2004; TRANGMAR et al., 1987).

Na amostragem utilizando a estatística clássica, considera-se que a variação de uma variável pode ser decomposta pela soma de duas componentes: uma determinística associada a um valor médio; e a outra, um

erro aleatório, representado pela equação 1 (GUEDES, 2009; MELLO, 2004).

$$V(x) = \mu(x) + \varepsilon \quad (1)$$

em que $\mu(x)$ é função determinística que descreve a componente estrutural $V(x)$ em x ; x é a representação genérica de uma coordenada geográfica que a variável $V(x)$ assumirá na região de estudo; e ε é um erro aleatório de cada observação com média zero e variância σ^2 .

A análise dos erros ε é fundamental na estatística, pois o que se espera é que os erros sejam independentes e sigam algum tipo de distribuição probabilidade para realizar inferências.

2.3. Geoestatística

A geoestatística surgiu na década de 1950, a partir de publicações de Daniel Krige, engenheiro de Minas Auríferas da África do Sul. Krige (1951) percebeu que as variâncias obtidas pela estatística clássica não faziam sentido se não considerasse a distância entre os locais onde foram observadas as amostras. Baseado nas publicações de Krige, Matheron (1963) formulou a teoria da geoestatística, que trata as variáveis como variáveis regionalizadas, em que ele define variável regionalizada como a função espacial numérica, que varia de um local para outro, com continuidade aparente e cuja variação não pode ser representada por uma simples função matemática (MELLO, 2004).

Essa teoria supõe a existência de dependência espacial entre as variáveis, ou seja, correlação dos valores das variáveis com a distância dos pontos de onde eles foram obtidos. Portanto, diferente da estatística clássica, que supõe independência espacial entre os valores das variáveis (MELLO, 2004).

A teoria das variáveis regionalizadas (VR) desenvolvida por Matheron pressupõe que cada observação $V(x_i)$ pode ser modelada como variável aleatória. Essa teoria supõe que a variação espacial de uma VR pode ser

decomposta na soma de três componentes: uma componente estrutural associada a um valor médio constante ou uma tendência constante; uma componente aleatória espacialmente correlacionada; e um erro aleatório (DRUCK et al., 2004; GUEDES, 2009; MELLO, 2004).

Se o vetor x representa posição com n -dimensões, então o valor da função aleatória ou variável $V(x)$ é dado por:

$$V(x) = \mu(x) + \varepsilon'(x) + \varepsilon'' \quad (2)$$

em que $\mu(x)$ é função determinística que descreve a componente estrutural $V(x)$ em x ; $\varepsilon'(x)$ é um termo estocástico ou aleatório, autocorrelacionado,, que varia localmente no espaço; $\varepsilon''(x)$ é um erro aleatório não correlacionado no espaço, com média zero e variância ν (GUEDES, 2009; MELLO, 2004).

A geoestatística utiliza o conceito das VR para prever valores de observações não amostradas. Essas previsões são obtidas através da modelagem da estrutura espacial do termo estocástico. Essa modelagem é obtida através de uma função de momentos estatísticos de ordem k , com a restrição de que os momentos sejam idênticos para qualquer direção em uma área de estudo.

Essa restrição propõe que uma VR seja definida como uma função aleatória (FA), a qual representa um conjunto de variáveis aleatórias $V(x)$, em que $V(x_i)$ corresponde a uma única realização de $V(x)$. Supõe-se que todas as variáveis aleatórias da FA apresentem idênticas distribuições de probabilidades e idênticos momentos estatísticos.

Em circunstâncias, em que o segundo momento não se verifica, a hipótese de estacionariedade é substituída pela “hipótese intrínseca”, que consiste na estacionariedade apenas do variograma e não da variância. Nesta hipótese, portanto, assume-se que para dada distância h o primeiro momento seja constante e o variograma seja constante.

O primeiro momento, ou seja, a esperança matemática para a variável $V(x)$, para uma distância h é obtido por:

$$E[V(x)] = E[V(x+h)] = \mu, \quad \forall h; \quad (3)$$

Por sua vez, a hipótese intrínseca supõe que o variograma da variável regionalizada $V(x)$ existe para uma distância h e é obtido por:

$$2\gamma(h) = E[V(x) - V(x+h)]^2 \quad (4)$$

2.4. Semivariograma

A medida de dispersão dos dados em torno da média na estatística clássica é realizada pela variância. Na geoestatística, a variância das variáveis regionalizadas é caracterizada pela semivariância, que corresponde à metade da variância espacial. Portanto, a função semivariograma corresponde à metade da função variograma, a qual é obtida por:

$$\gamma(h) = \frac{1}{2} E[V(x) - V(x+h)]^2 \quad (5)$$

em que $\gamma(h)$ corresponde à função de semivariâncias em função da distância (semivariograma), $V(x)$ é o valor da observação amostrada do ponto na posição x e $V(x+h)$ representa a observação do ponto $x+h$, com determinada distância h , que corresponde a distância.

O semivariograma corresponde uma função matemática que descreve o gráfico da semivariância em função da distância h , e seu estimador, o semivariograma experimental, é obtido pela metade da média aritmética do quadrado das diferenças entre os pares de pontos separados por uma distância h .

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [V(x_i) - V(x_i+h)]^2 \quad (6)$$

em que $\hat{\gamma}(h)$ é o estimador do semivariograma experimental, que representa o gráfico das semivariâncias em função da distância h ; $V(x_i)$ é o valor observado da variável no ponto amostrado x_i ; $V(x_i + h)$ é o valor observado da variável num ponto a uma distância h de x_i e $N(h)$ é o número de pares de pontos separados entre si por uma distância h (ADELMAN et al., 2008; LIMA et al., 2008).

Com o ajuste do semivariograma experimental, obtêm-se os parâmetros: efeito pepita (τ^2), contribuição (σ^2), patamar (ν) e alcance (ϕ). Eles, além de auxiliarem na descrição da dependência espacial, são responsáveis pelo ajuste de um modelo teórico a um semivariograma empírico, utilizado para modelar a estrutura de dependência espacial em função da distância (KOZAR et al., 2002). A Figura 1 representa um modelo típico de semivariograma experimental, e seus parâmetros efeito pepita, contribuição, patamar e o alcance são responsáveis pelo ajuste da dependência espacial.




Figura 1 – Modelo típico de semivariograma experimental com os parâmetros efeito pepita (τ^2), contribuição (σ^2) e alcance (ϕ).

O efeito pepita (τ^2) é o valor da semivariância para (h) igual a zero. Seu valor representa a descontinuidade do semivariograma na origem. O efeito pepita representa a variância aleatória que o modelo de semivariograma conseguiu captar. Geralmente, ele é atribuído a erros de mensuração (LANDIM, 2003).

Quando ocorre a inexistência de dependência espacial entre as variáveis regionalizadas, o modelo ajustado é de efeito pepita puro. Nesse caso, não é recomendada, sendo sugerido o uso de outros métodos de interpolação (LANDIM, 2003).

O modelo de efeito pepita puro é difícil de ocorrer na prática. Uma possível explicação para tal resultado é o fato de a malha de amostragem não ter sido suficiente para captar a variabilidade espacial (ASSIS, 2005).

O patamar (ν) é o valor-limite do semivariograma, o que corresponde à soma do efeito pepita (τ^2) com contribuição (σ^2), tal que essa contribuição se estabiliza a partir de determinada distância. A distância (h), a partir da qual os valores das semivariâncias se estabilizam, é denominada alcance (ϕ). O alcance do semivariograma representa a zona de influência de uma observação e separa o campo estruturado (amostras espacialmente correlacionadas) do campo aleatório (amostras espacialmente independentes), como pode ser visto na Figura 2.

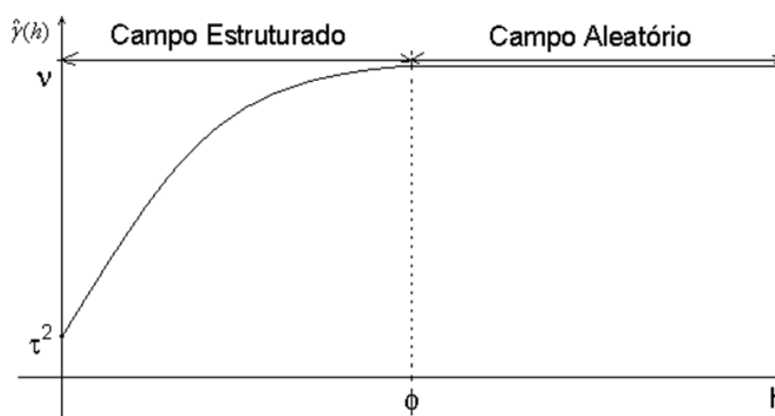


Figura 2 – Gráfico do semivariograma com os parâmetros efeito pepita (τ^2), patamar (ν) e alcance (ϕ) e a representação de seus campos estruturado e aleatório.

Fonte: SILVA et al., 2011, p. 8.

2.5. Modelos teóricos de semivariogramas

As características do semivariograma experimental são responsáveis pela escolha de um modelo de semivariograma teórico, para representar a estrutura espacial desse fenômeno em estudo. Há vários modelos teóricos de semivariograma. No entanto, eles devem ser positivos definidos ou a matriz de krigagem não possuirá inversa definida (SOARES, 2006).

Os principais modelos de semivariogramas são esférico, exponencial e gaussiano.

Esférico

$$\gamma(h) = \left\{ \begin{array}{ll} \sigma^2 \left[\frac{3 \|h\|}{2 \phi} - \frac{1}{2} \left(\frac{\|h\|}{\phi} \right)^3 \right] & \text{para } 0 \leq \|h\| \leq \phi \\ \sigma^2 & \text{para } \|h\| \geq \phi \end{array} \right\} \quad (7)$$

Exponencial

$$\gamma(h) = \left\{ \begin{array}{ll} \sigma^2 \left[1 - \exp\left(\frac{-3\|h\|}{\phi}\right) \right] & \text{para } \textit{todo } \|h\| \end{array} \right\} \quad (8)$$

Gaussiano

$$\gamma(h) = \left\{ \begin{array}{ll} \sigma^2 \left[1 - \exp\left(-3\left(\frac{\|h\|}{\phi}\right)^2\right) \right] & \text{para } 0 < \|h\| \leq \phi \\ \sigma^2 & \text{para } \|h\| > \phi \end{array} \right\} \quad (9)$$

2.6. Interpolação espacial (krigagem)

A krigagem é um interpolador geoestatístico que permite prever valores de variáveis distribuídas no espaço, utilizando as propriedades estruturais do semivariograma (LANDIM, 2003). O preditor da krigagem é considerado como o Best Linear Unbiased Predictor “BLUP”, ou seja, o melhor preditor linear não viesado, por fornecer variância mínima (GAETAN; GUYON, 2010; BRUS; GRUIJTER, 1997). A interpolação da krigagem para um ponto x_0 é obtida por:

$$\hat{V}(x_0) = \sum_{i=1}^K \lambda_i V(x_i) \quad (10)$$

em que $\hat{V}(x_0)$ é o preditor da krigagem, $V(x_i)$ é o valor observado na posição x_i , e λ_i são os pesos associados a k observações de vizinhança obtidos pela krigagem com a condição de que a soma dos pesos seja igual a 1 (WONG et al., 2004; LAGACHERIE; VOLTZ, 2000). A variância de predição é obtida por:

$$\hat{\sigma}_0^2 = \sum_{i=1}^K \lambda_i \gamma(x_i, x_0) + \mu \quad (11)$$

em que $\hat{\sigma}_0^2$ é o preditor da variância de krigagem, $\gamma(x_i, x_0)$ é a semivariância entre os pontos amostrados x_i e ponto que se quer prever x_0 , λ_i são os pesos associados a k observações de vizinhança obtidos pela krigagem com a condição de que a soma dos pesos seja igual a 1 e μ é o ponderador de Lagrange, que dá a condição para que a soma dos pesos seja igual a 1 (SOARES, 2006).

O interpolador também pode ser escrito por um sistema de equações de krigagem, cuja solução minimiza a variância predição (BARDOSSY; LEHMANN, 1998).

$$\sum \lambda_i \gamma(x_i, x_j) + \mu = \gamma(x_i, x_0) \quad \text{com} \quad i = 1, \dots, N \quad (12)$$

$$\sum \lambda_i = 1 \quad (13)$$

- em que $\gamma(x_i, x_j)$ é a semivariância entre pontos amostrados x_i e x_j , em que j corresponde à posição $x_i + h$;
- $\sum \lambda_i$ é o somatório dos pesos atribuídos aos pontos vizinhos x_i com a condição de ser igual a 1;
- μ é o multiplicador de Lagrange necessário para satisfazer a condição $\sum \lambda_i = 1$;
- $\gamma(x_i, x_0)$ é a semivariância entre cada ponto amostrado x_i e o ponto x_0 que se quer predizer.

Além do modelo proposto na fórmula (12), que é a krigagem ordinária (KO) que considera a média da VR como constante, há outros tipos de krigagem: krigagem simples (KS), que considera a média como conhecida; krigagem universal (KU), quando há tendência nos dados; krigagem indicativa (KI), recomendada quando a variável é binária, ou seja, assumindo valor zero ou 1 e a cokrigagem (CK), que está associada ao campo multivariado. Entretanto, elas só poderão ser utilizadas quando houver dependência espacial, ou seja, a variabilidade não for totalmente aleatória (YAMAMOTO, 2001).

A krigagem pode ser pontual ou em bloco. A krigagem pontual prediz o valor de um ponto. A krigagem em blocos é utilizada para obter a predição do valor médio de uma área. A diferença na utilização delas está no vetor de semivariâncias. Na krigagem pontual, os elementos que compõem o vetor de semivariâncias são as semivariâncias de um ponto amostrado em relação ao ponto não amostrado. Na krigagem em bloco, os elementos que compõem o vetor de semivariância são as médias das semivariâncias entre os pontos amostrados e aqueles contidos no bloco, sendo este a subárea ou local que se quer predizer.

A krigagem ordinária em blocos pode ser obtida através da solução de um sistema de equações de krigagem:

$$\sum \lambda_j \gamma(x_i, x_j) + u = \bar{\gamma}(x_i, \mathbf{B}) \quad \text{com} \quad \alpha = 1, \dots, N \quad (14)$$

$$\sum \lambda_\alpha = 1 \quad (15)$$

em que:

- $\gamma(x_i, x_j)$ é a semivariância dos pontos amostrados x_i com o seu vizinho x_j ;
- $\sum \lambda_j$ é o somatório dos pesos dos pontos vizinhos x_j ;
- μ é o multiplicador de Lagrange necessário para satisfazer a condição $\sum \lambda_i = 1$;
- $\bar{\gamma}(x_i, \mathbf{B}) = \frac{1}{N_B} \sum_{i=1}^{N_B} \gamma(x_i, x_\alpha)$ é a semivariância média entre cada amostra x_i e o conjunto dos pontos \mathbf{N}_B que compõe o bloco \mathbf{B} , onde x_α está contido;
- $\sum \lambda_i = 1$ é o somatório dos pesos dos pontos x_i , com a restrição do multiplicador de Lagrange, para obtenção de predições não viesadas.

2.7. Validação cruzada

A validação cruzada é um método de seleção do modelo semivariográfico e dos seus parâmetros, pois permite selecionar o modelo teórico que melhor descreve a dependência espacial das observações entre as variáveis em função das distâncias. Para Hernández et al. (2009), essa técnica é útil para avaliar a capacidade do semivariograma ajustado e modelar a incerteza do atributo não amostrado.

Para realizar validação cruzada, supõe-se que um elemento da amostra não tenha sido observado, e obtém-se a predição dele pela krigagem, usando os valores dos pontos vizinhos. Esse processo é realizado em todos os pontos amostrados. No final, em cada ponto amostrado existirão o valor verdadeiro e o valor predito, sendo possível, portanto, obter estimativa do erro de predição. Estatísticas associadas a esses erros, também denominados resíduos, são obtidas para selecionar o melhor modelo de semivariograma. Algumas delas são apresentadas nos tópicos subsequentes.

2.7.1. Média dos erros preditos (M)

Uma medida que avalia a precisão de uma predição pode ser obtida pela média do erro de predição. Essa medida consiste na média da diferença entre o valor predito e o valor amostrado. Quando esse valor é igual zero, essa predição é não viesada. Caram (2007) utilizou as estatísticas da validação cruzada tal como a média do erro de predição para a escolha do modelo teórico de semivariograma.

$$M = \frac{\sum_{i=1}^n (\hat{V}(x_i) - V(x_i))}{n} \quad (16)$$

em que $V(x_i)$ é o valor observado dos pontos amostrados, $\hat{V}(x_i)$ é o valor dos pontos preditos pela krigagem e n é o número de pontos amostrados.

2.7.2. Média do erro padronizada (MS)

Quando se deseja comparar ajuste de modelos de variáveis de escalas diferentes, realiza-se a padronização dos erros, dividindo cada desvio pela raiz quadrada da variância do seu erro de predição.

$$AS = \frac{\sum_{i=1}^n (\hat{V}(x_i) - V(x_i)) / \hat{\sigma}(x_i)}{n} \quad (17)$$

em que $V(x_i)$ é o valor dos pontos amostrados, $\hat{V}(x_i)$ é o valor dos pontos preditos pela krigagem, $\hat{\sigma}(x_i)$ é o valor obtido pela raiz quadrada da variância do erro de predição do ponto x_i e n é o número de pontos amostrados.

2.7.3. Raiz quadrada da média do erro ao quadrado (RMS)

O RMS, a raiz quadrada do erro médio ao quadrado é utilizado para avaliar a qualidade da predição obtida por determinado método (MCBRATNEY et al., 2000).

$$RMS = \sqrt{\frac{\sum_{i=1}^n (\hat{V}(x_i) - V(x_i))^2}{n}} \quad (18)$$

em que $V(x_i)$ é o valor observado dos pontos amostrados, $\hat{V}(x_i)$ é o valor dos pontos preditos pela krigagem e n é o número de pontos amostrados.

2.7.4. Média da variância dos erros padronizados (ASE)

O ASE é utilizado para comparar diferentes modelos de predição. Se o ASE for menor que o RMS, o modelo proposto estará subpredizendo a variabilidade da predição (ESRI, 2001).

$$ASE = \sqrt{\frac{\sum_{i=1}^n \hat{\sigma}^2(x_i)}{n}} \quad (19)$$

em que $\hat{\sigma}^2(x_i)$ é a variância do erro de predição e n é o número de pontos amostrados.

2.7.5. Raiz Quadrada da média dos erros padronizados ao quadrado (RMSS)

O RMSS também é utilizado para a escolha do modelo teórico de semivariograma.

$$RMSS = \sqrt{\frac{\sum_{i=1}^n (\hat{V}(x_i) - V(x_i)) / \hat{\sigma}(x_i)}{n}}^2 \quad (20)$$

Se RMSS for menor que 1, a predição do modelo proposto poderá estar superpredizendo a variabilidade da predição; caso contrário, estará subpredizendo-a.

O melhor modelo de semivariograma será aquele que apresentar as estatísticas M e MS próximas de zero, valores semelhantes em RMS e ASE e RMSS próximo de 1 (ESRI, 2001).

2.8. Índice de dependência espacial (IDE)

A autocorrelação entre as variáveis pode ser considerada uma simetria das variáveis em relação à distância, ou seja, variáveis mais próximas são mais semelhantes entre si. A medida que expressa grau de autocorrelação ou dependência espacial de uma variável pode ser obtida utilizando os parâmetros do modelo de semivariograma. Camdarbella et al. (1994) propuseram o índice de dependência espacial (IDE), o qual é expresso pelo quociente entre o efeito pepita e o patamar, para estimar a dependência espacial das propriedades do solo em Iowa, EUA. Esses autores classificaram os possíveis valores desse índice em categorias. Dependência espacial forte ocorre quando o índice é menor que 25%, moderada quando está entre 25 e 75% e fraca quando for maior que 75%. Algebricamente, o IDE é obtido por:

$$IDE(\%) = 100 \times \frac{\tau^2}{\tau^2 + \sigma^2} \quad (21)$$

2.9. Erro de amostragem

Em povoamentos florestais, a medida de precisão da estimação da média populacional é obtida pelo erro de amostragem. Isso também pode ser obtido em percentagem pelo quociente entre o erro-padrão da média

associado a uma distribuição t , de Student, e a predição da média amostral. Algebricamente, o erro de amostragem é obtido por:

$$E(\%) = \pm \left(\frac{t_\alpha \times s_{\bar{y}}}{\bar{y}} \right) \times 100 \quad (22)$$

erro-padrão para populações finitas

$$s_{\bar{y}} = \pm \frac{s}{\sqrt{n}} \times \sqrt{1 - \frac{n}{N}} \quad (23)$$

em que \bar{y} é o estimador do parâmetro média populacional; s é o estimador do parâmetro desvio-padrão populacional; $s_{\bar{y}}$ é o erro-padrão amostral; n é o número de elementos contidos na amostra; N é o número de elementos contidos na população e t_α é o valor da distribuição t de Student com $n-1$ grau de liberdade.

Para variáveis autocorrelacionadas no espaço, o erro de amostragem é obtido de maneira análoga à estatística clássica, com a diferença de que o desvio-padrão amostral é a raiz quadrada da variância de predição obtida pela krigagem. Em povoamentos florestais, o volume de um talhão pode ser obtido pela krigagem em blocos e seu erro de amostragem, por:

$$E\% = \pm \frac{S_0 \cdot t_\alpha}{\hat{Z}(x_0) \cdot \sqrt{nbs}} \times 100 \quad (24)$$

com

$$S_0 = \sqrt{\sum \lambda_\alpha \bar{\gamma}(x_\alpha, B) + \mu - \bar{\gamma}(B, B)} \quad (25)$$

em que S_0 é o desvio-padrão amostral expresso pela raiz quadrada da variância de predição obtido pela krigagem em blocos, t_α o valor da distribuição t de Student com $n-1$ grau de liberdade; $\hat{Z}(x_0)$ o valor predito do bloco e nbs é o número de sub-blocos considerados na predição do bloco (YAMAMOTO, 2001).

3. MATERIAL E MÉTODOS

3.1. Softwares utilizados

Para obter as análises estatísticas, foram utilizados os softwares SAS e ArcGis®, já as análises exploratórias da base de estudos foram obtidas pelo SAS e as análises geoestatísticas, pelo software de informação geográfica ArcGis®, versão 9.3.1.

3.2. Região

Este trabalho foi realizado empregando-se dados e informações de um plantio de *Tectona grandis* L.f. de 391,87 ha, submetidos a dois desbastes seletivos, com idades variando de 10,6 a 11,4 anos por ocasião da medição das 101 parcelas instaladas no campo. Na área desse projeto, a altitude média é de 300 m, com temperatura média anual de 24 °C, precipitação média anual de 2.000 mm, com cinco meses de seca, período de chuva de novembro a março (anexos dados históricos de uma fazenda próxima), com predominância de Solos Concrecionários Câmbicos.

O processo de amostragem utilizado no inventário foi o sistemático, adotando-se a intensidade de uma parcela para cada cerca de quatro ha. As parcelas foram alocadas em grades de linhas sistemáticas, com tamanho fixo de 200 m por 250 m e orientadas por coordenadas UTM. Ao todo, foram

instaladas 101 parcelas circulares em 17 talhões, totalizando 391,87 ha: Os arranjos espaciais seguidos no plantio foram de 4 x 2,5 m e 4 x 3 m, conforme pode ser visto na Figura 3.

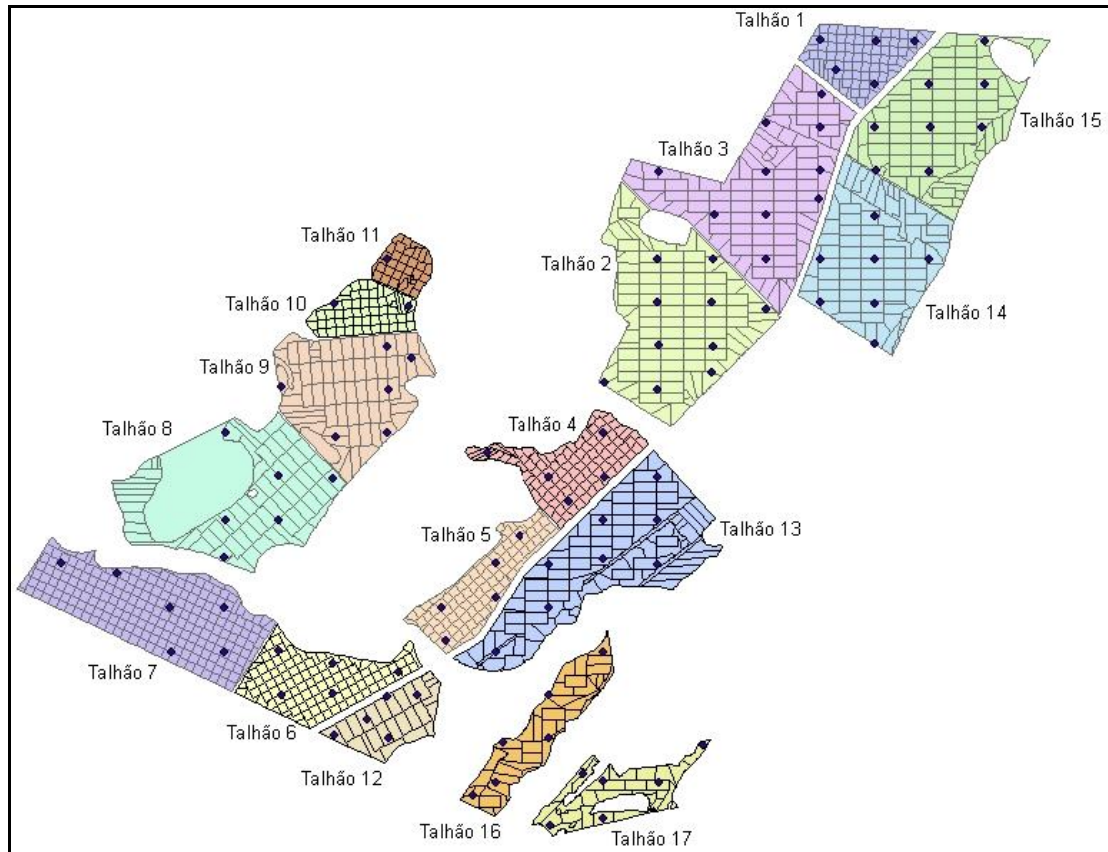


Figura 3 – Formato das 101 parcelas distribuídas na região de estudo.

3.3. Análise exploratória dos dados

Com o objetivo de encontrar valores discrepantes da base de dados em estudo, foi utilizada a análise do gráfico de Box-Whisker Plot, que permite detectar a presença de valores discrepantes. Tais valores podem mascarar a modelagem da dependência espacial, representada pelo semivariograma. Mello (2004), Assis (2005) e Guedes (2009) utilizaram a análise gráfica do Box-Whisker Plot para detectar dados discrepantes em inventários florestais envolvendo geoestatística.

3.4. Métodos de estimação de parâmetros da estatística clássica

O inventário florestal tem por objetivo obter informações qualitativas e quantitativas para o manejo florestal. Essas informações são usualmente obtidas por meio de procedimentos de amostragem utilizando a estatística clássica ou no caso de algumas áreas de povoamentos inequianeos manejados por meio de censo. A estatística clássica supõe que a variável para a qual esteja fazendo o inventário, ou seja, a variável em estudo, não seja correlacionada espacial.

Na amostragem utilizando a estatística clássica, considera-se que a variação de uma variável pode ser decomposta pela soma de duas componentes: uma componente determinística associada a um valor médio e um erro aleatório representado pela equação 26 (GUEDES, 2009; MELLO, 2004).

$$V(x) = \mu(x) + e \quad (26)$$

em que x indica uma posição no espaço, $\mu(x)$ é uma função determinística que descreve a componente estrutural $V(x)$, em x_i , e ε é um erro aleatório com média zero e variância σ^2 . Os estimadores dos parâmetros volume médio e total por talhão da variável aleatória $V(x)$, num inventário florestal, são:

$$\bar{V} = \frac{\sum_{i=1}^n V(x_i)}{n} \quad (27)$$

e

$$\hat{V} = \bar{V} \times N \quad (28)$$

em que n é o número de pontos amostrados; N é o número de da população; $V(x_i)$ é o valor observado da variável em estudo; \bar{V} é o

estimador do parâmetro média populacional; e \hat{V} é o estimador do parâmetro volume total da população.

Existem vários estimadores, entretanto neste trabalho foram utilizados apenas aqueles que envolvem processos de ACS, para a obtenção das estimativas dos parâmetros volume médio, volume total, erro-padrão da média e intervalo de confiança da variável volume, na região em estudo.

3.5. Estudo semivariográfico

Após a análise exploratória dos dados foi realizado o estudo do semivariograma, com o objetivo de detectar a estrutura de dependência espacial para a variável volume, na região de estudo. O semivariograma é uma função matemática que descreve as semivariâncias ou variâncias espaciais em função da distância, e seus parâmetros podem detectar até que distância há estrutura de dependência espacial da variável na região em estudo.

3.6. Modelos de semivariograma avaliados

Existem vários modelos de semivariogramas, no entanto alguns podem fornecer soluções estáveis, ou seja, a matriz de krigagem não possuirá inversa definida (ASSIS, 2005; MELLO, 2004; SOARES, 2006). Os modelos de semivariograma utilizados para descrever a estrutura de dependência espacial da variável volume na região em estudo foram: esférico, exponencial e gaussiano.

Esférico

$$\gamma(h) = \left\{ \begin{array}{ll} \sigma^2 \left[\frac{3 \|h\|}{2 \phi} - \frac{1}{2} \left(\frac{\|h\|}{\phi} \right)^3 \right] & \text{para } 0 \leq \|h\| \leq \phi \\ \sigma^2 & \text{para } \|h\| \geq \phi \end{array} \right\} \quad (29)$$

Exponencial

$$\gamma(h) = \left\{ \begin{array}{l} \sigma^2 \left[1 - \exp\left(\frac{-3\|h\|}{\phi}\right) \right] \\ \sigma^2 \end{array} \right. \quad \left. \begin{array}{l} \text{para } \text{todo } \|h\| \\ \text{para } \|h\| > \phi \end{array} \right\} \quad (30)$$

Gaussiano

$$\gamma(h) = \left\{ \begin{array}{l} \sigma^2 \left[1 - \exp\left(-3\left(\frac{\|h\|}{\phi}\right)^2\right) \right] \\ \sigma^2 \end{array} \right. \quad \left. \begin{array}{l} \text{para } 0 < \|h\| \leq \phi \\ \text{para } \|h\| > \phi \end{array} \right\} \quad (31)$$

Em que $\gamma(h)$ é o semivariograma, efeito pepita (τ^2), contribuição (σ^2), alcance (ϕ) e distância (h) ou tamanho da lag (ESRI, 2001; ISAACS; SRIVASTAVAS, 1989).

3.7. Ajuste do modelo de semivariograma

Foram ajustados os três modelos teóricos de semivariograma - esférico, exponencial e gaussiano - para a variável volume na região de estudo. O ajuste do modelo acontece de maneira iterativa, através da escolha das distâncias entre os pares de pontos (comprimento da lag), o número de pares de pontos, a avaliação dos parâmetros do modelo e a análise gráfica do modelo.

No ajuste do semivariograma experimental, a distância escolhida entre os pares de pontos para ajustar o modelo não deve ser superior à metade da maior distância entre os pares de pontos contidos na região de estudo. As distâncias utilizadas para ajustar o semivariograma foram de 200 m, 250 m, 300 m e 350 m. A maior distância de separação foi de 2.450 m, que corresponde à metade da maior distância entre os pares de pontos contidos na região de estudo.

3.8. Seleção do modelo de semivariograma

O semivariograma é uma função matemática que descreve as semivariâncias em função da distância. Em uma análise geoestatística, ele é o elemento responsável pela análise de dependência espacial na área em estudo. Existem vários modelos matemáticos de semivariograma. Entretanto, nem todos conseguirão descrever fielmente a estrutura de dependência espacial na área de estudo. Nesse caso, a escolha do melhor modelo que descreverá a dependência espacial será crucial. E, uma vez escolhido um modelo inadequado, todas as análises geoestatísticas serão viesadas. Neste trabalho foi utilizado o método da validação cruzada para a escolha do modelo de semivariograma.

A validação cruzada é um método que permite selecionar o modelo de semivariograma que melhor expressa a estrutura da dependência espacial. Compara o valor observado de uma amostra com a respectiva predição obtida pela krigagem. Esse processo é repetido em todas as observações contidas no conjunto de dados, obtendo-se, assim, o erro de predição de cada valor verificado.

O processo de seleção do modelo consiste na análise das estatísticas obtidas pelos resíduos da validação cruzada, como: Média dos erros preditos (M), Média dos erros padronizada (MS), Raiz quadrada da média do erro ao quadrado (RMS), Média da variância dos erros padronizados (ASE) e Raiz quadrada da média dos erros padronizados ao quadrado (RMSS).

O melhor modelo de semivariograma será aquele que apresentar as estatísticas M e MS próximas de zero, valores semelhantes em RMS e ASE e RMSS próximo de 1 (ESRI, 2001).

Além dessas estatísticas, foi utilizado um critério que ajudasse na escolha do melhor modelo que descreve a dependência espacial: o índice de dependência espacial (IDE) proposto por Camdarbella et al. (1994). O (IDE) é classificado em três categorias de dependência espacial: forte quando o índice é menor que 25%, moderado quando estiver entre 25 e 75% e fraco quando for maior que 75%.

3.9. Predição por geoestatística

As predições da variável volume envolvendo geoestatística neste trabalho foram obtidas pela krigagem em blocos, através da qual foi possível obter as predições do volume dos 17 talhões e o volume de área total. Neste estudo, cada talhão foi considerado um bloco, e o volume da área total foi obtido pela soma dos sub-blocos de cada talhão. A krigagem em blocos é um preditor que permite predizer o valor médio de dado local ou bloco, levando-se em consideração a estrutura de dependência espacial do semivariograma em relação às amostras vizinhas a esse local. O preditor da krigagem blocos pode ser obtido na forma de uma combinação linear de valores observados, como pode ser visto na equação 32; ou na forma de sistemas de equações, conforme mostrado na equação 33.

$$\hat{V}(x_0) = \sum_{i=1}^K \lambda_i V(x_i) \quad (32)$$

em que $\hat{V}(x_0)$ é o preditor da krigagem, $V(x_i)$ é o valor observado na posição x_i e λ_i são os pesos associados a k observações de vizinhança, obtidos pela krigagem com a condição de que a soma dos pesos seja igual a 1 (WONG et al., 2004; LAGACHERIE; VOLTZ, 2000).

Sistema de equações de krigagem:

$$\sum \lambda_j \gamma(x_i, x_j) + u = \bar{\gamma}(x_i, B) \quad \text{com} \quad \alpha = 1, \dots, N \quad (33)$$

$$\sum \lambda_\alpha = 1 \quad (34)$$

em que:

- $\gamma(x_i, x_j)$ é a semivariância dos pontos amostrados x_i com o seu vizinho x_j ;
- $\sum \lambda_j$ é o somatório dos pesos dos pontos vizinhos x_j ;

- μ é o multiplicador de Lagrange necessário para satisfazer a condição $\sum \lambda_i = 1$;
- $\bar{\gamma}(x_i, B) = \frac{1}{N_B} \sum_{i=1}^{N_B} \gamma(x_i, x_\alpha)$ é a semivariância média entre cada amostra x_i e o conjunto dos pontos \mathbf{N}_B que compõe o bloco \mathbf{B} , onde x_α está contido;
- $\sum \lambda_i = 1$ é o somatório dos pesos dos pontos x_i , com a restrição do multiplicador de Lagrange, para obtenção de predições não viesadas.

3.10. Erro de amostragem num inventário florestal

Em povoamentos florestais, a quantificação da precisão de uma estimativa média do parâmetro é dada pelo erro de amostragem, sendo expresso, em termos de erro-padrão da média, associado a uma distribuição t , de Student, em um nível de probabilidade desejado. O qual é definido por:

$$E = \pm t_\alpha s(\bar{y}) \quad (35)$$

Com erro-padrão da média para populações finitas

$$s(\bar{y}) = \pm \frac{s}{\sqrt{n}} \times \sqrt{1 - \frac{n}{N}} \quad (36)$$

Podendo também ser expresso em percentagem, que consiste na razão do erro-padrão da média pela média, sendo obtido por:

$$E\% = \pm \frac{t_\alpha \times s}{\bar{y}} \times 100 \quad (37)$$

em que \bar{y} é o estimador do parâmetro média populacional; s é o estimador do parâmetro desvio-padrão populacional; $s_{\bar{y}}$ é o erro-padrão amostral; n é o número de elementos contidos na amostra; e t_α é o valor da distribuição t de Student com $n-1$ grau de liberdade.

Para variáveis com estrutura de dependência espacial, o erro-padrão da média é obtido de maneira análoga à estatística clássica, com a diferença de que o desvio-padrão amostral é a raiz quadrada da variância de predição

obtida pela krigagem. Em povoamentos florestais, o volume de um talhão pode ser obtido pela krigagem em blocos e seu erro de amostragem, por:

$$E\% = \pm \frac{S_0 t_\alpha}{\hat{Z}(x_0) \cdot \sqrt{nbs}} \times 100 \quad (38)$$

com

$$S_0 = \sqrt{\sum \lambda_\alpha \bar{\gamma}(x_\alpha, B) + \mu - \bar{\gamma}(B, B)} \quad (39)$$

em que S_0 é o desvio-padrão amostral expresso pela raiz quadrada da variância de predição e obtido pela krigagem em blocos, t_α o valor da distribuição t de Student com $n-1$ grau de liberdade; $\hat{Z}(x_0)$ o valor predito do bloco e nbs é o número de sub-blocos considerados na predição do bloco (YAMAMOTO, 2001).

Neste trabalho foi utilizado o erro de amostragem, com o objetivo de comparar a precisão das estimativas de um inventário florestal usando a estatística clássica com as predições de um inventário florestal com o auxílio da geoestatística.

O erro de amostragem empregando a estatística clássica foi obtido pela fórmula 37, dividindo-se o erro-padrão da média obtido em cada talhão associado à distribuição de t de Student com $n-1$ grau de liberdade, pela respectiva média. O erro de amostragem na geoestatística foi obtido pela fórmula 38, que consiste no quociente do erro-padrão da média obtido em cada talhão e associado a uma distribuição t de Student com $n-1$ grau de liberdade, e pelo produto entre a média de cada talhão e o respectivo número de sub-blocos. O erro-padrão da média na geoestatística é obtido pelo desvio-padrão da krigagem em blocos, dividido pelo número de elementos da amostra.

4. RESULTADOS E DISCUSSÃO

4.1. Análise exploratória dos dados

Na Figura 4 é apresentado o gráfico de Box–Whisker Plot da variável volume obtido pelo software SAS. O gráfico de Box-Wisker Plot trata-se de apenas uma análise descritiva de pontos discrepantes sem levar em consideração a dependência espacial da variável em estudo, mas valores discrepantes podem afetar no ajuste do semivariograma experimental. Mello (2004), Assis (2005) e Guedes (2009) utilizaram a análise gráfica do Box-Whisker Plot para detectar dados discrepantes em inventários florestais envolvendo geoestatística.

Valores que estão além desse de Whisker podem ser considerados discrepantes. Na parte superior do gráfico é possível perceber a presença de dois valores discrepantes, os quais foram removidos deste estudo.




Figura 4 – Gráfico de Box–Whisker Plot da variável dendrométrica volume, que representa os dados candidatos a *outliers*.

4.2. Modelos de semivariograma ajustados

Nas Figuras 5, 6, 7 e 8 estão apresentados os modelos teóricos de semivariogramas ajustados: esférico, exponencial e gaussiano, ambos ajustados para as distâncias de 200 m, 250 m, 300 m e 350 m da variável volume, na região de estudo.




Figura 5 – Modelos de semivariograma ajustados: esférico, exponencial e gaussiano, com distância de 200 m da variável volume, na região de estudo.




Figura 6 – Modelos de semivariograma ajustados: esférico, exponencial e gaussiano, com distância de 250 m da variável volume, na região de estudo.




Figura 7 – Modelos de semivariograma ajustados: esférico, exponencial e gaussiano, com distância de 300 m da variável volume, na região de estudo.




Figura 8 – Modelos de semivariograma ajustados: esférico, exponencial e gaussiano com distância de 350 m, da variável volume na região de estudo.

Na Tabela 1, apresentam-se as predições dos parâmetros dos modelos de semivariograma: esférico, exponencial e gaussiano, ajustados utilizando a caixa de ferramentas Geostatistical Wizard, do módulo Geostatistical Analyst do software ArcGis®, versão 9.3.1. Adicionalmente, é apresentado o índice de dependência espacial, o qual foi obtido pela razão entre o efeito pepita e o patamar do modelo ajustado.

Tabela 1 – Estimativas dos parâmetros efeito pepita (τ^2), patamar (ν), contribuição (σ^2) e alcance (ϕ), dos modelos esférico, exponencial e gaussiano, e o respectivo índice de dependência espacial (IDE), ajustados considerando lags com tamanhos de 200 m, 250 m, 300 m e 350 m

Lag	Modelos	$\hat{\tau}^2$	$\hat{\sigma}^2$	$\hat{\tau}^2 + \hat{\sigma}^2$	ϕ	IDE(%)
200	Esférico	181,50	343,48	524,98	2370,65	34,58
	Exponencial	148,35	356,98	505,33	2370,65	29,36
	Gaussiano	234,86	334,23	569,09	2370,65	41,27
250	Esférico	185,91	313,14	499,05	2215,01	37,26
	Exponencial	144,10	343,57	487,67	2215,01	29,55
	Gaussiano	236,29	300,06	536,35	2215,01	44,06
300	Esférico	181,97	344,49	526,46	2371,71	34,56
	Exponencial	137,20	375,63	512,83	2371,71	26,75
	Gaussiano	181,97	344,49	526,46	2371,71	34,57
350	Esférico	183,57	348,57	532,14	2437,47	34,50
	Exponencial	133,15	386,3	519,45	2437,47	25,63
	Gaussiano	238,11	338,39	576,5	2437,47	41,30

De acordo com a Tabela 1, utilizando o IDE proposto por Cambardella et al. (1994), foram ajustados os modelos de semivariograma e os quatro tamanhos de lag. A produção por hectare apresentou grau de dependência espacial entre 25,63% e 44,06%. Portanto, a dependência espacial para o volume por unidade de área pode ser classificada como moderada.

Um dos fatores contribuidores pelo moderado valor da dependência espacial é alto valor do efeito pepita, pois, pela razão de Cambardella et al. (1994), quanto maior o efeito pepita, menor a estrutura de dependência

espacial. Isso também pôde ser constatado em Aubry e Debouzie (2001 citados por MELLO, 2004), que verificaram que variáveis ecológicas possuem alto valor de efeito pepita.

O alcance apresentado pelos modelos exponencial e gaussiano das quatro lags de distância é chamado de alcance prático, pois eles só atingem o alcance de maneira assintótica, ou seja, quando h tende ao infinito. Na prática considera-se o alcance teórico do semivariograma exponencial, como três vezes o alcance ajustado pelo modelo de semivariograma, enquanto no gaussiano esse alcance é multiplicado por raiz de 3 (ANDRIOTTI, 2005).

4.3. Escolha do modelo de semivariograma

A Tabela 2 apresenta as distâncias utilizadas para ajustar os modelos de semivariograma, índice de dependência espacial e as estatísticas descritivas utilizadas na validação cruzada: média dos erros preditos, média dos erros padronizados, raiz quadrada da média do erro ao quadrado, média da variância dos erros padronizados e raiz quadrada da média dos erros padronizados ao quadrado, todas obtidas pelo módulo Geostatistical Wizard do ArcGis®, versão 9.3.1.

Conforme Cressie (1991), McBratney e Webster (1986), Mello (2004) e Vieira (2000), as estatísticas M e AS devem ser próximas de zero e $RMSS$ próximo de 1, pela condição de não viesamento. Já as estatísticas RMS e ASE devem apresentar valores semelhantes (ESRI, 2001).

Verifica-se, na Tabela 2, que os três modelos apresentaram valores semelhantes para as estatísticas da validação cruzada, em que os valores se aproximam daquela esperada quando o modelo apresenta bom ajuste. A seleção do modelo teve que se basear, portanto, em outro critério. Neste estudo, optou-se por selecionar o modelo que apresentasse menor índice de dependência espacial, pois indicaria uma dependência espacial mais forte (CAMBARDELLA et al., 1994). Ao comparar o IDE dos três modelos ajustados nas quatro lag utilizadas, verificou-se que o modelo exponencial apresenta menor valor de IDE. Portanto, esse modelo foi o selecionado para escrever a dependência espacial da característica dendrométrica volume na área em estudo.

Tabela 2 – Estatísticas da validação cruzada média dos erros preditos (M), média dos erros padronizados (MS), raiz quadrada da média do erro ao quadrado (RMS), média da variância dos erros padronizados (ASE) e raiz quadrada da média dos erros padronizados ao quadrado (RMSS), obtidas ao ajustar modelos de semivariograma esférico, exponencial e gaussiano considerando os tamanhos de 200 m, 250 m, 300 m e 350 m para lag de pares de pontos e o índice de dependência espacial (IDE)

Lags	Modelos	Estatística da Validação Cruzada					
		M	MS	RMS	ASE	RMSS	IDE(%)
200	Esférico	-0,13	0,00	17,72	16,14	1,09	34,58
	Exponencial	-0,22	-0,01	17,94	16,46	1,09	29,36
	Gaussiano	-0,02	0,00	17,59	16,33	1,07	41,27
250	Esférico	-0,13	0,00	17,72	16,25	1,09	37,26
	Exponencial	-0,22	-0,09	17,95	16,38	1,09	29,55
	Gaussiano	-0,02	0,00	17,58	16,40	1,07	44,06
300	Esférico	-0,13	0,00	17,72	16,16	1,09	34,56
	Exponencial	-0,23	-0,09	17,99	16,23	1,10	26,75
	Gaussiano	-0,02	0,00	17,59	16,35	1,07	34,57
350	Esférico	-0,13	0,00	17,71	16,19	1,09	34,50
	Exponencial	-0,10	0,00	17,89	16,09	1,11	25,63
	Gaussiano	-0,09	0,00	17,55	16,42	1,06	41,30

4.4. Predições geoestatísticas do inventário florestal

Na Figura 9 é apresentada a região de estudo com o mapa de predições da krigagem em blocos da variável volume dos 17 talhões.

Na Tabela 3, apresentam-se as predições do volume médio, do volume total, do erro-padrão da média e do intervalo de confiança de cada talhão de povoamento de *Tectona grandis L.f.*, obtidas ao utilizar a krigagem em bloco. A krigagem em bloco fornece estimativas mais suaves quando comparada com a krigagem pontual.

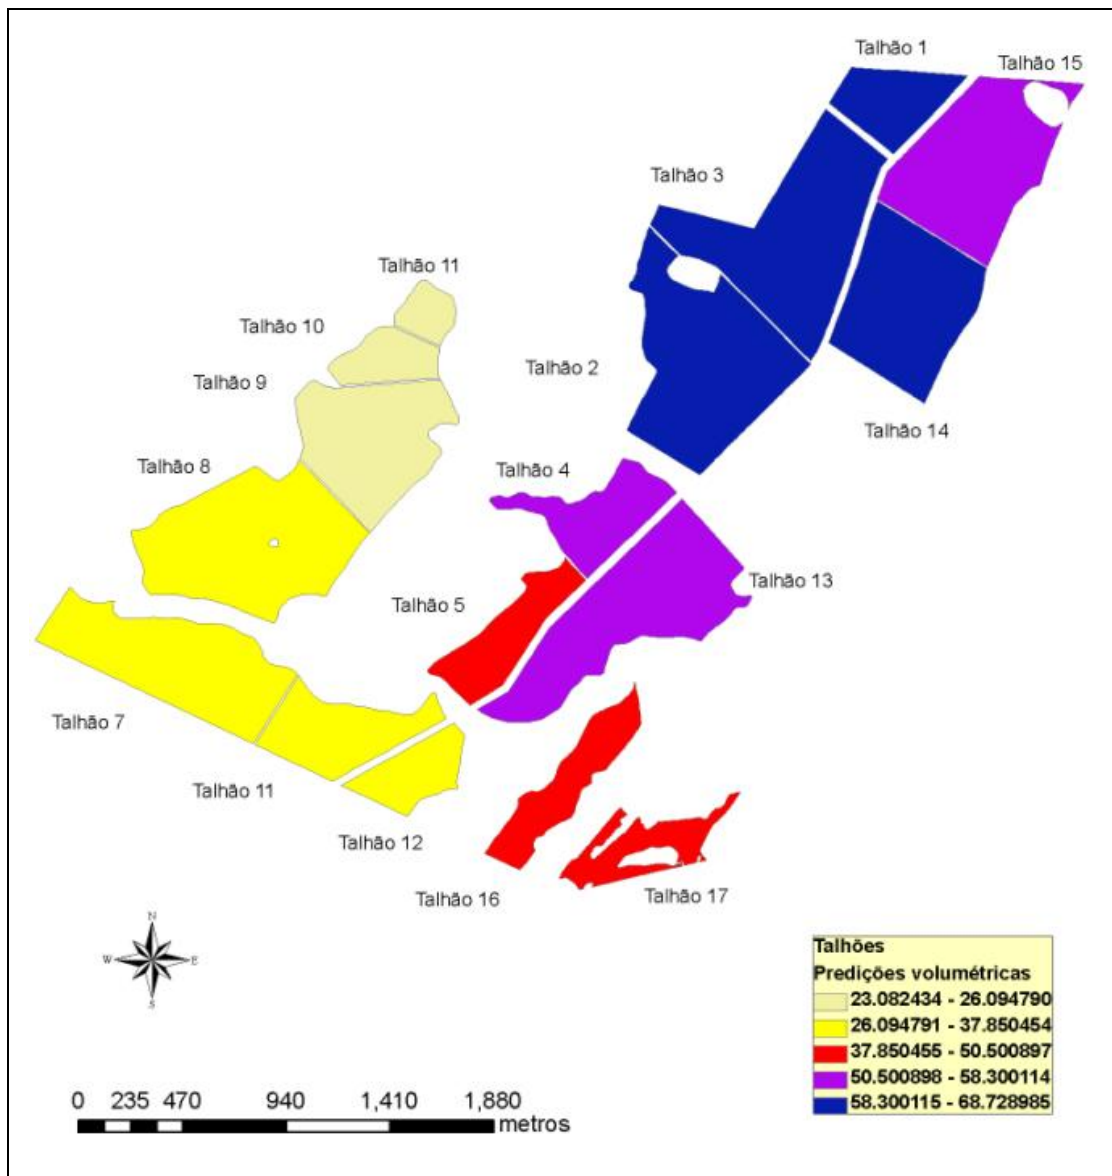


Figura 9 – Mapa de predições da krigagem em blocos da variável volume dos 17 talhões.

Tabela 3 – Predições, por talhão, das características volume médio (V), volume total (VT) e erro-padrão da média (EPM) e intervalo de confiança (IC) com 95% de probabilidade pela distribuição t, de Student, utilizando a krigagem em bloco

Talhão	Subbloco	V(m ³ .ha ⁻¹)	VT	EPM	IC
1	83	66,64	25.473,05	±1,94	66,64 ± 3,80
2	97	64,40	85.524,41	±1,79	64,40 ± 3,50
3	102	62,60	83.432,20	±1,72	62,60 ± 3,37
4	103	61,26	29.158,81	±1,79	61,26 ± 3,51
5	95	47,32	20.666,90	±1,82	47,32 ± 3,56
6	116	48,74	19.804,27	±1,68	48,74 ± 3,30
7	230	31,47	25.232,22	±1,20	31,47 ± 2,35
8	66	29,05	22.480,67	±2,22	29,05 ± 4,35
9	66	21,14	10.400,89	±2,21	21,14 ± 4,34
10	57	26,33	4.566,85	±2,61	26,33 ± 5,12
11	33	22,44	1.327,43	±3,97	22,44 ± 7,77
12	25	31,25	9.851,51	±3,59	31,25 ± 7,04
13	94	54,12	56.106,32	±1,83	54,12 ± 3,58
14	80	68,91	65.522,49	±1,98	68,91 ± 3,88
15	86	56,89	54.831,73	±1,89	56,89 ± 3,70
16	38	52,79	20.399,63	±2,91	52,79 ± 3,70
17	31	47,20	14.670,55	±3,23	47,20 ± 6,30
Área Total	1402	45,91	64.273,21	±3,71	45,91±6,48

Os talhões apresentaram erro-padrão da média relativamente baixo, e isso aconteceu devido ao fato de a krigagem fornecer predições com variância mínima. Em comparação com a krigagem pontual (não avaliada neste estudo), a krigagem em blocos tende a apresentar resultados com maior minimização na variância do que os da krigagem pontual, pois, em blocos, usa a média da semivariância entre as amostras e os valores a predizer. Conforme Trangmar et al. (1985 citados por MELLO, 2004), a krigagem em bloco produz mapas suaves através da interpolação dos valores médios de cada bloco.

Apesar de a krigagem fornecer predições com variância minimizada quando comparada a outros métodos de interpolação, todos os talhões apresentaram predições do erro-padrão da média minimizado.

No talhão 11, o erro-padrão da média foi o maior de todos os talhões, para o qual houve uma única observação. Tal fato ocorreu porque a krigagem considera a relação de dependência espacial entre esse ponto e todos os pontos da área de estudo.

O talhão 12 foi o que apresentou o segundo maior erro-padrão da média em relação aos demais talhões, isso porque havia alta variabilidade entre parcelas amostradas contidas nessa área. Tal fato pode ser constatado novamente pelos talhões 16 e 17, pois ambos constituíam o mesmo número de parcelas amostradas.

4.5. Estimativas clássicas do inventário florestal

Na Tabela 4 apresentam-se, para cada talhão, as estimações do volume médio, do volume total, do erro-padrão da média e intervalo de confiança das predições obtidas usando o procedimento clássico de um inventário florestal, que se baseia em metodologias de estatísticas clássicas.

Os talhões 2, 3, 7, 10, 11 e 12 apresentaram erro-padrão de baixa magnitude. No talhão 11, não pôde ser calculado o erro-padrão da média, pois o denominador do estimador da variância amostral com uma única observação foi zero.

4.6. Comparação das predições geoestatísticas versus clássicas

Na Tabela 5 são apresentadas as predições dos erros de amostragem em percentagem (E%), obtidos nos 17 talhões com povoamentos de *Tectona grandis L.f.*, utilizando a estatística clássica e a geoestatística. O erro de amostragem foi utilizado neste trabalho para comparar a precisão das estimativas das médias dos talhões produzidas pelas duas técnicas de estatística.

Tabela 4 – Predições, por talhão, do volume por hectare (V), do volume total (VT) e do erro-padrão da média (EPM) e intervalo de confiança (IC) com 95% de probabilidade pela distribuição t, de Student, e (n) número de unidades de amostras utilizando a estatística clássica

Talhão	n	V(m ³ .ha ⁻¹)	VT	EPM	IC(95%)
1	4	65,20	25.809,51	±16,54	65,20 ± 45,92
2	10	64,77	86.019,94	±3,52	64,77 ± 7,95
3	10	58,92	78.529,37	±4,35	58,92 ± 9,84
4	5	59,02	28.091,09	±6,59	59,02 ± 18,29
5	5	49,52	21.626,25	±5,72	49,52 ± 18,89
6	5	41,25	21.087,19	±4,79	41,25 ± 13,29
7	6	28,94	23.201,58	±4,34	28,94 ± 11,15
8	6	31,66	24.501,70	±6,42	31,66 ± 16,51
9	6	24,56	12.083,28	±9,72	24,56 ± 24,98
10	2	22,20	3.851,70	±2,49	22,20 ± 10,71
11	1	4,78	660,48	Não calculado	Não calculado
12	5	31,31	9.870,17	±2,82	31,31 ± 7,83
13	8	31,31	32.456,67	±2,82	31,31 ± 7,27
14	7	75,17	71.471,44	±5,47	75,17 ± 13,38
15	7	56,78	54.728,85	±11,66	56,78 ± 27,58
16	6	53,21	20.563,20	±8,70	53,21 ± 22,34
17	6	45,49	14.137,81	±9,05	45,49 ± 23,56
Área total	99	49,75	541.738,20	±0,2313	49,75 ±0,45

Tabela 5 – Erros de amostragem (%) utilizando estatística clássica e geoestatística

Talhão	$\hat{E}C$ (%)	$\hat{E}G$ (%)
1	68,02	5,70
2	12,28	5,43
3	16,70	5,39
4	30,99	5,73
5	32,09	7,53
6	32,22	8,52
7	38,53	7,47
8	52,15	14,96
9	101,73	20,51
10	48,23	19,46
12	25,02	22,54
13	25,02	6,62
14	17,80	5,63
15	48,57	6,52
16	42,02	10,81
17	68,70	13,97
Área Total	0,91	0,04

As estimativas dos erros de amostragem nos talhões de povoamentos de *Tectona grandis* L.f. utilizando a geoestatística foram menores do que as que empregaram a estatística clássica. O mesmo ocorreu na estimativa do erro de amostragem da área total. Isso aconteceu pelo fato de a krigagem oferecer previsões com variância minimizada. O erro de amostragem do talhão 11 não pôde ser comparado, pois pela estatística clássica não é possível estimar a variância de uma única observação. Isso foi devido ao fato de o denominador da variância amostral ser zero em uma única observação. Já o talhão 12 apresentou estimativas do erro de amostragem próximas utilizando as duas metodologias. Tal fato ocorreu devido à alta variabilidade da característica volume no talhão.

5. CONCLUSÃO

A geoestatística proporciona estimativas do volume de *Tectona grandis* L.f. mais precisas do que as obtidas por meio de estatística clássica.

O volume de *Tectona grandis* L.f. pode ser estudado pelo modelo de semivariograma exponencial com alcance prático de 2;370,65 m.

6. REFERÊNCIAS

ADELMAN, D. J.; BRENT, E. E.; SCOTT, M. Use of temporal patterns in vapor pressure deficit to explain spatial autocorrelation dynamics in tree transpiration. **Tree Physiology**, n. 28, p. 647-658, 2008.

ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística**. São Leopoldo, RS: Ed. Unisinos, 2005. 165 p.

ASSIS, A. L. **Definição da estratégia amostral em plantios de Eucalyptus SPP pelo uso de geoestatística**. 2005. 127 f. Tese (Doutorado em Engenharia Florestal, área de concentração em Florestas de Produção) – Universidade Federal de Lavras, Lavras, MG, 2005.

AUBRY, P.; DEBOUZIE, D. Estimation of the mean from a two-dimensional sample: the geoestatistical model-based approach. **Ecology**, Washington, v. 82, n. 5, p. 1484-1494, May 2001.

BARDOSSY, A.; LEHMANN, W. Spatial distribution of soil moisture in a small catchment. Part 1: geoestatistical analysis. **Journal of Hydrology**, n. 206, p. 1-15, 1998.

BRUS, D. J.; GRUIJTER, J. J. Random sampling or geoestatistical modelling? Choosing between design-based and model-based sampling strategies for soil (with discussion). **Geoderma**, v. 80, p. 1-44, 1997.

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.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal**. 3. ed. Viçosa, MG: Editora UFV, 2009. 548 p.

CARAM, R. O. **Reconstrução de séries e análise geoestatística da precipitação no estado de Minas Gerais**. 2007. 84 f. Dissertação (Mestrado em Meteorologia Agrícola) – Universidade Federal de Viçosa, Viçosa, MG, 2007.

COCHRAN, W. G. **Sampling techniques**. 3. ed. New York: Wiley, 1977. 555 p.

CRESSIE, N. **Statistics for spatial data**. New York: Wiley, 1993. 900 p.

DAVIS, L. S.; JOHNSON, K. M. **Forest management**. New York: Mc-Graw-Hill Book Company, 1987. 790 p.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. V. M. **Análise espacial de dados geográficos**. Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/analise/cap1-intro.pdf>>. Acesso em: 12 set. 2010.

ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. **Using ArcGIS geoestatistical analyst**. Redlands, 2001. 300 p.

GAETAN, C.; GUYON, X. **Spatial statistics and modeling**. New Yourk: Springer, 2010. 308 p.

GUEDES, L. C. I. **Técnicas geoestatísticas e interpoladores espaciais na estratificação de povoamentos de *Eucalyptus* sp.** 2009. 70 f. Dissertação (Mestrado em Engenharia Florestal, área de concentração em Florestas de Produção) – Universidade Federal de Lavras, Lavras, MG, 2009.

HUSCH, B.; MILLER, C. I.; BEERS, T. W. **Forest mensuration**. New York: Wiley & Sons, 1982. 398 p.

HERNÁNDEZ, J.; XAVIER, E. A geoestatistical approach to optimize sampling designs for local Forest inventories. **Canadian Journal of Forest Research**, n. 39, p. 1465-1474, 2009.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. New York: Oxford University Press, 1989. 560 p.

KOZAR, B.; LAWRENCE, R.; LONG, S. D. Soil phosphorus and potassium mapping using a spatial correlation model incorporating terrain slope gradient. **Kluwer Academic Publishers**, n. 3, p. 407-417, 2002.

KRIGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal of the Chemical, Metallurgical and Mining Society of South Africa**, v. 52, p. 119-139, 1951.

LAGACHEIRIE, P.; VOLTZ, M. Predicting soil properties over a region using sample information from a mapped reference area and digital elevation data: a conditional probability approach. **Geoderma**, v. 97, p. 187-208, 2000.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. São Paulo: UNESP, 2002. 242 p.

LEGLEITER, J. C.; KYRIAKIDIS, C. P. Spatial prediction of river channel topography by kriging. **John Wiley & Sons**, v. 33, p. 841-867, 2008.

LIMA, S. S. J.; OLIVEIRA, C. P.; OLIVEIRA, B. R.; XAVIER, C. A. Métodos geoestatísticos no estudo da resistência do solo à penetração em trilha de tráfego de tratores na colheita de madeira. **Revista Árvore**, Viçosa, MG, v. 32, n. 5, p. 931-938, 2008.

LÖETSCH, F.; HALLER, K. E. **Forest inventory**. München: BLV, Verlagsgesellschaft, 1964. v. 1, 436 p.

LÖETSCH, F.; ZÖHRER, F.; HALLER, K. E. **Forest inventory**. München: BLV, Verlagsgesellschaft, 1973. v. 2, 469 p.

MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, p. 1246-1266, 1963.

MELLO, J. M. **Geoestatística aplicada ao inventário florestal**. 2004. 110 f. Tese (Doutorado em Recursos Florestais, Silvicultura e Manejo Florestal) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, SP, 2004.

MELLO, J. M.; OLIVEIRA, S. M.; BATISTA, F. L. J.; JUNIOR, J. R. P.; JUNIOR, K. H. Uso do estimador geoestatístico para predição volumétrica por talhão. **Revista Floresta**, Curitiba, v. 36, n. 2, maio/ago. 2006.

MCBRATNEY, A. B.; ODEH, I. O. A.; BISHOP, T. F. A.; DUNBAR, S. M.; SHATAR, T. M. An overview of pedometric techniques for use in soil survey. **Geoderma**, v. 97, p. 293-327, 2000.

Mc BRATNEY, A. G.; WEBSTER, A. G. Choosing functions for semivariograms and fitting them to sampling estimates. **Journal of Soil Science**, v. 37, p. 617-639, 1986.

RUFINO, C. M. T.; THIERSCH, R. C.; FERREIRA, O. S.; JUNIOR, K. H.; FAIS, D. O uso da geoestatística no estudo da relação entre variáveis dendrométricas de povoamento de Eucalyptus sp. e atributos do solo. **Revista Ambiente**, Guarapuava, PR, v. 2, n. 1, p. 83-93, 2006.

SILVA, R. M. S.; JUNIOR, M. R. S.; MELO, I. D. F. **Conhecendo a técnica geoestatística e aplicação**. Disponível em: <<http://emr11.de.ufpe.br/cd/trabalhos/T200.pdf>>. Acesso em: 12 abr. 2011.

SILVA, C. J.; CASTRO, R. V.; XAVIER, A. B. **Eucalipto manual prático do fazendeiro florestal produzindo madeira com qualidade**. Viçosa, MG: DEF/UFV, 2008. 72 p.

SOARES, A. G. **Geoestatística para as ciências da terra e do ambiente**. 2. ed. Lisboa, Portugal: IST Press, 2006. 186 p.

TRANGMAR, B. B.; YOST, R. S.; UEHARA, G. Application of geostatistics to special studies of soil properties. **Advances in Agronomy**, v. 38, p. 45-94, 1985.

UBIALLI, A. J.; FILHO, F. A.; MACHADO, A. S.; ARCE, E. J. Comparação de métodos e processos de amostragem para estudos fitossociológicos em uma floresta ecotonal na região norte mato-grossense. **Floresta**, Curitiba, v. 39, n. 3, p. 511-523, jul./set. 2009.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAES, R. S.; ALVAREZ, V. V. H.; SCHAESER, C. E. G. R. (Eds.). **Tópicos em Ciências do Solo**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2000. cap.1, p. 1-54.

YAMAMOTO, K. J. **Avaliação e classificação de reservas minerais**. São Paulo: EDUSP, 2001. 226 p.

WANG, G.; GERTNER, G.; ANDERSON, A. B. Sampling design and uncertainty based on spatial variability of spectral variables for mapping vegetation cover. **International Journal of Remote Sensing**, v. 26, n. 15, p. 3255-3274, 2005.

WONG, W. D.; YUAN, L.; PERLIN, A. S. Comparicion of spatial interpolation methods of air quality data. **Journal of Exposure Analysis and Environmental Epidemiology**, v. 14, p. 404-417, 2004.