

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**MODELAGEM DA INCERTEZA DA DISTRIBUIÇÃO
ESPACIAL DE FÓSFORO E POTÁSSIO DO SOLO SOB A
CULTURA CANAVIEIRA**

Ismênia Ribeiro de Oliveira

Bacharel em Ciência da Computação

2013

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**MODELAGEM DA INCERTEZA DA DISTRIBUIÇÃO
ESPACIAL DE FÓSFORO E POTÁSSIO DO SOLO SOB A
CULTURA CANAVIEIRA**

Ismênia Ribeiro de Oliveira

Orientador: Prof. Dr. Gener Tadeu Pereira

Coorientador: Prof. Dr. José Marques Júnior

Tese apresentada à Faculdade de Ciências
Agrárias e Veterinárias – Unesp, Câmpus de
Jaboticabal, como parte das exigências para a
obtenção do título de Doutor em Agronomia
(Ciência do Solo)

2013

O46m Oliveira, Ismênia Ribeiro de
Modelagem da incerteza da distribuição espacial de fósforo e
potássio do solo sob a cultura canavieira / Ismênia Ribeiro de Oliveira.
– – Jaboticabal, 2013
v, 71 f. ; 28 cm

Tese (doutorado) - Universidade Estadual Paulista, Faculdade de
Ciências Agrárias e Veterinárias, 2013

Orientador: Gener Tadeu Pereira

Banca examinadora: Alan Rodrigo Panosso, Marcílio Vieira
Martins Filho, Morel de Passos e Carvalho, Zigomar Menezes Sousa

Bibliografia

1. Geoestatística-krigagem ordinária 2. Geoestatística-simulação
sequencial gaussiana 3. Geoestatística-simulação sequencial
indicatriz. I. Título. II. Jaboticabal-Faculdade de Ciências Agrárias e
Veterinárias.

CDU 631.41:633.61

Ficha catalográfica elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
– Serviço Técnico de Biblioteca e Documentação - UNESP, Câmpus de Jaboticabal.

CERTIFICADO DE APROVAÇÃO


TÍTULO: MODELAGEM DA INCERTEZA DA DISTRIBUIÇÃO ESPACIAL DE FÓSFORO
E POTÁSSIO DO SOLO SOB A CULTURA CANAVIEIRA

AUTORA: ISMÊNIA RIBEIRO DE OLIVEIRA

ORIENTADOR: Prof. Dr. GENER TADEU PEREIRA

CO-ORIENTADOR: Prof. Dr. JOSE MARQUES JUNIOR

Aprovada como parte das exigências para obtenção do Título de DOUTOR EM AGRONOMIA
(CIÊNCIA DO SOLO), pela Comissão Examinadora:


Prof. Dr. GENER TADEU PEREIRA

Departamento de Ciências Exatas / Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal


Prof. Dr. MARCILIO VIEIRA MARTINS FILHO

Departamento de Solos e Adubos / Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal


Prof. Dr. ALAN RODRIGO PANOSSO

Pós-Doutorando / Departamento de Ciências Exatas / Faculdade de Ciências Agrárias e
Veterinárias de Jaboticabal


Prof. Dr. ZIGOMAR MENEZES DE SOUZA

Universidade Estadual de Campinas / Campinas/SP


Prof. Dr. MOREL DE PASSOS E CARVALHO

Departamento de Fitossanidade, Engenharia Rural e Solos / Faculdade de Engenharia de Ilha
Solteira

Data da realização: 28 de fevereiro de 2013.

DADOS CURRICULARES DO AUTOR

ISMÊNIA RIBEIRO DE OLIVEIRA – nascida em 5 de dezembro 1976 em Bacabal Maranhão – MA, graduada em Ciência da Computação pela Universidade Federal do Maranhão - UFMA (1996 a 2002). Em janeiro de 2002 ingressou no curso de Mestrado em Engenharia elétrica na área de Ciência da Computação na Universidade Federal do Maranhão - UFMA, concluindo em fevereiro de 2004. Foi bolsista do CNPq na modalidade Desenvolvimento Tecnológico Industrial – DTI, categoria 7G de março de 2004 a abril de 2005. Em 2006 foi nomeada, em caráter efetivo, como professora na Universidade Federal do Maranhão em regime de dedicação exclusiva. Em de 2011, ingressou no Curso de Doutorado em Agronomia (Ciência do Solo) na Universidade Estadual Paulista (UNESP/FCAV). No mês de fevereiro de 2013, submeteu-se à banca para a defesa de Tese, sendo aprovada como Doutora em Agronomia.

Nada me pertube.

Nada me amedronte.

Nada me assuste.

Tudo passa.

A paciência tudo alcança.

A quem tem Deus, nada falta.

Só Deus basta.

(Oração de Santa Teresa)

DEDICO

Aos alicerces da minha vida:

Minha mãe, Elisabete, meu porto seguro.

Meu pai, Aristides, meu herói.

Meu marido, Edenilson, meu companheiro, meu amigo, meu amor.

Meu filho, Ian Pedro, pedaço de mim, a luz dos meus dias.

Minhas irmãs, Islávia e Isabel, minhas companheiras.

Minhas sobrinhas, Ianka e Camila, princesas da tia.

Amo vocês!

AGRADECIMENTOS

A todos aqueles que diretamente ou indiretamente contribuíram ao longo desse caminho até a apresentação final desse trabalho.

Ao orientador, Dr. Gener Tadeu Pereira por transmitir os ensinamentos complicados da Geoestatística sempre de forma tranquila e paciente. Obrigada, acima de tudo pelas palavras de incentivo e otimismo. Neste curto ano de convivência aprendi muito com este ser humano de alma e caráter admiráveis.

Ao coorientador, José Marques Júnior, pelo estímulo e ensinamentos durante o desenvolvimento da pesquisa.

Aos membros da Banca de Qualificação: Alan Rodrigo Panosso, Célia Regina Paes Bueno, Glauco Rolim, Marcílio Vieira Martins Filho e aos membros da Banca de defesa: Alan Rodrigo Panosso, Marcílio Vieira Martins Filho, Morel de Passos e Carvalho, Zigomar Menezes de Souza, cujas críticas e sugestões contribuíram para a melhoria desse trabalho.

Aos amigos do grupo CSME, Alan, Angélica, Diego, Elton, João, Livia, Roni e Sísara, pela colaboração e conselhos durante a difícil jornada.

Ao querido Daniel Teixeira pelo conhecimento compartilhado fundamental para o andamento da pesquisa. Obrigada pela infinita disposição, pela preocupação e, principalmente, pela amizade.

À Mara Moitinho, companheira de sala, de agradáveis conversas acompanhadas de café e bolo de banana.

Aos amigos e funcionários do Departamento de Ciências Exatas, Zezé, Shirley, Norival e Adriana. Obrigada pelo precioso acolhimento.

Às queridas amigas de trabalho, Jussara e Ana Zélia, pela força, companheirismo, pelos momentos de descontração em Jaboticabal e durante as aulas em Chapadinha. Sem elas a jornada seria muito mais pesada. Obrigada pela amizade!

Ao Professor Vitório Barato Neto pela correção gramatical.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES.

SUMÁRIO

	Página
RESUMO.....	X
ABSTRACT.....	XI
CAPÍTULO 1 – CONSIDERAÇÕES GERAIS	1
1.1 Introdução	1
1.2 Objetivos.....	3
1.2.1 Gerais	3
1.2.2 Específicos.....	3
1.3 Revisão de literatura.....	4
1.3.1 Variabilidade espacial de atributos do solo e manejo localizado	4
1.3.2 Geoestatística.....	5
1.3.3 Krigagem	10
1.3.4 Simulações estocásticas.....	13
1.3.5 Incertezas dos interpoladores geoestatísticos	16
1.4 Referências.....	19
CAPÍTULO 2 – INCERTEZA DA DISTRIBUIÇÃO ESPACIAL DO FÓSFORO DISPONÍVEL DO SOLO EM ÁREA DE CANA-DE-AÇÚCAR.....	24
CAPÍTULO 3 – MODELAGEM DA INCERTEZA DO POTÁSSIO DISPONÍVEL DO SOLO POR SIMULAÇÕES ESTOCÁSTICAS.....	45
CAPÍTULO 4 – IMPLICAÇÕES	68
APÊNDICES	69
Apêndice A	70
Apêndice B	71

MODELAGEM DA INCERTEZA DA DISTRIBUIÇÃO ESPACIAL DE FÓSFORO E POTÁSSIO DO SOLO SOB A CULTURA CANAVIEIRA

RESUMO - O tratamento das incertezas associadas às predições dos atributos de solos é de suma importância para aumentar a confiabilidade dos métodos geoestatísticos e incrementar o desenvolvimento de tecnologias que permitam o manejo localizado e aumente a eficiência das atividades agrícolas. Neste trabalho, foi avaliado o desempenho dos métodos de interpolação geoestatísticos no que diz respeito, principalmente, ao tratamento das incertezas associadas às predições desses métodos. Foram avaliados dois métodos de simulação estocástica, a simulação sequencial gaussiana (SSG) e a simulação sequencial indicatriz (SSI), comparando com o método já consagrado krigagem ordinária (KO). Foi realizado um estudo de caso, com os atributos do solo fósforo (P) disponível e potássio (K) disponível no solo, em uma malha amostral com 626 pontos, instalada em uma área experimental de cana-de-açúcar no município de Tabapuã, São Paulo. Foram geradas 200 realizações por meio de cada algoritmo de simulação. As simulações estocásticas reproduziram as estatísticas e a variabilidade dos dados amostrais de K e P, enquanto a KO promoveu superestimativa e subestimativa dos baixos e altos valores, respectivamente. O mapa de desvio-padrão obtido a partir da KO apresentou menor variação ao longo da área de estudo, quando comparado aos mapas de desvio-padrão obtidos a partir das simulações da SSG e SSI. Os mapas simulados por meio da SSG e da SSI representaram a distribuição espacial do P e do K de forma mais realista do que o mapa de estimação fornecido pela KO. As técnicas SSG e SSI mostraram-se mais eficientes para modelar a incerteza da distribuição espacial do P e do K do que a técnica KO. A avaliação da incerteza, obtida por meio das técnicas de simulação, pode ser utilizada para definir, de forma mais confiável, áreas de manejo específico.

Palavras-chave: geoestatística, krigagem ordinária, simulação sequencial gaussiana, simulação sequencial indicatriz.

UNCERTAINTY MODELING OF SPATIAL DISTRIBUTION OF PHOSPHORUS AND POTASSIUM OF THE SOIL IN SUGARCANE CROP

ABSTRACT - The treatment of uncertainties associated with predictions of soil attributes is critical to increase the reliability of geostatistical methods and encourage the development of technologies that allow for localized management and increase the efficiency of agricultural. In this study, was evaluated the performance of geostatistical interpolation methods with regard mainly to the treatment of uncertainties associated with the predictions of these methods. Was evaluated two methods of stochastic simulation, sequential gaussian simulation (SGS) and sequential indicator simulation (SIS), comparing with the method ordinary kriging (OK). A case study was conducted with the soil attributes available phosphorus (P) and available potassium (K) in a sample grid with 626 points, installed in sugarcane experimental area at Tabapuã, São Paulo, Brazil. Two hundred realizations were generated by each simulation algorithm. The stochastic simulations reproduced the statistics and variability of the sample data of P and K, while the OK promoted the overestimation and the underestimation of low and high values, respectively. The map of standard deviation obtained from the OK showed less variation along the study area compared to maps of standard deviation obtained from the SGS simulations and SIS. The simulated maps generated through SGS and SIS represents spatial distribution of P and K more realistically than an estimation map obtained by OK. The SGS techniques and SIS were more efficient to model the uncertainty of the spatial distribution of P and K than the technical OK. The evaluation of uncertainty, obtained through simulation techniques can be used to define more reliably, specific management areas.

Keywords: geoestatics, ordinary kriging, sequential gaussian simulation, sequential indicator simulation.

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS

1.1 Introdução

A cultura da cana-de-açúcar continua em expansão no Brasil, sendo o Estado de São Paulo o maior produtor, com 51,82% da área total cultivada no Brasil, segundo dados da CONAB (2012). A cultura consome aproximadamente 13% do total de fertilizantes utilizados anualmente no Brasil, (ANDA, 2008; OTTO et al., 2010). O fósforo (P) e o potássio (K) são macronutrientes utilizados como fertilizantes dos solos. Do total do fertilizante potássico e do fosfatado utilizado no Brasil, 90% e 51%, respectivamente, são importados (KINPARA, 2003; LUPINACCI, 2012).

O K é o macronutriente mais absorvido pela cana-de-açúcar (MALAVOLTA, 1994) e o P é o macronutriente exigido em menor quantidade pelas plantas, porém é o que mais limita o desenvolvimento e a longevidade da cultura, além de sua aplicação exigir um grande investimento devido ao alto custo dos fertilizantes fosfatados. Os solos brasileiros apresentam baixos teores de potássio (K) e fósforo (P) na forma disponível ou solúvel, isto é, em forma assimilável pelas plantas (ERNANI et al., 2007; BENITES et al., 2010; SAMPAIO et al., 2011). Um dos motivos da carência de K nestes solos é que a forma solúvel é facilmente lixiviada no perfil do solo. A reduzida disponibilidade de fósforo em solos brasileiros está relacionada aos baixos teores no material de origem, à baixa solubilidade dos compostos de fósforo e à sua imobilização causada pelas fortes interações, denominadas de adsorção, que o fósforo apresenta com os constituintes destes solos (MOREIRA et al., 2006).

Atualmente, grande parte da aplicação de fertilizantes é efetuada levando em conta a necessidade média do nutriente em determinada área, não considerando a existência de estrutura de dependência espacial entre as distintas regiões dentro de uma área de manejo. Tais aplicações elevam o custo do processo produtivo, uma vez que regiões com pouca necessidade de nutriente recebem as mesmas taxas de aplicação que as regiões com deficiência (MARQUES JÚNIOR et al., 2008). Várias

pesquisas mostram que a variabilidade dos atributos químicos do solo apresenta correlação ou dependência espacial (TRANGMAR et al., 1985; SOUZA et al., 2003; SOUZA et al. 2004). Portanto, a obtenção de informações a respeito da variabilidade espacial dos atributos do solo, tais como os teores de P e K do solo, é de grande importância para a avaliação da fertilidade e para a recomendação da adubação, visando à melhora do manejo e ao aumento de produtividade. Os padrões espaciais das propriedades do solo podem ser obtidos por meio de métodos geoestatísticos. Estes métodos são, por definição, procedimentos matemáticos que ajustam uma função para determinados pontos de dados amostrais para, assim, poder-se estimar o valor de uma variável em um ponto não amostrado.

Dentre os métodos geoestatísticos, a krigagem, em suas diversas variações, é o estimador amplamente aplicado na predição espacial de nutrientes do solo (MARQUES JUNIOR et al., 2008; SILVA et al., 2008; SAMPAIO et al., 2011; SANTOS; GONTIJO; NICOLE, 2012; CAMARGO et al., 2013). A krigagem obtém uma única realização segundo o critério de minimização da variância do erro. Os mapas krigados capturam as grandes variações, mas sempre suavizam e não descrevem realisticamente a variabilidade do fenômeno.

As ferramentas geoestatísticas são usadas não só para a predição de nutrientes do solo, mas também para avaliar as incertezas associadas a estas predições. Na geoestatística, a incerteza é uma medida indicativa da magnitude do erro, uma vez que não se pode determinar com exatidão o erro de estimação do atributo, pois para isto seria necessário o conhecimento do valor real do atributo em cada posição estimada (ISAAKS; SRISVASTAVA, 1989).

Como a krigagem gera somente um mapa, a variância desta estimativa fornece subsídio apenas para a avaliação da incerteza local, não sendo possível a avaliação da incerteza em vários pontos simultaneamente (incerteza espacial). Como alternativa para suprir as limitações da krigagem, as simulações estocásticas surgiram como métodos mais adequados para avaliação de incertezas. Os modelos de simulação não fornecem uma imagem mais provável para o atributo simulado, mas, sim, um conjunto de imagens equiprováveis com a mesma variabilidade espacial que podem ser processadas e manipuladas para fornecer diferentes medidas de incerteza (GOOVAERTS, 1997).

Dentre as simulações estocásticas, a simulação sequencial gaussiana (SSG) e a simulação sequencial indicatriz (SSI) estão ganhando popularidade na geoestatística, particularmente em estudos para avaliar e quantificar a incerteza de propriedades do solo, embora, no Brasil, exista uma carência de trabalhos nesta área. A incerteza da distribuição espacial, usando a SSG e as técnicas de krigagem, foi avaliada em trabalhos de: Bourennane et al. (2007, 2010), com elementos contaminantes e conteúdo de água; Zhao et al. (2009) e Sun et al. (2012), com nutrientes; e Chai, Huang e Yuan (2007), com matéria orgânica. A SSI foi utilizada para avaliar a incerteza da distribuição espacial de metais pesados (JUANG; CHEN; LEE, 2004); de indicadores de fertilidade (ORTIZ et al., 2004); e de carbono orgânico (ZHAO et al., 2005). Os métodos de krigagem, a SSG e a SSI, foram avaliados conjuntamente em trabalhos com carbono orgânico (DELBARI; LOISKANDL; AFRASIAB, 2010) e variáveis geológicas (YU; LI, 2012). Estas informações ressaltam a importância de avaliar a incerteza da distribuição espacial de nutrientes do solo, utilizando simulações estocásticas, para otimizar o uso dos fertilizantes na cultura da cana-de-açúcar.

1.2 Objetivos

1.2.1 Gerais

Avaliar o desempenho das técnicas KO, SSG e SSI por meio de um estudo de caso utilizando os atributos fósforo disponível e potássio disponível do solo, com enfoque no tratamento de incertezas.

1.2.2 Específicos

1. Caracterizar a variabilidade e a distribuição espacial do fósforo disponível e potássio disponível do solo.
2. Avaliar o desempenho da SSG e da KO na modelagem da incerteza das previsões do fósforo disponível.

3. Avaliar o desempenho das simulações SSG e SSI na modelagem da incerteza das predições do potássio disponível, utilizando como método de referência a estimativa KO.

1.3 Revisão de literatura

1.3.1 Variabilidade espacial de atributos do solo e manejo localizado

O processo de cultivo e colheita remove nutrientes do solo. A menos que os níveis destes nutrientes sejam excessivamente altos, estes precisam ser repostos para o solo permanecer produtivo. A análise de solo é a ferramenta comumente usada para determinar a necessidade de fertilizantes para a cultura, porém o nível de fertilidade normalmente não é uniforme em toda área. A determinação desta variação é um fator importante que deve ser considerado ao planejar um programa de análise de solo (MALLARINO e WITTRY, 2004). Em função da alta variabilidade espacial dos atributos do solo, este apresenta teores diferenciados de nutrientes dentro de uma mesma área de manejo. Porém, tradicionalmente, os fertilizantes têm sido aplicados de forma uniforme o que ocasionará uma aplicação excessiva em algumas localidades e deficiente em outras (SAWYER, 1994; MARQUES JÚNIOR et al., 2008).

O manejo localizado é baseado no gerenciamento agrícola de informações sobre a variabilidade espacial dos atributos do solo. Esta forma de manejo propõe aumentar a eficiência do gerenciamento agrícola por meio da utilização de ferramentas que permitem a identificação da variabilidade dos atributos do solo e uma intervenção de forma específica de forma a promover a minimização de custos, aumento de produtividade e consequentemente maior lucratividade (MAULE et al., 2001). Assim, as análises de solos com controle da variabilidade espacial dos atributos, permitem identificar e mapear zonas mínimas de manejo, ou áreas de manejo específico, conceitualmente utilizado em agricultura de precisão. Especificamente no manejo do solo, a agricultura de precisão tem como principal conceito aplicar no local correto, no momento adequado, as quantidades de insumos necessários à produção agrícola (DOBERMANN e PING, 2004).

Análises estatísticas clássicas que consideram a independência entre as amostras, baseadas na média, vêm sendo substituídas por análises geoestatísticas (ISAAKS & SRIVASTAVA, 1989). A geoestatística possibilita a interpretação dos resultados com base na estrutura da variabilidade natural dos atributos avaliados, considerando a dependência espacial dentro do intervalo de amostragem (VIEIRA, 2000). A análise geoestatística pode indicar alternativas não só para reduzir os efeitos da variabilidade na produção das culturas, como também para aumentar a possibilidade de se estimarem respostas de atributos químicos do solo em função de determinadas práticas de manejo (TRANGMAR et al., 1985; OVALLES e REY, 1994; SILVEIRA et al., 2000). Além disso, a estratégia de amostragem do solo pode ser melhorada com a incorporação de um modelo de variabilidade espacial. De acordo com Cavalcante et al. (2007), o conhecimento da variabilidade dos atributos do solo sob diferentes usos e manejos constitui-se numa importante meta para que se possa empregar o manejo mais adequado, considerando a aplicação de fertilizantes, estratégias de amostragem e planejamento de delineamento de pesquisa em campo. Essa tecnologia permite aplicar doses de fertilizantes com taxa variada, segundo a necessidade de cada local específico, reduzindo os impactos negativos na agricultura e no meio ambiente (MOLIN, 2001).

1.3.2 Geoestatística

A geoestatística está fundamentada na teoria das variáveis regionalizadas, segundo a qual os valores de uma variável estão, de alguma forma, relacionados à sua distribuição espacial, ou seja, o valor da variável depende de sua posição na área de estudo (ISAAKS; SRIVASTAVA, 1989). Na teoria das variáveis regionalizadas, $Z(x)$ pode ser definida como uma variável aleatória (VA) que assume diferentes valores Z , em função da posição x dentro de uma região S , com certa aparência de continuidade (VIEIRA, 2000). O conjunto de variáveis $Z(x)$, medidas em toda a área, pode ser considerado uma função aleatória $Z(x)$, uma vez que são variáveis aleatórias, regionalizadas, e considera-se que a dependência entre elas é regida por algum mecanismo probabilístico (ISAAKS; SRIVASTAVA, 1989). O teor de fósforo disponível, por exemplo, pode ser considerado uma variável regionalizada

no espaço de duas dimensões. Segundo Burrough e McDonnel (2006), os métodos geoestatísticos para interpolação reconhecem que a variabilidade espacial de qualquer atributo contínuo do solo é muito irregular para ser modelada por uma função matemática polinomial simples, porém mais bem descrita por uma superfície estocástica.

A VA assume diferentes valores de acordo com uma função de distribuição acumulada (*fda*) (GOOVAERTS, 1997). Assim, um ponto $Z(x_i)$ é tratado como uma variável aleatória com média, μ , variância, σ^2 , momentos de primeira e segunda ordens, e uma *fda* entre duas VA, $Z(x_1)$ e $Z(x_2)$ (MATHERON, 1971). O conjunto de VA, $Z(x_i)$, $i=1,\dots,N$, correlacionadas entre si, constitui uma função aleatória (FA), um processo aleatório ou um processo estocástico, da qual se conhece apenas uma realização $z(x_i)$ – conjunto de dados experimentais. Uma FA é definida como o conjunto de variáveis aleatórias geralmente dependentes para cada local da área de estudo.

Com apenas uma realização, é impossível estimar momentos estatísticos de segunda ordem, e a solução proposta pela geoestatística é assumir a estacionariedade da FA (SOARES, 2006). Se admitirmos que todas as VAs possuem a mesma média sobre a área em estudo, este parâmetro passa a ser independente da localização (x_i). Essa hipótese de estacionariedade da média não pode ser validada nem refutada na prática, pois, na realidade, só existe uma realização da FA (VIEIRA, 2000). Se a esperança matemática de uma VA é constante, independentemente da origem, pode-se dizer que é estacionária de primeira ordem, e, portanto, a média será a mesma para todo o processo:

Um processo é estacionário se o seu desenvolvimento, no tempo ou no espaço, ocorre de maneira mais ou menos homogênea, com oscilações aleatórias contínuas em torno de um valor médio (GUIMARÃES, 2004). A hipótese de estacionariedade em relação à covariância e ao variograma, que são medidas das médias da correlação entre duas VAs, depende somente da distância espacial entre elas e é independente de sua localização (GOOVAERTS, 1997). Essa hipótese implica que os pares correspondentes da FA $\{Z(x_i), Z(x_{i+h}); i=1,\dots,n\}$ são originados da mesma distribuição em dois pontos (duas VAs que relatam o mesmo valor do atributo z , em dois pontos ou locais diferentes).

Uma FA é dita estacionária de segunda ordem quando o valor esperado (média) é constante e invariante dentro da área de estudo, e a covariância e o variograma entre dois pontos existem e dependem somente do vetor de separação h . A similaridade ou a dissimilaridade entre dados separados por um vetor h podem ser quantificadas pela covariância e pelo variograma, respectivamente.

A covariância entre dados separados por um vetor h é calculada por:

$$C(h) = \frac{1}{N(h)} \sum_{i=1}^{N(h)} [z(x_i)z(x_i + h) - m_{-h}m_{+h}]^2 \quad (1.1)$$

em que $N(h)$ é o número de pares de dados dentro da classe de distância e direção, e m_{-h} e m_{+h} são as médias correspondentes à cauda e à cabeça (lag médio) dos pontos (GOOVAERTS, 1997).

Com base nos dados amostrais dentro de uma vizinhança, a geoestatística, por meio do processo de interpolação, obtém as estimativas nos locais não amostrados da área de estudo. Antes da estimação, a variabilidade espacial tem de ser modelada por uma função denominada de variograma. Esta função fornece uma medida da mudança da similaridade espacial em função da distância de separação para uma direção determinada ou para todas as direções. O variograma fornece informações úteis para a interpolação, otimização amostral e também é usado para compreender a estrutura espacial de um conjunto de dados (OLIVER, 1999). Para isto, é necessário ajustar um modelo teórico ao variograma experimental, o qual é estimado por:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [z(x_i) - z(x_i + h)]^2 \quad (1.2)$$

em que, $\hat{\gamma}(h)$ é a semivariância experimental para uma distância de separação h , $z(x_i)$ é o valor da propriedade no ponto i , e $N(h)$ é o número de pares de pontos separados pela distância h . O variograma descreve a continuidade espacial das variáveis como função das distâncias entre duas localizações (ISAACS; SRIVASTAVA, 1989).

A modelagem do variograma é uma técnica exploratória que auxilia os métodos geoestatísticos, contribuindo na modelagem da dependência espacial, determinando os parâmetros básicos do modelo: efeito pepita (C_0), patamar (C) e alcance (a). O efeito pepita representa a variância aleatória frequentemente causada por erros de medida ou microvariabilidade da propriedade que não pôde ser detectada na escala de amostragem (TRANGMAR et al., 1985). O patamar (C_0+C_1) representa a semivariância na qual o modelo de variograma atinge o valor do alcance, sendo essa próxima à variância amostral dos dados. O alcance indica o limite de dependência espacial entre amostras; desta forma, amostras espaçadas acima deste valor não apresentam dependência espacial entre si (ISAAKS; SRIVASTAVA, 1989). O gráfico de h vs $\hat{\gamma}(h)$ é denominado de variograma. A Figura 1.1 mostra um variograma experimental ideal. Como amostras coletadas mais próximas umas das outras devem ser mais parecidas do que aquelas separadas por grandes distâncias, $\hat{\gamma}(h)$ aumenta à medida que h cresce, até se estabilizar no valor do alcance a .




Figura 1.1. Variograma experimental e parâmetros alcance (a); efeito pepita (C_0); variância estruturada (C_1); e patamar (C).

De posse do variograma experimental, que é aquele obtido a partir do conjunto de dados amostrais, é necessário ajustá-lo a um modelo teórico de referência, ou seja, a uma função que definirá os parâmetros do variograma, efeito pepita, alcance e patamar. Entre os modelos disponíveis, os mais utilizados para modelar os fenômenos espaciais nas ciências da Terra e do ambiente são o esférico, o exponencial e o gaussiano (SOARES, 2006). O modelo esférico, dado pela

equação (1.3), é o mais comumente ajustado em Ciência do Solo e possui comportamento linear em pequenas distâncias.

$$\begin{cases} \hat{\gamma}(h) = C_0 + C_1 \left[\frac{3}{2} \left(\frac{h}{a} \right) - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], & \text{se } 0 < h \leq a \\ \hat{\gamma}(h) = C_0 + C_1, & \text{se } h > a \end{cases} \quad (1.3)$$

O modelo exponencial, dado pela equação (1.4), possui comportamento linear perto da origem, porém com crescimento mais rápido do que o do modelo esférico. O modelo Gaussiano, dado pela equação (1.5), é ajustado para fenômenos regulares e contínuos, com crescimento lento de $\hat{\gamma}(h)$ e comportamento parabólico junto à origem. Nesses modelos, d é a máxima distância do variograma

$$\hat{\gamma}(h) = C_0 + C_1 \left[1 - \exp \left(-3 \frac{h}{a} \right) \right], \text{ se } 0 < h < d \quad (1.4)$$

$$\hat{\gamma}(h) = C_0 + C_1 \left[1 - \exp \left(-3 \left(\frac{h}{a} \right)^2 \right) \right], \text{ se } 0 < h < d \quad (1.5)$$

O modelo do variograma pode revelar muitas características da variação espacial do atributo em estudo. Um variograma errático sugere que poucas amostras foram usadas para calcular a semivariância. Para se obter um variograma estável, é necessário de 50 a 100 pontos (BURROUGH; McDONNELL, 2006). O alcance fornece uma informação a respeito do tamanho do raio de procura que deve ser usado, pois toda amostra, cuja distância ao ponto a ser estimado for menor ou igual ao alcance, fornece informações sobre o ponto. Quando o alcance é menor que a distância entre as amostragens, tem-se o chamado efeito pepita puro e uma distribuição espacial completamente ao acaso, deixando-se de aplicar os princípios da geoestatística. O alcance também é utilizado para definir o raio de ação ("range") máximo de interpolação pela krigagem, onde os pesos utilizados na ponderação afetam os valores estimados (SOARES, 2006).

O estudo da estrutura espacial pela análise da função de semivariância, utilizando o variograma, não constitui o objetivo final da análise espacial. É necessário estimar os valores em locais não amostrados, para se obter o conhecimento do padrão espacial da variável regionalizada. Dessa forma, a análise da estrutura de dependência espacial deve ser vista como um passo fundamental que precede as técnicas de estimação de qualquer valor, em qualquer posição da área de estudo (VIEIRA; CARVALHO, 2001).

1.3.3 Krigagem

Krigagem é um nome usual utilizado na geoestatística para a família de algoritmos de regressão de mínimos quadrados. A krigagem é um dos mais importantes métodos de interpolação que deu origem a todo campo da geoestatística (MATHERON, 1962). A krigagem é um estimador linear que obtém estimativas não viesadas de variáveis regionalizadas em locais não amostrados. É linear porque suas estimativas são feitas por combinações lineares; e não viesado porque o erro de estimativa esperado é nulo. Os estimadores de krigagem fornecem a melhor estimativa local da variável pela minimização da estimativa da variância, resultando na suavização dos detalhes espaciais, conhecido como “efeito de suavização”. Esta suavização reflete-se em uma baixa precisão global das estimativas a qual pode ser observada das seguintes maneiras: (1) a não reprodução do variograma observado, sendo que o variograma experimental dos valores estimados apresentará maior amplitude e menor variância espacial, o que significaria uma continuidade exagerada nos valores; (2) a não reprodução do histograma dos valores observados, sendo que os valores estimados apresentarão frequências muito maiores para as classes próximas à média (GOOVAERTS, 1997). Além disso, a suavização não é uniforme, o que implica mapas de padrão espacial com maior variação em regiões densamente amostradas do que em áreas com poucos pontos amostrais.

Algumas técnicas de krigagem são apresentadas com o objetivo de descrever a obtenção da estimativa e das funções de distribuição acumulada condicional (fdac) utilizadas nos algoritmos de simulação estocástica deste trabalho. A krigagem

simples (KS) é a forma mais básica de krigagem, já que seu modelo é o mais simples em termos de formulação matemática. É basicamente uma combinação linear de variáveis aleatórias nas localidades x_i , sendo o estimador dado por:

$$\hat{z}_{KS}(x_0) = m + \sum_{i=1}^N \lambda_i (z(x_i) - m), \quad (1.6)$$

em que, $\hat{z}_{KS}(x_0)$ é o valor estimado no ponto 0; N é o número de valores utilizados na estimação; λ_i é o peso associado a cada valor observado; $z(x_i)$ é o valor observado no ponto i , e m é a média, considerada constante em qualquer ponto do domínio. O estimador KS não inclui restrições quanto ao peso. A KS é sempre não viesada, pois o erro da estimativa, diferença entre o valor estimado e o verdadeiro, é sempre nulo na média (SOARES, 2006).

Dentre esta família de algoritmos, a krigagem ordinária (KO) é o estimador mais popular. A KO é um método de interpolação preferível porque não requer conhecimento da estacionariedade da média sobre a área de estudo. Somente amostras locais, que estão dentro do alcance de dependência espacial, são usadas na krigagem (TRANGMAR et al., 1985). Da mesma forma que na KS, deseja-se minimizar a variância do erro, só que na KO é necessário acrescentar a condição de não viés, isto é, a somatória dos pesos igual a 1.

A estimativa, $\hat{z}(x_0)$, e a variância, σ^2 , da KO em um local não amostrado x_0 são calculadas, respectivamente, pelas equações (1.7) e (1.8):

$$\hat{z}(x_0) = \sum_{i=1}^N \lambda_i z(x_i), \text{ com } \sum_{i=1}^N \lambda_i = 1, \quad (1.7)$$

$$\sigma^2(x_0) = \sum_{i=1}^N \lambda_i \gamma(x_0, x_i) + \mu, \quad (1.8)$$

em que, $\hat{z}(x_0)$ é o valor estimado no ponto 0; N é o número de valores utilizados na estimação; λ é o peso associado a cada valor observado, e $z(x_i)$ é o valor observado no ponto i ; $\gamma(x_0, x_i)$ é a semivariância entre o local a ser estimado x_0 e o

i -ésimo ponto amostrado, e μ é o parâmetro de Lagrange utilizado para minimizar a variância da krigagem (Soares, 2006).

A krigagem indicatriz (KI) foi proposta por Journel (1983) como uma alternativa não paramétrica para as abordagens paramétricas. A expressão "não paramétrica" não significa que o modelo de função aleatória (FA) não tem parâmetros, mas que o mesmo tem mais parâmetros livres do que, por exemplo, o modelo gaussiano, em que as fdacs são completamente definidas por dois parâmetros: a média e variância. A abordagem indicatriz baseia-se na codificação da função aleatória $z(x)$ em um vetor de indicadores $I(x_\alpha; z_k)$ definido com base em diferentes parâmetros de corte z_k :

$$I(x_\alpha; z_k) = \begin{cases} 1 & \text{se } z(x_\alpha) \leq z_k \\ 0 & \text{caso contrário} \end{cases}, k = 1, \dots, K \quad \alpha = 1, \dots, n \quad (1.9)$$

A estimativa da fdac, fornecida pela KI, para um determinado corte é dada por:

$$[I(x_\alpha; z_k)]^* = E[I(x_0; z_k) | (n)]^* = P^*[Z(x_0) \leq z_k | (n)] \quad (1.10)$$

em que, n representa o condicionamento das informações disponíveis nas vizinhanças da posição x_0 , na qual será realizada a estimativa. O processo KI é repetido para uma série de K valores de cortes que subdividem o intervalo de variabilidade de um atributo contínuo, ou para cada uma das classes de uma variável categórica. A fdac, construída por meio da união das K estimativas do tipo (1.10), representa um modelo probabilístico para a incerteza sobre um valor não amostrado $Z(x_0)$.

Para variáveis categóricas, não é necessária a prévia transformação indicatriz. Se $Z(x)$ é uma variável contínua, então a correta seleção dos cortes z_k é uma etapa crucial: quanto mais cortes, maior o número de covariâncias a serem inferidas, e quanto menos cortes, mais detalhes da distribuição serão perdidos. Com os dados referentes às variáveis indicadoras, podem-se usar tanto a KS como a KO para realizar a estimativa da fdac em cada posição.

Apesar da simplicidade do formalismo da indicatriz para o cálculo de valores da lei de distribuição de probabilidades de $Z(x_0)$, no ponto x_0 , este possui alguns inconvenientes, que apesar de, na prática, não serem limitativos, é necessário conhecê-los:

1. Para diferentes valores de corte, z_1 e z_2 , o método não garante a manutenção da relação de ordem:

$$[I(x_0; z_1)]^* \leq [I(x_0; z_2)]^* \quad \text{se} \quad z_1 < z_2,$$

uma vez que as estimações de $[I(x_0; z_1)]^*$ e $[I(x_0; z_2)]^*$ são independentes.

Para que aquela relação seja verdadeira para qualquer par de valores de z_1 e z_2 , é suficiente que os pesos λ_i , para a estimação de $[I(x_0; z_1)]^*$ e $[I(x_0; z_2)]^*$, sejam iguais e positivos, isto é, independentes de z .

2. Uma vez que o estimador de krigagem impõe que a soma dos pesos seja 1, mas não impõe que não haja ponderadores negativos ou superiores a 1, não há garantia de que os valores estimados estejam compreendidos entre 0 e 1.

Todas as metodologias que utilizam a abordagem indicatriz estão sujeitas a ocorrência dos problemas de relação de ordem. O GSLIB (DEUTSCH; JOURNEL, 1998) faz as correções necessárias, embora, segundo os autores, as correções são bastante reduzidas. Os problemas de relação de ordem são, portanto, a maior desvantagem do formalismo da indicatriz (SOARES, 2006).

1.3.4 Simulações estocásticas

As simulações estocásticas surgiram como uma proposta para a problemática do efeito de suavização causado pelas técnicas de interpolação derivadas de métodos de minimização da variância dos erros, como a KO. Esta técnica consiste na criação de algoritmos que simulam o comportamento espacial de determinadas variáveis. O termo estocástico, neste caso, refere-se ao fato de estes algoritmos serem não determinísticos, isto é, quando há mais de uma opção entre o valor a ser

assumido em determinado ponto de execução do algoritmo, tal escolha será aleatória, gerando inúmeras possíveis realizações a partir de um mesmo conjunto inicial de dados (SOARES, 2006). Embora ainda não se tenha chegado a um consenso sobre o número mínimo de realizações que devem ser geradas, alguns trabalhos buscam caracterizar e quantificar o impacto do número de realizações sobre as simulações de propriedades do solo (GOOVAERTS, 1999; LIN, 2008). Segundo Monteiro (2003), o número de realizações produzidas deve ser tal que a média dos valores simulados seja semelhante aos valores estimados pela técnica da KO.

As simulações estocásticas, em oposição aos modelos de krigagem, geram um conjunto de realizações igualmente prováveis a partir de uma função aleatória. Estes métodos, diferentemente da KO, possuem precisão global, pois reproduzem a variabilidade dos dados de entrada por meio do histograma e, especialmente pelo variograma. Os múltiplos cenários gerados pelos modelos estocásticos fornecem subsídios para a avaliação das incertezas inerentes aos fenômenos complexos como os relacionados às propriedades do solo, por exemplo.

As simulações diferem dos mapas krigados, principalmente nos seguintes aspectos (DEUSCTH; JOURNAL, 1998; BASARIR et al., 2010):

- Preservam os dados de entrada nos locais amostrados;
- Apresentam a mesma dispersão espacial (reprodução dos variogramas) e a mesma distribuição dos valores (reprodução dos histogramas);
- Fornecem vários modelos alternativos, sendo cada um uma representação “ótima” da realidade global, ao contrário da KO, que fornece um único modelo, considerado “ótimo” no que diz respeito à precisão local.

Uma das principais críticas às simulações estocásticas é o fato de serem geradas n imagens equiprováveis a partir de um mesmo conjunto de dados, dificultando a escolha de uma realização, porém os cenários gerados permitem avaliar as incertezas (SRISVASTAVA, 1994). Além disso, é possível gerar um mapa único a partir do cálculo da média de todas as realizações geradas, a qual é denominada E-type. Com o avanço dos recursos computacionais, a análise e a utilização destes cenários se tornarão tão aplicáveis quanto os estimadores de krigagem.

Para simulações condicionais, como a simulação sequencial gaussiana (SSG) e a simulação sequencial indicatriz (SSI), todas as características mencionadas anteriormente são obtidas; no entanto, algumas simulações não atendem ao princípio de honrar os dados observados, sendo estas denominadas simulações não condicionais.

O objetivo da simulação sequencial gaussiana (SSG) é a reprodução de propriedades da distribuição gaussiana dos dados amostrais nas estimativas por meio do uso sequencial de distribuições condicionais, que seriam funções que descrevem completamente a distribuição de probabilidade para uma determinada variável aleatória (CAERS, 2000). É denominada gaussiana devido ao fato de ser necessário que os dados sejam, primeiramente, transformados para um espaço gaussiano normal. Os mapas simulados resultam de imagens equiprováveis que reproduzem a variabilidade espacial dos dados amostrais.

No algoritmo da SSG, cada variável é simulada sequencialmente de acordo com sua fdac gaussiana completamente caracterizada por meio de um sistema de krigagem. Em cada etapa, os dados condicionantes são formados pelos dados originais e pelos previamente simulados que se encontram dentro da vizinhança da posição a ser simulada.

Uma desvantagem da SSG é que este modelo se baseia na premissa da "gaussianidade" multivariada, implicando a normalidade não só da fdac de um ponto, mas também das fdacs de dois, três pontos normalizados, o que, na prática, não pode ser verificada. Outra desvantagem reportada em alguns trabalhos é que a SSG resulta em pequena continuidade dos valores extremos (GOOVAERTS, 2001).

Como o próprio nome sugere, a simulação sequencial indicatriz (SSI) segue a abordagem sequencial, só que, diferentemente da SSG, nenhuma hipótese é feita sobre a forma da distribuição condicional. As estimativas da distribuição condicional em cada nó são obtidas por krigagem indicatriz (seção 1.3.3), utilizando variogramas indicadores. A execução do algoritmo da SSI é mais lenta do que a da SSG, porém, teoricamente, a SSI tem a vantagem de preservar a conectividade entre os valores extremos, o que é difícil de modelar no paradigma multigaussino (VANN; BERTOLI; JACKSON, 2002).

1.3.5 Incertezas dos interpoladores geoestatísticos

Os modelos resultantes, de qualquer que seja o método de interpolação escolhido para a predição espacial de nutrientes de solo, sempre terão um erro associado que precisa ser considerado na definição de áreas de manejo específico. Não se pode calcular este erro exatamente, pois os verdadeiros valores nos locais não amostrados são desconhecidos. A incerteza é, de certa forma, alguma indicação da magnitude desse erro. A modelagem da incerteza, segundo Goovaerts (1997), é uma discussão sobre o desconhecido, que tem como objetivo avaliar os riscos envolvidos nos processos de tomada de decisão. A partir da modelagem da incerteza, é possível otimizar as estimativas de acordo com critérios definidos.

A avaliação da incerteza espacial, ou seja, a avaliação de incerteza de um conjunto de pontos simultaneamente, só é possível por meio da avaliação do comportamento deste conjunto de pontos em vários mapas, o que não é viável por meio da KO. Assim, a KO fornece apenas uma medida da incerteza local. Além disso, na maioria dos casos, a utilização da variância produzida pela KO como medida de erro local é inadequada, uma vez que apenas o variograma e a configuração amostral são considerados em seu cálculo (ZHAO et al., 2005). Em resumo, o objetivo geral dos modelos de krigagem é a obtenção da imagem mais próxima provável das características de um dado atributo que, simultaneamente, passe pelos pontos experimentais (SOARES, 2006).

A ideia da simulação estocástica como instrumento avaliador da incerteza espacial é extremamente simples e consiste na geração de N_s conjuntos de valores simulados – realizações. Trata-se de imagens simuladas da área que se pretende analisar, $Z(x_i)$, $s = 1, \dots, N_s$, com as mesmas estatísticas e as mesmas características de continuidade espacial – variograma das amostras. A partir das N_s realizações do fenômeno espacial, consideradas equiprováveis, o comportamento espacial extremo e a incerteza do fenômeno podem ser contabilizados. Por exemplo, quantas vezes uma dada região da imagem ultrapassa um dado limite z em 100 imagens.

Existem várias metodologias e estatísticas utilizadas para avaliar a incerteza de uma ou de um conjunto de realizações, e estas metodologias checam se o modelo simulado reproduz (LEUANGTHONG; MCLENNAN; DEUTSCH, 2004):

1. A variabilidade dos dados de entrada;
2. A distribuição dos dados de entrada;
3. A continuidade espacial caracterizada pelo modelo do variograma.

A acurácia dos modelos de predição pode ser verificada usando o procedimento de validação externa. Este procedimento consiste em separar parte dos pontos medidos (pontos de validação) e deixá-los fora do processo de simulação. Estes pontos são simulados normalmente como se fossem pontos perdidos, levando-se em conta a variabilidade espacial local, expressa nas primeiras distâncias, no variograma (CERRI et al., 2004; TEIXEIRA et al., 2011). De posse dos pontos de validação e dos seus correspondentes valores simulados, estes podem ser usados na metodologia, proposta por Deutsch (1997) e para o cálculo da raiz do erro quadrático médio – REQM:

$$REQM = \left\{ \frac{1}{n} \sum_{i=1}^n [z(x_i) - \hat{z}(x_i)]^2 \right\}^{0.5} \quad (1.11)$$

em que, n é o número de valores utilizados na validação; $z(x_i)$ é o valor da propriedade no ponto i , e $\hat{z}(x_i)$ é o valor estimado da propriedade no ponto i (CHAI; HUANG; YUAN, 2007).

A metodologia, proposta por Deutsch (1997) examina a acurácia na reprodução da fdac dos dados amostrais pelas simulações, verificando as proporções de valores dos dados do conjunto de validação que pertencem a intervalos de probabilidade (IP) - p simétricos, calculados a partir da fdac $F(u, z|(n))$. Em qualquer localização u , o conhecimento da fdac permite calcular uma série de IP - p simétricos limitados pelos quantis da fdac $(1-p)/2$ e $(1+p)/2$. As frações de valores verdadeiros a que pertencem cada IP- p simétrico são obtidas por:

$$\bar{\xi}_{(p)} = \frac{1}{N} \sum_{j=1}^{N_p} \xi(u_j, p) \quad \forall p \in [0,1] \quad (1.12)$$

$$\text{com, } \xi(u_j, p) = \begin{cases} 1 & \text{se } \hat{F}^{-1}(u_j, (1-p)/2) < z(u_j) \leq \hat{F}^{-1}(u_j, (1+p)/2) \\ 0 & \text{caso contrário} \end{cases}$$

A acurácia na reprodução dos variogramas pode ser verificada visualmente por meio da análise entre o modelo do variograma dos dados de entrada e os variogramas calculados para as múltiplas realizações (LEUANGTHONG; MCLENNAN; DEUTSCH, 2004), e numericamente, por meio de equação proposta por Goovaerts (2000), que calcula a variação da dispersão dos variogramas produzidos pelas estimações em torno do variograma dos dados originais:

$$\varepsilon_\gamma = \sum_{s=1}^S \frac{[\gamma(h_s) - \hat{\gamma}(h_s)]^2}{[\gamma(h_s)]^2}, \quad (1.13)$$

em que, S é o número de intervalos (lags) de distância h utilizados para a construção do variograma; $\gamma(h_s)$ é a semivariância na distância h_s calculada a partir dos valores observados, e $\hat{\gamma}(h_s)$ é a semivariância na distância h_s calculada a partir dos valores simulados.

1.4 Referências

ANDA - ASSOCIAÇÃO NACIONAL PARA DIFUSÃO DE ADUBOS - **Anuário Estatístico do Setor de Fertilizantes**. São Paulo, 2008.

BASARIR, H.; KUMRAL, M.; KARPUZ, C.; TUTLUOGLU, L. Geostatistical modeling of spatial variability of SPT data for a borax stockpile site. **Engineering Geology**, Amsterdam, v. 114, n. 3-4, p.154-163, 2010.

BENITES, V. M.; CARVALHO, M. C. S.; RESENDE, A. V.; POLIDORO, J.C.; BERNARDI, A. C. C. & OLIVEIRA, F. A. Potássio, cálcio e magnésio. In: PROCHNOW, L. I.; CASARIN, V.; STIPP, S. R. (Eds.). **Boas práticas para o uso eficiente de fertilizantes: nutrientes**. Piracicaba, IPNI, 2010. p. 137-191.

BOURENNANE, H.; DOUAY, F.; STERCKEMAN, T.; VILLANNEAU, E.; CIESIELSKI, H.; KING, D.; BAIZE, D. Mapping of anthropogenic trace elements inputs in agricultural topsoil from Northern France using enrichment factors. **Geoderma**, Amsterdam, v. 157, n. 3-4, p.165-174, 2010.

BOURENNANE, H.; KING, D.; COUTURIER, A.; NICOUILLAUD, B.; MARY, B.; RICHARD, G. Uncertainty assessment of soil water content spatial patterns using geostatistical simulations: An empirical comparison of a simulation accounting for single attribute and a simulation accounting for secondary information. **Ecological Modelling**, Amsterdam, v. 205, n. 3-4, p. 323–335, 2007.

CAERS, J. Adding local accuracy to direct sequential simulation. **Mathematical Geology**, v.32; n. 7, p. 815-850, 2000.

CAMARGO L. A.; MARQUES JÚNIOR J.; PEREIRA G. T.; ALLEONI L. R. F. Spatial correlation between the composition of the clay fraction and contents of available phosphorus of an Oxisol at hillslope scale. **Catena**, Amsterdam, v.100, p. 100–106, 2013.

CAVALCANTE, E. G. S.; ALVES, M. C.; SOUZA, Z. M.; PEREIRA, G. T. Variabilidade espacial de atributos químicos do solo sob diferentes usos e manejos. **Revista Brasileira de Ciência do Solo**, Viçosa, v.31, p.1329-1339, 2007.

CHAI, X.; HUANG, Y.; YUAN, X. Accuracy and uncertainty of spatial patterns of soil organic matter. **New Zealand Journal of Agricultural Research**, Singapore, v. 50, n. 5, p. 1.141–1.148, 2007.

CONAB– Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: cana-de-açúcar, Segundo Levantamento Agosto/2012**. Disponível em: http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12_09_05_09_11_59_boletim_cana_portugues_-_agosto_2012_2o_lev.pdf. Acesso em: 10 out. 2012.

DELBARI, M.; LOISKANDL, W.; AFRASIAB, P. Uncertainty assessment of soil organic carbon content spatial distribution using geostatistical stochastic simulation. **Aust. J. Soil Res.**, Austrália, v. 48, p. 27–35, 2010.

DEUTSCH, C. Direct assessment of local accuracy and precision. In: BAAFI, E. Y., SCHOFIELD, N. A. (Eds.), **Geostatistics Wollongong '96**. Dordrecht, Kluwer Academic Publishing, 1997. p. 115–125

DEUTSCH, C. V.; JOURNEL, A. G. **GSLIB: Geostatistical software Library and User's Guide**. New York, Oxford University Press, 1998. 369 p.

DOBERMANN, A.; PING, J. L. Geoestatistical integration of yield monitor data and remote sensing improves yield maps. **Agronomy Journal**, v. 96, n. 1, p. 285-297, 2004.

ERNANI, P. R.; ALMEIDA, J. A.; SANTOS, F. C. Potássio. In: NOVAIS, R. F. et al. (Eds.). **Fertilidade do Solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. p. 551-594.

GOOVAERTS, P. Geostatistical modeling of uncertainty in soil science. **Geoderma**, Amsterdam, v. 103, n. 1-2, p. 3– 26, 2001.

GOOVAERTS, P. **Geostatistics for Natural Resources Evaluation**. Oxford University Press, 1997. 483 p.

GOOVAERTS, P. Geostatistics in soil science: state-of-the-art and perspectives. **Geoderma**, Amsterdam, v. 89, n. 1-2, p.1–45, 1999.

GUIMARAES, E. C. **Geoestatística básica e aplicada**. UFU/FAMAT, Uberlândia, fev., 2004. Disponível em :<<http://www.ebah.com.br/content/ABAAABLOUAE/geoestatistica-basica-aplicada>>. Acesso em: jun. 2012.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. Nova York: Oxford University Press, 1989. 561 p.

JOURNEL, A. G. Nonparametric estimation of spatial distributions. **Mathematical Geology**, v. 15, n. 3, p. 445-468, 1983.

JUANG, K. W.; CHEN, Y. S.; LEE, D. Y. Using sequential indicator simulation to assess the uncertainty of delineating heavy-metal contaminated soils. **Environmental Pollution**, Oxford, v. 127, n. 2, p. 229–238, 2004.

KINPARA, D. I. A. **Importância Estratégica do Potássio para o Brasil**. Embrapa Cerrados, Planaltina, 2003, 27p.

LEUANGTHONG, O.; MCLENNAN, J. A.; DEUTSCH, C. V. Minimum acceptance criteria for geostatistical realizations. **Natural Resources Research**, Nova York, v. 13, 131–141, 2004.

LIN, Y. P. Simulating Spatial Distributions, Variability and Uncertainty of Soil Arsenic by Geostatistical Simulations in geographic information systems. **The Open Environmental Journal**, Atlanta, v. 2, p. 26-33, 2008.

LUPINACCI, F. **Estudo sobre a sazonalidade nas importações de fertilizantes no Brasil e dos valores de frete na rota Santos a Araçatuba**. Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2012. Disponível em: <<http://log.esalq.usp.br/home/uploadfiles/arquivo3930.PDF>>, acesso em: jun. 2012.

MALAVOLTA, E. Importância da adubação na qualidade dos produtos: função dos nutrientes na planta. In: SÁ, M. E.; BUZZETI, S. **Importância da adubação na qualidade dos produtos agrícolas**. São Paulo: Ícone, 1994. p. 19-44.

MALLARINO, A. P.; WITTRY, D. J. Efficacy of grid and zone soli sampling approaches for site-specific assessment of phosphorus, potassium, pH and organic matter. **Precision Agriculture**, v. 5, p. 131-144, 2004.

MARQUES JÚNIOR, J.; SOUZA, Z. M.; PEREIRA, G. T.; BARBIERI, D. M. Variabilidade espacial de matéria orgânica, P, K e CTC de um Latossolo cultivado com cana-de-açúcar por longo período. **Revista de Biologia e Ciências da Terra**, Campina Grande, v. 8, p.143-152, 2008.

MATHERON, G. **Traité de géostatistique appliquée**. Editions Technip, Paris, 1962, 334 p.

MAULE, R. F., MAZZA, J. A., MARTHA JR., G. B. Produtividade agrícola de cultivares de cana-de-açúcar em diferentes solos e épocas de colheita. **Scientia. Agrícola**, Piracicaba, v. 58, p.295-301, 2001.

MOLIN, J. P. **Agricultura de precisão - o gerenciamento da variabilidade**. Piracicaba: José Paulo Molin, 2001. 83 p.

MOREIRA, F. L. M.; MOTA, F. O. B.; CLEMENTE, C. A.; AZEVEDO, B. M.; BOMFIM, G. V. Adsorção de fósforo em solos do Estado do Ceará. **Rev. Ciênc. Agron.**, Fortaleza, v. 37, p. 7-12, 2006.

OLIVER, M. A. Exploring soil spatial variation geostatisticaly. In: STANFORD, V. (Ed.) **Precision agriculture '99. Part I**. Sheffield: Academic Press, 1999, p. 17.

ORTIZ, J. O.; FELGUEIRAS, C. A.; DRUCK, S.; MONTEIRO, A. M. V. Modelagem de fertilidade do solo por simulação estocástica com tratamento de incertezas. **Pesq. agropec. bras.**, Brasília, v. 39, n.4, p.379-389,2004.

OTTO, R., VITTI, G. C. & LUZ, P. H. C. de. Manejo da adubação potássica na cultivada cana-de-açúcar. **R. Bras. Ci. Solo**, v. 34, p. 1.137-1.145, 2010.

OVALLES, F.; REY, J. Variabilidad interna de unidades de fertilidad en suelos de la depresión del Lago de Valencia. **Agronomía Tropical**, Madrid, v.44, n.1, p.41-65, 1994.

SAMPAIO, M. S.; ALVES, M. C.; SILVA, F. M.; POZZA, E. A.; OLIVEIRA, M. S. Avaliação do comportamento da variabilidade espacial do fósforo remanescente no solo de lavoura cafeeira. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR), 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0977.pdf>>. Acesso em: 07 dez. 2012.

SANTOS, E. O. J.; GONTIJO, I.; NICOLE, L. R.; Variabilidade espacial de cálcio, magnésio, fósforo, potássio no solo e produtividade da pimenta-do-reino. **R. Bras. Eng. Agríc. Ambiental**. v. 16, n. 10, p. 1.062–1.068, 2012.

SAWYER, J. E. Concepts of variable rate technology with considerations for fertilizer application. **Journal of Production Agriculture**, v. 7, p. 195-201, 1994.

SILVA, F. M.; SOUZA, Z. M.; FIGUEIREDO, C. A. P.; VIEIRA, L. H. S.; OLIVEIRA, E. Variabilidade espacial de atributos químicos e produtividade da cultura do café em duas safras agrícolas. **Ciênc. agrotec.**, Lavras, v. 32, n. 1, p. 231-241, 2008.

SILVEIRA, P. M.; ZIMMERMANN, F. J. P.; SILVA, S. C.; CUNHA, A. A. Amostragem e variabilidade espacial de características químicas de um Latossolo submetido a diferentes sistemas de preparo. **Pesquisa Agropecuária Brasileira**, Brasília, v.35, n.10, p. 2.057-64, 2000.

SOARES, A. **Geoestatística para ciências da terra e do ambiente**. 2. ed. Lisboa: IFT Press, 2006. 214 p.

SOUZA, C. K.; MARQUES JR., J.; MARTINS FILHO, M.V.; PEREIRA, G.T. Influência do relevo na variação anisotrópica dos atributos químicos e granulométricos de uma Latossolo em Jaboticabal-SP. **Engenharia Agrícola**, v. 23, n. 3, p. 486-495, 2003.

SOUZA, Z. M.; MARQUES JR., J.; PEREIRA, G. T.; MOREIRA, L. F. Variabilidade espacial do pH, Ca, Mg e V% do solo em diferentes formas do relevo sob cultivo de cana-de-açúcar. **Ciência Rural**, v. 34, n. 6, p. 1.763-1.771, 2004.

SRISVASTAVA, R. M. A overview of stochastic methods for Reservoir Characterization in YARUS, J. M. & CHABERS, R. I. (Eds.), **Stochastic modeling geostatistics: Principles, methods and case studies**. American association of petroleum geologists - computer applications in geology, n. 3, 1994.

SUN, X. ; WU, S.; WANG, H.; ZHAO, Y.; ZHAO, Y.; ZHANG, G.; MAN, Y. B.; WONG, M. H. Uncertainty Analysis for the Evaluation of Agricultural Soil Quality Based on Digital Soil Maps. **Soil Sci. Soc. Am. J.**, Madison, v. 76, p. 1.379–1.389, 2012.

TRANGMAR, B. B.; YOST, R. S.; UEHARA, G. Application of geoestatísticas to spatial studies of soil properties. **Adv. Agron.**, Madison, v. 38, p. 45-94, 1985.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F.; ALVAREZ, V. V. H.; SCHAEFER, C. E. (Ed.) **Tópicos em ciência do solo**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2000. p. 1-54.

VIEIRA, S.R.; CARVALHO, J. R. P. **Estudo de periodicidade temporal de chuvas em bacia hidrográfica dos Rios Turvo/Grande - uma proposta**. Campinas: Embrapa Informática Agropecuária, 2001. 17. (Série de documentos, 10).

YU, X.; LI, X. The Application of Sequential Indicator Simulation and Sequential Gaussian Simulation in Modeling a Case in Jilin Oilfield. **Lecture Notes in Electrical Engineering (LNEE)**, v. 173, p. 111-118, 2012.

ZHAO, Y.; SHI, X.; YU, D.; WANG, H.; SUN, W. Uncertainty assessment of spatial patterns of soil organic carbon density using sequential indicator simulation, a case study of Hebei province, China. **Chemosphere**, Kidlington, v. 59, p. 1.527–1.535, 2005.

ZHAO, Y.; XU, X.; DARILEK, J. L.; HUANG, B.; SUN, W.; SHI, X. Spatial variability assessment of soil nutrients in an intense agricultural area, a case study of Rugao County in Yangtze River Delta Region, China. **Environmental Geology**, New York, v. 57, n. 5, p. 1.089–1.102, 2009.

CAPÍTULO 2 – INCERTEZA DA DISTRIBUIÇÃO ESPACIAL DO FÓSFORO DISPONÍVEL DO SOLO EM ÁREA DE CANA-DE-AÇÚCAR

RESUMO

O teor de fósforo disponível é um dos principais fatores limitantes do desenvolvimento da cultura da cana-de-açúcar. Avaliar a incerteza das predições associada à distribuição espacial do fósforo disponível é importante para otimizar o uso dos fertilizantes fosfatados nesta cultura. Os objetivos deste estudo foram: (1) caracterizar a variabilidade e a distribuição espacial do fósforo disponível no solo; (2) avaliar o desempenho da simulação sequencial gaussiana (SSG) e da krigagem ordinária (KO) na modelagem da incerteza das predições do fósforo disponível. Uma malha amostral com 626 pontos foi instalada em uma área experimental de cana-de-açúcar no município de Tabapuã, São Paulo. Foram geradas 200 realizações por meio do algoritmo da SSG. As realizações da SSG reproduziram as estatísticas e a distribuição dos dados amostrais. O mapa de desvio-padrão, obtido por meio da KO, apresentou menor variação na área de estudo do que o obtido por meio da SSG. A estatística G (0,81) indicou boa proximidade entre as frações dos valores simulados e as dos observados. As realizações da SSG preservaram a variabilidade espacial do fósforo disponível, sem o efeito de suavização obtido pelo mapa da KO. A acurácia na reprodução do variograma dos dados amostrais, obtida pelas realizações da SSG foi, em média, 240 vezes maior que obtida por meio da KO. A avaliação das incertezas, por meio da SSG, foi mais informativa quando comparada à fornecida pela KO. A avaliação da incerteza da distribuição espacial do fósforo disponível, obtida por meio das realizações da SSG, pode ser utilizada para definir, de forma mais confiável, áreas de manejo específico.

Termos de indexação: simulação sequencial gaussiana, krigagem ordinária, geoestatística.

SUMMARY: UNCERTAINTY OF THE SPATIAL DISTRIBUTION OF SOIL AVAILABLE PHOSPHORUS IN SUGARCANE AREA

Phosphorus is a major factor limiting the development of the culture of sugarcane. To evaluate the uncertainty associated with the spatial distribution of available phosphorus is important to optimize the use of phosphate fertilizers in this

culture. The objectives of this study were characterize the spatial distribution and variability of available phosphorus in the soil; and evaluate the performance of sequential Gaussian simulation (SGS) and ordinary kriging (OK) in the modeling of the uncertainty of predictions of available phosphorus. A sample grid with 626 points was installed in an experimental area of sugarcane in Tabapuã, São Paulo. The algorithm of SGS was used to generate 200 realizations. The realizations of SGS achieved a satisfactory reproduction of the statistics and the distribution of the sample data. The map standard deviation, obtained by OK, showed less variation in the study area than that obtained by SGS. The G statistic (0.81) indicated good proximity between fractions of the simulated values and the observed. The realizations of SGS preserved the spatial variability of phosphorus without the smoothing effect of the kriged map. The accuracy in the reproduction of variogram of sample data obtained by the SGS was on average 240 times greater than obtained by OK. The uncertainty assessment of through the SGS was more informative when compared to that provided by OK. The uncertainty assessment of the spatial distribution of phosphorus, obtained through the SGS, can be used to define, more reliable, specific management areas.

Index terms: sequential Gaussian simulation; ordinary kriging, geostatistics.

INTRODUÇÃO

A cultura da cana-de-açúcar continua em expansão no Brasil, sendo o estado de São Paulo o maior produtor, com 51,82% da área total cultivada no Brasil, segundo dados da CONAB (2012). O teor de fósforo disponível é um dos principais fatores limitantes do desenvolvimento da cultura e da longevidade do canavial, além da sua aplicação exigir um grande investimento devido ao alto custo dos fertilizantes fosfatados e da necessidade de aplicação destes em grandes quantidades para manter a produtividade viável economicamente. Embora o teor de fósforo total nos solos possa apresentar altos valores, apenas uma pequena fração, denominada fósforo disponível ou lábil, está disponível para as plantas (Sampaio et al., 2011). No Brasil, mais de 90% das análises de solo mostram teores de fósforo disponível menores que 10 mg dm^{-3} , considerado um nível baixo (Faquin, 2005). A reduzida

disponibilidade de fósforo em solos brasileiros está relacionada aos baixos teores desse elemento presentes no material de origem, à baixa solubilidade dos compostos de fósforo e à sua imobilização causada pelas fortes interações, denominadas de adsorção, que o fósforo apresenta com os constituintes destes solos (Moreira et al., 2006).

Atualmente, grande parte da aplicação de fertilizantes fosfatados é efetuada levando em conta a necessidade média do nutriente em determinada área, não considerando a existência de estrutura de dependência espacial entre as distintas regiões dentro de uma área de manejo. Tais aplicações elevam o custo do processo produtivo, uma vez que regiões com pouca necessidade de fósforo recebem as mesmas taxas de aplicação que as regiões com deficiência (Marques Júnior et al., 2008).

A geoestatística é utilizada principalmente para a caracterização da variabilidade espacial dos atributos do solo (Sigua & Hudnall, 2008; Marques Júnior et al., 2008). Porém, a avaliação da incerteza, associada aos métodos de predição, tem ganhado importância nos últimos anos (Bourennane et al., 2007; Goovaerts et al., 2008; Delbari et al., 2009; Zhao et al., 2009; Sun et al., 2012). Em geoestatística, a incerteza é uma medida indicativa da magnitude do erro, uma vez que não se pode determinar com exatidão o erro de estimação do atributo, pois para isto seria necessário o conhecimento do valor real do atributo em cada posição estimada (Isaaks & Srisvastava, 1989). O conhecimento da incerteza é uma etapa importante no processo de avaliação da qualidade do interpolador utilizado e dos riscos envolvidos nos processos de tomada de decisão, particularmente no que se refere à identificação de áreas com necessidades específicas de fósforo.

Dentre os métodos geoestatísticos, a krigagem ordinária (KO) é o estimador adotado na maioria dos estudos sobre a variabilidade espacial do fósforo disponível (Sampaio et al., 2011; Camargo et al., 2013), porém a KO suaviza detalhes locais por meio da superestimação de valores pequenos e da subestimação de valores altos (Zhao et al., 2009). Além disso, a obtenção da variância da estimativa é função apenas da distribuição dos dados e das características do variograma ajustado, não levando em consideração os valores dos dados, sendo, portanto, uma medida incompleta da incerteza local (Soares, 2006).

Recentes aplicações da geoestatística têm utilizado a simulação estocástica, em particular a simulação sequencial gaussiana (SSG), como alternativa para avaliar e quantificar a incerteza das propriedades físicas e químicas do solo (Bourennane et al., 2007; Zhao et al., 2009; Delbari et al., 2009, Sun et al., 2012). Ao contrário da KO, a SSG reproduz a variabilidade espacial dos dados, o que elimina deste método a problemática do efeito de suavização. Na SSG, um conjunto de realizações é gerado, e não uma “melhor estimativa”, como no modelo da KO; deste modo, um conjunto de estimativas no local fornece uma medida quantitativa da incerteza espacial (Goovaerts, 1997).

Estas informações ressaltam a importância do mapeamento mais preciso e detalhado do fósforo disponível no solo para otimizar o uso dos fertilizantes fosfatados na cultura da cana-de-açúcar. Dessa forma, os objetivos deste estudo foram caracterizar a variabilidade e a distribuição espacial do fósforo disponível; e avaliar o desempenho da SSG e da KO na modelagem da incerteza das previsões do fósforo disponível.

MATERIAL E MÉTODOS

Área de estudo e conjunto de dados

A área de estudo está localizada nas coordenadas geográficas 21°05'57,11" de latitude Sul e 49°01'02,08" de longitude Oeste, com altitude média de 500 m, no município de Tabapuã, no noroeste do Estado de São Paulo, Brasil (Figura 2.1). O clima da região, segundo a classificação de Köppen, é do tipo mesotérmico com inverno seco (Cwa), com precipitação pluvial média anual de 1.200 mm e chuvas concentradas no período de novembro a fevereiro. O solo foi classificado como Argissolo Vermelho-Amarelo eutrófico textura média/argilosa de acordo com o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2006). A área, de 200 hectares, apresenta um histórico de mais de 20 anos de cultivo de cana-de-açúcar com sistema de colheita queimada.




Figura 2.1. Localização da área experimental e mapa de distribuição dos pontos amostrais.




Figura 2.2. Mapa de distribuição dos teores de fósforo disponível medidos.

O solo foi amostrado nos pontos de cruzamento de uma malha, com intervalos regulares de 50 m, perfazendo um total de 626 pontos. Destas observações, 63 pontos (conjunto validação), cerca de 10% do total de pontos amostrados (Bourennane et al., 2007), foram sorteados aleatoriamente antes do início da modelagem geoestatística para a composição de um conjunto de dados utilizados no processo de validação da modelagem; os 563 pontos restantes (conjunto interpolação) foram utilizados para as predições da variável em local não amostrado (Figura 2.1).

As amostras foram coletadas nas profundidades de 0,00-0,20 m, e o fósforo disponível foi extraído utilizando o método da resina trocadora de íons, proposta por Raij et al. (2001). A Figura 2.2 ilustra a distribuição dos teores de fósforo disponível medidos na área de estudo. Esse banco de dados, juntamente com as metodologias

de coleta, análise e classificação dos dados são originários de pesquisas realizadas por Sanchez et al. (2009).

Estatística descritiva e variabilidade espacial

Inicialmente, foi feita a estatística descritiva dos valores observados de fósforo disponível (média, desvio-padrão, mínimo, máximo, coeficiente de variação, assimetria e curtose), com objetivo de obter informações para identificar tendência, dispersão e forma de distribuição dos dados (Bourgault et al., 1997). O software R foi utilizado para as avaliações da estatística descritiva (R Development Core Team, 2010). A dependência espacial das amostras de fósforo disponível foi caracterizada por meio do variograma (Soares, 2006). Os ajustes dos variogramas experimentais foram feitos com base na menor soma de quadrado dos resíduos (SQR), no maior coeficiente de determinação (R^2) e, nos parâmetros linear e angular da validação cruzada (Isaaks & Srivastava, 1989).

Krigagem Ordinária

Na estimativa da krigagem ordinária (KO), a dependência espacial dos dados amostrais de fósforo disponível foi quantificada por meio do variograma. O valor de fósforo disponível em um local não amostrado x_0 foi estimado usando o estimador $\hat{z}(x_0)$, definido como:

$$\hat{z}(x_0) = \sum_{i=1}^N \lambda_i z(x_i), \text{ com } \sum_{i=1}^N \lambda_i = 1, \quad (2.1)$$

em que, $\hat{z}(x_0)$ é o valor estimado de fósforo disponível no ponto 0; N é o número de valores utilizados na estimação; λ é o peso associado a cada valor observado, e $z(x_i)$ é o valor observado de fósforo disponível no ponto i (Soares, 2006).

A variância da KO (σ^2), no local não amostrado (x_0), foi calculada por:

$$\sigma^2(x_0) = \sum_{i=1}^N \lambda_i \gamma(x_0, x_i) + \mu, \quad (2.2)$$

em que, $\gamma(x_0, x_i)$ é a semivariância entre o local a ser estimado x_0 e o i -ésimo ponto amostrado, e μ é o parâmetro de Lagrange utilizado para minimizar a variância da krigagem (Soares, 2006).

Simulação sequencial gaussiana

Atendendo ao pré-requisito do procedimento da simulação sequencial gaussiana (SSG), os dados de fósforo disponível foram transformados para uma distribuição normal padronizada (com média igual a 0 e variância igual a 1). A normalidade desta transformação foi verificada e confirmada por meio do teste de normalidade Shapiro-Wilk ($p > 0,05$).

O procedimento da SSG consiste em refinar a malha amostral e definir um caminho aleatório de forma que cada ponto a ser simulado seja visitado apenas uma vez. Para cada ponto a ser simulado é determinada a função de distribuição condicional (fdac) gaussiana, por meio do estimador da krigagem simples, utilizando o variograma dos dados normalizados. Posteriormente é sorteado um valor normal padronizado, a partir da fdac, e adicionado ao conjunto de dados condicionais, que consiste nos pontos observados e nos previamente simulados, dentro da vizinhança do ponto a ser simulado. Este procedimento é repetido até que todos os pontos sejam simulados. Por fim, os dados normalizados são transformados para a escala original dos dados observados. Para gerar múltiplas realizações, essa sequência deve ser repetida com diferentes caminhos aleatórios para cada realização (Goovaerts, 1997).

A partir das realizações geradas, foram obtidas diferentes medidas de estimativa e de incerteza. A média, calculada ponto a ponto, de todos os mapas simulados forneceu uma estimativa denominada E-type (Deutsch & Journel, 1998). Da mesma forma, o desvio-padrão, calculado ponto a ponto, de todos os mapas simulados forneceu o mapa de desvio, utilizado para avaliar a incerteza local (Bourennane et al., 2007).

Neste trabalho, foram geradas 200 realizações utilizando o software WinGslib (Deutsch & Journel, 1998). Para representar o conjunto das 200 realizações geradas

e verificar a reprodução dos valores observados do fósforo disponível pelas realizações, foram sorteadas, aleatoriamente, as realizações 11; 60; 94 e 143.

Reprodução dos dados amostrais

A reprodução dos dados amostrais, pelos modelos de simulação e estimação, foi verificada por meio das estatísticas descritivas, dos histogramas e da função de distribuição acumulada condicional (fdac). O gráfico quantil-quantil (Q-Q) foi usado para examinar os histogramas dos modelos de predição o qual permitiu comparar os quantis da distribuição dos dados amostrais versus a distribuição dos dados simulados, fornecidos pelas 200 realizações da SSG, e os fornecidos pela estimativa KO.

Avaliação da incerteza

Como medida de incerteza local, foi utilizado o procedimento que quantificou o número de locais simulados em que a concentração de fósforo disponível $z(x_0)$, em um local x_0 , não excedeu pontualmente um limite crítico (z_c) e converte a soma em uma proporção por meio da equação (Zhao et al., 2009; Delbari et al., 2009):

$$Prob[z(x_0) \leq z_c] = \frac{n(x_0)}{L}, \quad (2.3)$$

em que, $z(x_0)$ é o valor da variável z no local x_0 ; z_c é o limite crítico adotado; $n(x_0)$ é o número de realizações em que a variável apresenta valor menor ou igual a z_c , e L é o número total de realizações geradas, neste estudo $L=200$. Foi utilizado o limite $z_c = 6 \text{ mg dm}^{-3}$, o qual é considerado muito baixo para solos cultivados com cana-de-açúcar (Raij et al., 1996).

Após a quantificação da incerteza local do fósforo disponível, a incerteza espacial foi avaliada com base no cálculo da probabilidade conjunta (Zhao et al., 2009; Delbari et al., 2009). Uma área A com deficiência em fósforo disponível foi obtida usando a regra $Prob[z(x_0) \leq Pc] \geq z_c$; em que foi considerada uma

probabilidade crítica $P_c = 0,8$ e o limite para o fósforo disponível $z_c = 6 \text{ mg dm}^{-3}$. A probabilidade conjunta de K locais x_{0k} ($k=1, \dots, K$), na área A , ter o teor de fósforo disponível menor ou igual ao limite z_c , foi calculada com base na seguinte equação:

$$Prob[z(x_{01}) \leq z_c, z(x_{02}) \leq z_c, \dots, z(x_{0k}) \leq z_c] = \frac{n(x_{01}, x_{02}, \dots, x_{0k})}{L} \quad (2.4)$$

em que, $n(x_{01}, x_{02}, \dots, x_{0k})$ é o número de realizações em que todos os valores simulados de fósforo disponível nos K locais $x_{01}, x_{02}, \dots, x_{0k}$ foram conjuntamente menores ou iguais a z_c , e L é o número de realizações geradas. Considerou-se que valores de probabilidade conjunta próximas à unidade estão relacionados a menores incertezas espaciais.

A metodologia, proposta por Deutsch (1997), foi utilizada para examinar a acurácia em reproduzir a fdac dos dados amostrais pelo conjunto de realizações da SSG. Esta consistiu em verificar as proporções de valores dos dados do conjunto de validação que pertencem a intervalos de probabilidade (IP) - p simétricos, calculados a partir da fdac $F(u, z|(n))$. Em qualquer localização u , o conhecimento da fdac, permite calcular uma série de IP - p simétricos limitados pelos quantis da fdac $(1-p)/2$ e $(1+p)/2$. Considerando os dados de validação, $F(u_j, z|(n))$, $j = 1, \dots, N_v = 63$, as frações de valores verdadeiros que pertencem a cada IP- p simétrico, foram obtidas por:

$$\bar{\xi}_{(p)} = \frac{1}{N} \sum_{j=1}^{N_v} \xi(u_j, p) \quad \forall p \in [0,1] \quad (2.5)$$

$$\text{com, } \xi(u_j, p) = \begin{cases} 1 & \text{se } \hat{F}^{-1}(u_j, (1-p)/2) < z(u_j) \leq \hat{F}^{-1}(u_j, (1+p)/2) \\ 0 & \text{caso contrário} \end{cases}$$

O algoritmo de simulação usado para gerar as fdacs é considerado acurado quando $\bar{\xi}(p) \geq p, \forall p$. O gráfico de dispersão, denominado gráfico de acurácia (Deutsch, 1997), foi gerado a partir das frações calculadas versus o conjunto de probabilidades p . A estatística G , também proposta por Deutsch (1997), foi utilizada

para mensurar, no gráfico de acurácia, o afastamento dos pontos em relação à reta 1:1, sendo numericamente calculada pela equação:

$$G = 1 - \int_0^1 [3a(p) - 2][\bar{\xi}(p) - p]dp, \quad (2.6)$$

em que $a(p)$ é igual a 1, se $\bar{\xi}(p) \geq p$, e igual a 0 em caso contrário.

Considerou-se que valores de G iguais à unidade indicam máxima eficiência no ajuste do modelo, ou seja, $\bar{\xi}(p) = p, \forall p \in [0,1]$.

A acurácia na reprodução do variograma pelos métodos de predição SSG e KO foi avaliada por meio da equação, proposta por Goovaerts (2000):

$$\varepsilon_\gamma = \sum_{s=1}^S \frac{[\gamma(h_s) - \hat{\gamma}(h_s)]^2}{[\gamma(h_s)]^2}, \quad (2.7)$$

em que, S é o número de intervalos (lags) de distância h utilizados para a construção do variograma; $\gamma(h_s)$ é a semivariância na distância h_s calculada a partir dos valores observados, e $\hat{\gamma}(h_s)$ é a semivariância na distância h_s calculada a partir dos valores simulados. Assumiu-se que valores de ε_γ próximos a zero indicam uma boa acurácia na reprodução do variograma dos dados observados (Herbst et al., 2010).

RESULTADOS E DISCUSSÃO

Estatística descritiva e variabilidade espacial

As estatísticas descritivas do conjunto validação foram próximas às do conjunto interpolação (Quadro 2.1), não havendo diferença significativa entre os dois conjuntos de dados, de acordo com o teste de significância “t-student” ($p > 0,05$). A média dos valores observados de fósforo apresentou nível médio para a cultura (Raij et al., 1996), semelhante aos relatados em trabalhos realizados em solos sob o

cultivo da cana-de-açúcar (Marques Júnior et al., 2008; Carmargo et al., 2013). O coeficiente de variação (CV) de 93,65% para os dados amostrais do fósforo disponível indicou alta variabilidade de acordo com a classificação de Warrick & Nielsen (1980). Silva et al. (2008) também encontraram alto valor de CV para o fósforo disponível em Argissolo Vermelho-Amarelo cultivado com café. Esta alta variabilidade indica que se a aplicação de fertilizantes for feita considerando apenas a média dos teores de fósforo, a dose recomendada será adequada em alguns locais, porém em outros será subdimensionada ou superdimensionada. A grande amplitude de variação dos teores de fósforo disponível pode está relacionada: (1) ao manejo da aplicação do adubo, geralmente feita no sulco; (2) a pouca mobilidade do fósforo o que pode causar acúmulo deste nutriente, justificando os valores mais altos, bem como o fenômeno de adsorção, justificando os valores mais baixos (Barbieri et al., 2009; Camargo et al. 2013). Portanto, estes aspectos contribuíram para uma distribuição irregular do nutriente no solo.

As estatísticas referentes às quatro realizações individuais sorteadas da SSG (Quadro 2.1) apresentam valores de CV e desvio-padrão (DP) próximos aos dados observados (conjunto interpolação), confirmando que as estatísticas dos dados originais foram mantidas pelo processo de simulação. Os valores mínimos (Mín.) e máximos (Máx.) produzidos pelas realizações foram os mesmos dos dados originais. No procedimento da KO, as estatísticas dos dados originais não foram mantidas, sendo o valor mínimo superestimado, e o valor máximo, subestimado, revelando o efeito de suavização típico da KO. Esse mesmo cenário também foi encontrado em outros trabalhos que utilizaram a KO e a SSG para a predição de atributos do solo (Bourenanne et al., 2007; Delbari et al., 2009). A média, o DP e o CV da E-type apresentaram valores próximos aos da KO, demonstrando que o número de realizações adotado foi adequado, porém, diferentemente da KO, a E-type preservou a variação (Mín. e Máx.) do conjunto interpolação.

A caracterização da estrutura da variabilidade espacial foi determinada com o ajuste de modelos teóricos aos variogramas experimentais (Figura 2.3a, b). Utilizou-se a transformação logarítmica nos dados de fósforo disponível, visando à correção da assimetria da distribuição (Quadro 2.1). A transformação logarítmica é recomendada para conjuntos de valores com assimetria positiva maior que a

unidade (Webster & Oliver, 2009). A transformação normal dos dados originais do fósforo disponível foi realizada para atender a um pré-requisito da SSG.

Quadro 2.1. Estatística descritiva do fósforo disponível (conjunto interpolação, conjunto validação, KO, E-type e realizações sorteadas da SSG).

P (mg dm ⁻³)	N	Média	DP	CV	Mín.	Máx.	Ass.	Curt.
* Conjunto interpolação	563	20,01	18,74	93,65	1,00	86,00	1,48	1,68
** Conjunto validação	63	20,15	20,65	102,46	2,00	74,00	1,34	0,55
KO	8.640	20,36	9,620	47,27	4,58	51,29	0,63	-0,23
E-type	8.640	19,31	9,420	48,82	1,00	86,00	1,41	5,77
Realização 11	8.640	19,22	18,45	95,97	1,00	86,00	1,54	1,89
Realização 60	8.640	18,34	17,53	95,59	1,00	86,00	1,61	2,28
Realização 94	8.640	18,75	17,82	95,06	1,00	86,00	1,59	2,12
Realização 143	8.640	18,00	17,27	95,87	1,00	86,00	1,66	2,53

N=número de observações; P=fósforo disponível; DP=desvio-padrão; CV=coeficiente de variação (%); Mín=mínimo; Máx=máximo; Ass.=coeficiente de assimetria; Curt.=coeficiente de curtose; *dados utilizados para gerar as realizações e a krigagem ordinária; **dados utilizados na validação externa.




Figura 2.3. Variogramas do fósforo disponível: modelo experimental (•) e modelo teórico (—) do conjunto interpolação com transformação logarítmica (a) e com transformação normal (b).

O modelo teórico esférico apresentou os melhores ajustes, tanto para valores de fósforo disponível com transformação logarítmica, quanto para os com transformação normal (Quadro 2.2 e Figura 2.3a, b), sendo este modelo também utilizado em outros trabalhos para descrever a variabilidade espacial do fósforo disponível do solo (Marques Júnior et al., 2008; Sampaio et al., 2011). Este modelo é

característico de variáveis com mudanças abruptas em grandes distâncias, sendo usado para descrever fenômenos relativamente irregulares (Soares, 2006), tais como os atributos do solo (Cambardella et al., 1994).

O grau de dependência espacial (GDE) do fósforo disponível foi classificado como moderado para os dados com transformação normal e com transformação logarítmica (Quadro 2.2) de acordo com a classificação de Cambardella et al. (1994). Os modelos ajustados aos variogramas (Figura 2.3a, b), utilizados no processo de SSG e KO, respectivamente, apresentam valores de alcances iguais (349,04 m), demonstrando que a estrutura espacial se manteve, mesmo após a transformação normal (Quadro 2.2).

Quadro 2.2. Tipo de transformação empregada nos dados e parâmetros dos modelos ajustados aos variogramas experimentais do fósforo disponível.

Transf.	Modelo	C ₀	C ₀ +C ₁	A	GDE	SQR	R ²	Validação cruzada	
								a	b
Log	Esférico	0,51	0,88	349,04	0,57	3,43E-03	0,97	0,82	3,37
Normal	Esférico	0,60	0,99	349,04	0,61	5,86E-02	0,96	0,00	1,03

N=563; Transf=transformação da distribuição dos dados; Normal=transformação normal padronizada; Log=transformação logarítmica; C₀=efeito pepita; C₀+C₁=patamar; A=alcance; C₁=variância estrutural; GDE=grau de dependência espacial (C₀/(C₀+C₁)); SQR=soma de quadrado dos resíduos; R²=coeficiente de determinação; a=coeficiente linear; b=coeficiente angular.

As realizações individuais da SSG (Figura 2.4) apresentaram padrões espaciais semelhantes nas áreas com baixos teores de fósforo disponível, evidenciando maior continuidade espacial. No entanto, áreas com teores elevados de fósforo disponível (regiões demarcadas por retângulos) exibiram distintos padrões espaciais nas quatro realizações selecionadas, evidenciando, assim menor continuidade espacial.

A análise visual dos mapas das estimativas E-type e KO (Figura 2.4) demonstrou que os padrões espaciais produzidos por ambos os métodos foram semelhantes, no entanto foi possível observar o efeito característico da suavização da KO, principalmente nas regiões com valores extremos. A semelhança entre as duas estimativas também pôde ser observada numericamente na estatística descritiva para a média, DP e CV (Quadro 2.1). Esses resultados foram esperados,

uma vez que, quando há um grande número de realizações, a média das realizações da SSG converge para os resultados da KO (Chilès & Delfiner, 1999).




Figura 2.4. Mapas estimados do fósforo disponível: realizações sorteadas da SSG (11; 60; 94 e 143), média das realizações (E-type) e KO.

Reprodução dos dados amostrais

As fdacs das quatro realizações sorteadas reproduziram satisfatoriamente o histograma dos dados observados (Figura 2.5a). As fdacs da KO e da E-type apresentaram formas semelhantes entre si, porém não reproduziram a distribuição dos dados amostrais. Uma boa reprodução da fdac dos dados originais pela SSG também foi encontrada por Delbari et al. (2009). No gráfico Q-Q (Figura 2.5b), foi observada uma boa distribuição dos quantis entre os histogramas dos dados amostrais e dos dados simulados de fósforo disponível obtidos por meio da SSG. No entanto, no gráfico Q-Q (Figura 2.5c), nas partes circuladas, foram observadas a superestimação dos valores baixos e a subestimação dos valores altos de fósforo disponível, evidenciando o efeito de suavização da KO.




Figura 2.5. Funções densidade acumulada condicional do fósforo disponível (a); gráfico Q-Q do fósforo disponível: conjunto interpolação vs SSG (b) e conjunto interpolação vs KO (c).

Avaliação da incerteza

Os altos teores simulados de fósforo disponível (Figura 2.4) foram associados aos maiores desvios estimados a partir das 200 realizações (Figura 2.6a). Desta forma, pode-se afirmar que áreas com altos teores amostrados apresentaram alta incerteza local e, portanto, requerem um maior refinamento amostral. Como a SSG é um método condicional, os valores de desvio-padrão nos locais amostrados foram iguais a zero (Figura 2.6a), uma vez que nenhuma estimativa é produzida por meio da SSG nestes locais (Delbari et al., 2009; Zhao et al., 2009).




Figura 2.6. Mapas de desvio-padrão para os teores de fósforo disponível gerados a partir da SSG (a) e da KO (b).

O mapa de desvio associado à estimação da KO na área estudada (Figura 2.6b) apresentou menor variação que o mapa dos desvios das realizações. Isto confirma que a variância da KO e, por consequência, seus desvios independem do valor real da amostra, levando em consideração apenas o variograma teórico ajustado e a configuração amostral avaliada (Goovaerts, 1997). Assim, esta menor incerteza forneceu uma estimativa menos conservadora da distribuição espacial do fósforo disponível, não podendo ser utilizada como uma medida confiável da incerteza local.

As áreas delimitadas pelos retângulos (Figura 2.7) apresentaram alta probabilidade ($P > 0,75$) de deficiência de fósforo disponível ($\leq 6 \text{ mg dm}^{-3}$). Nota-se que estas foram as mesmas áreas com os menores valores de fósforo disponível amostrados (Figura 2.2). No entanto, a delimitação de áreas com deficiência de fósforo disponível, identificadas somente por meio deste mapa, é inadequada, uma vez que as fdacs obtidas pela SSG apenas forneceram uma medida da incerteza local (em um único ponto) e a série de fdacs de um único ponto não provê uma medida de incerteza espacial (em vários pontos) (Zhao et al., 2009).




Figura 2.7. Mapa de probabilidade de o teor de fósforo disponível não exceder a 6 mg dm^{-3} .

A probabilidade conjunta (equação 2.4), obtida por meio das realizações produzidas pela SSG, foi utilizada na avaliação da incerteza espacial. Com uma probabilidade crítica de 0,8, a probabilidade conjunta foi de 0,006 para 204 locais simulados na área. Em apenas 0,6% das 200 simulações, 204 locais simulados na área apresentaram valores de fósforo disponível menores ou iguais a 6 mg dm^{-3} . A

probabilidade conjunta indicou uma alta incerteza espacial, apesar de a probabilidade, nas áreas delimitadas pelos retângulos (Figura 2.7), ter sido alta. Zhao et al. (2009), utilizando o cálculo da probabilidade conjunta, avaliaram a incerteza espacial de nutrientes no solo, encontrando alta incerteza espacial para o fósforo disponível (0,12), para a probabilidade crítica de 0,90. Assim, pode-se inferir que não é confiável assumir as áreas no mapa da Figura 2.7 como deficientes em fósforo (com teores menores ou iguais a 6 mg dm^{-3}).

O gráfico de acurácia (Figura 2.8) para a SSG foi calculado a partir das 200 realizações e dos 63 pontos do conjunto validação, de acordo com a equação 5. O gráfico mostra que todos os pontos se localiza abaixo da reta 1:1, indicando que o modelo probabilístico da SSG para o fósforo disponível foi pouco acurado. No entanto, o valor da estatística G (0,81), próximo à unidade, indica boa proximidade entre as frações dos valores simulados e as do conjunto validação. Valores de G entre 0,80 e 0,96 foram encontrados por Goovaerts et al. (2008) e Bourennane et al. (2007) ao avaliarem a acurácia da modelagem de atributos do solo utilizando a SSG.




Figura 2.8. Gráfico de acurácia e estatística G para a SSG do fósforo disponível.

Os variogramas padronizados das realizações sorteadas da SSG apresentaram modelo e alcance semelhantes aos do variograma dos dados observados de fósforo disponível (Figura 2.9a). A KO, por sua vez, apresentou estrutura variográfica distinta dos dados observados (Figura 2.9b). Este mesmo

cenário foi encontrado por Delbari et al. (2009), analisando a reprodução do variograma dos dados amostrais pela SSG e KO. Este resultado é mais uma implicação que pode ser atribuída ao efeito de suavização da estimativa da KO, uma vez que houve uma subestimação da variabilidade em pequenas distâncias e um ajuste do variograma ao modelo gaussiano, que é característico de variáveis com distribuição suave no espaço (Figura 2.9a).

As estatísticas ε_γ das realizações sorteadas (Figura 2.9a) demonstraram, numericamente, que as realizações geradas pela SSG preservaram os padrões de variabilidade dos dados amostrais, pois apresentaram baixos valores, variando entre 0,01 e 0,04, sendo estes, em média, 240 vezes menores que o valor de 6,07 para o ε_γ obtido a partir da KO (Figura 2.9b). As flutuações dos valores de ε_γ entre as realizações da SSG, chamadas de ergóticas, foram encontradas em outros trabalhos que analisaram a reprodução dos variogramas dos dados amostrais pelos algoritmos de simulações (Delbari et al., 2009, Herbst et al., 2010).




Figura 2.9. Variogramas padronizados do fósforo disponível e erro na reprodução do variograma (ε_γ): realizações sorteadas e conjunto interpolação (a); KO e conjunto interpolação (b).

CONCLUSÕES

1. O desempenho do método da simulação sequencial gaussiana (SSG) forneceu mais informações quantitativas e visuais na avaliação das incertezas da distribuição de fósforo disponível quando comparado à krigagem ordinária (KO).

2. As diferentes realizações da SSG possibilitaram a avaliação da incerteza distribuição espacial do fósforo disponível que pode ser utilizada para definir, de forma mais confiável, áreas de manejo específico.

LITERATURA CITADA

BOURENNANE, H.; KING, D.; COUTURIER, A.; NICOULLAUD, B.; MARY, B. & RICHARD, G. Uncertainty assessment of soil water content spatial patterns using geostatistical simulations: An empirical comparison of a simulation accounting for single attribute and a simulation accounting for secondary information. *Ecol. Model.*, Amsterdam, 205:323-335, 2007.

BOURGAULT, G.; JOURNEL, A.G.; RHOADES, J.D.; CORWIN, D.L. & LESCHG, S. M. Geostatistical analysis of a soil salinity data set. *Adv. Agron.*, Maryland Heights, 58: 241-292, 1997.

CAMARGO L. A.; MARQUES JÚNIOR J.; PEREIRA G. T. & ALLEONI L. R. F. Spatial correlation between the composition of the clay fraction and contents of available phosphorus of an Oxisol at hillslope scale. *Catena*, Amsterdam, 100:100–106, 2013.

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. Sci. Soc. Am. J.*, Madison, 58:1.501-1.511, 1994.

CHILÈS, J.P. & DELFINER, P. *Geostatistics: Modelling spatial Uncertainty*. Wiley, New York, 695 p., 1999.

CONAB– Companhia Nacional de Abastecimento. Acompanhamento de safra brasileira: cana-de-açúcar, Segundo Levantamento Agosto/2012. Disponível em: http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12_09_05_09_11_59_boletim_cana_portugues_-_agosto_2012_2o_lev.pdf. Acesso em 10 out. 2012.

DELBARI, M.; AFRASIAB, P. & LOISKANDL, W. Using sequential Gaussian simulation to assess the field-scale spatial uncertainty of soil water content. *Catena*, Amsterdam, 79: 163-169, 2009.

DEUTSCH, C. Direct assessment of local accuracy and precision. In: BAAFI, E. Y. & SCHOFIELD, N. A. (Eds.), *Geostatistics Wollongong '96*. Dordrecht, Kluwer Academic Publishing, 1997. p. 115–125.

DEUTSCH, C. V. & JOURNEL, A. G. *GSLIB: Geostatistical software Library and User's Guide*. New York, Oxford University Press, 1998. 369 p.

EMBRAPA- Empresa Brasileira de Pesquisa Agropecuária, Centro Nacional de Pesquisa de Solos. Sistema Brasileiro de Classificação de Solos. Rio de Janeiro, 2006. 306 p.

FAQUIN, V. Nutrição Mineral de Plantas. Lavras: UFLA – FAEPE, 2005. 183 p.

GOOVAERTS, P. Estimation or simulation of soil properties? An optimization problem with conflicting criteria. *Geoderma*, Amsterdam, 97:165-186, 2000.

GOOVAERTS, P. Geostatistics for natural resources evaluation. New York: Oxford University Press, 1997, 483p.

GOOVAERTS, P.; TRINH, H. T.; DEMOND, A. H.; TOWEY, T.; CHANG, SHU-CHI; GWINN, D.; HONG, B.; FRANZBLAU, A.; GARABRANT, D.; GILLESPIE, B. W.; LEPKOWSKI, J. & ADRIAENS, P. Geostatistical Modeling of the Spatial Distribution of Soil Dioxin in the Vicinity of an Incinerator. 2. Verification and Calibration Study. *Environ. Sci. Technol.*, Dordrecht, 42:3.655-3.661, 2008.

HERBST, M.; PROLINGHEUER, N.; GRAF, A.; HUISMAN, J. A.; WEIHERMÜLLER, L.; VANDERBORGHT, J. & VEREECKEN, H. Multivariate conditional stochastic simulation of soil heterotrophic respiration at plot scale. *Geoderma*, Amsterdam, 160: 74–82, 2010.

ISAAKS, E. H. & SRIVASTAVA, R. M. A introduction to applied geostatistics. Oxford University Press, 1989. 592 p.

MARQUES JÚNIOR, J.; SOUZA, Z. M. de; PEREIRA, G. T. & BARBIERI, D. M. Variabilidade espacial de matéria orgânica, P, K e CTC de um latossolo cultivado com cana-de-açúcar por longo período. *Revista de Biologia e Ciências da Terra*, Campina Grande, 8:143-152, 2008.

MOREIRA, F. L. M.; MOTA, F. O. B.; CLEMENTE, C. A.; AZEVEDO, B. M. & BOMFIM, G. V. Adsorção de fósforo em solos do Estado do Ceará. *Rev. Ciênc. Agron.*, Fortaleza, 37:7-12, 2006.

R DEVELOPMENT CORE TEAM (2010). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, ISBN 3-900051-07-0. Disponível em: URL <http://www.R-project.org>. Acesso em: set. 2012.
RAIJ, B. van; CANTARELLA, H.; QUAGGIO, J. A. & FURLANI, A. M. C. (Ed.). Recomendações de adubação e calagem para o Estado de São Paulo. 2.ed. Campinas: IAC, 1996. 285 p.

RAIJ, B. van; ANDRADE, J. C.; CANTARELLA, H. & QUAGGIO, J. A. (eds.). Análise química para avaliação da fertilidade de solos tropicais. Campinas: Instituto Agrônomo, 2001. 285 p.

SAMPAIO, M. da S. Avaliação do comportamento da variabilidade espacial do fósforo remanescente no solo de lavoura cafeeira. In: XV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Anais. Curitiba, INPE, 2011, p. 9.203-9.210.

SANCHEZ, R. B.; MARQUES JÚNIOR, J.; SOUZA, Z. M.; PEREIRA, G. T. & MARTINS FILHO, M. V. Variabilidade espacial de atributos do solo e de fatores de erosão em diferentes pedoformas. *Bragantia*, Campinas, 68:1.095-1.103, 2009.

SIGUA, G. & HUDNALL, W. Kriging analysis of soil properties. *J. Soil Sediment*, Heidelberg, 8: 193-202, 2008.

SILVA, F. M. da; SOUZA, Z. M. de; FIGUEIREDO, C. A. P. de; VIEIRA, L. H. de. & OLIVEIRA, E. de. Variabilidade espacial de atributos químicos e produtividade da cultura do café em duas safras agrícolas. *Ciênc. agrotec.*, Lavras, 32:231-241, 2008.

SOARES, A. Geoestatística para ciências da terra e do ambiente. 2. ed. Lisboa: IST Press, 2006, 214 p.

SUN, X. ; WU, S.; WANG, H.; ZHAO, Y.; ZHAO, Y.; ZHANG, G.; MAN, Y. B. & WONG, M. H. Uncertainty Analysis for the Evaluation of Agricultural Soil Quality Based on Digital Soil Maps. *Soil Sci. Soc. Am. J.*, Madson, 76: 1379–1389, 2012.

WARRICK, A.W. & NIELSEN, D.R. Spatial variability of soil physical properties in the field. In: HILLEL, D., ed. *Applications of soil physics*. New York, Academic, 1980. p. 319-344.

WEBSTER, R. & OLIVER, M. A. *Geostatistics for Environmental Scientists*. Second Edition, Oxford, Oxford University Press, 2009. 315 p.

ZHAO, Y.; XU, X.; DARILEK, J.; HUANG, B.; SUN, W. & SHI, X. Spatial variability assessment of soil nutrients in an intense agricultural area, a case study of Rugao County in Yangtze River Delta Region, China. *Environ. Geol.*, Heidelberg, 57:1.089-1.102, Berlin, 2009.

CAPÍTULO 3 – MODELAGEM DA INCERTEZA DO POTÁSSIO DISPONÍVEL DO SOLO POR SIMULAÇÕES ESTOCÁSTICAS

RESUMO

O potássio (K) é o nutriente mais absorvido pela cultura da cana-de-açúcar. Avaliar a incerteza das predições associada à distribuição espacial do K é importante para otimizar o uso dos fertilizantes potássicos. Como alternativa para suprir a deficiência da krigagem ordinária (KO) em avaliar a incerteza, a simulação sequencial gaussiana (SSG) e a simulação sequencial indicatriz (SSI) são usadas para modelar a incerteza das propriedades do solo. Os objetivos deste estudo foram: (1) caracterizar a variabilidade e a distribuição espacial do K disponível; (2) avaliar o desempenho das simulações SSG e SSI na modelagem da incerteza das predições do K, comparando com o método já consagrado da KO. Uma malha amostral com 626 pontos foi instalada em uma área experimental de cana-de-açúcar, no município de Tabapuã, São Paulo. Foram geradas 200 realizações por meio dos algoritmos da SSG e SSI. As simulações estocásticas mantiveram a variabilidade dos dados amostrais de K, enquanto a KO promoveu superestimativa e subestimativa dos baixos e altos valores, respectivamente. As realizações individuais de ambos os métodos de simulação mostraram maior variabilidade para os teores altos e intermediários de K. O mapa de desvio-padrão obtido a partir da KO apresentou menor variação ao longo da área de estudo quando comparado aos mapas de desvio-padrão obtidos a partir das simulações da SSG e SSI. Em relação à SSG, a SSI obteve acurácia 13% superior para modelar a função de distribuição condicional do K. Os mapas simulados por meio da SSG e da SSI representaram a distribuição espacial do K disponível no solo de forma mais realista do que o mapa de estimação fornecido pela KO. Os desempenhos das técnicas SSG e SSI mostraram-se mais eficientes para modelar a incerteza da distribuição espacial do K disponível do que a técnica KO.

Termos de indexação: simulação sequencial gaussiana; simulação sequencial indicatriz; krigagem; cana-de-açúcar.

SUMMARY: MODELING OF UNCERTAINTY OF SOIL POTASSIUM AVAILABLE FOR STOCHASTIC SIMULATIONS

Potassium (K) is the most nutrient absorbed by the culture of sugar cane. To assess the uncertainty of predictions associated with the spatial distribution of K is important to optimize the use of potash fertilizers. As an alternative to supply the deficiency of ordinary kriging (OK) to assess uncertainty, sequential simulation gaussiana (SGS) and sequential indicator simulation (SIS) are being used to model the uncertainty of soil properties. The objectives of this study were: (1) characterize the variability and spatial distribution of available K, (2) evaluate the performance of the SGS and SSI simulations in uncertainty modeling of predictions of K compared with the already established method OK. A sample grid with 626 points was installed in an sugarcane experimental area in Tabapuã, São Paulo. Were generated 200 realizations by means of algorithms SGS and SIS. The stochastic simulations maintained the variability of the sample data of K, while OK promoted the overestimation and underestimation the low and high values, respectively. The Individual realizations of both simulation methods showed greater variability for the high and intermediate levels of K. The map of standard deviation obtained from the OK showed less variation along the study area compared to maps of standard deviation obtained from the SGS and SSI simulations. Regarding SGS, SIS obtained a accuracy 13% higher for modeling the conditional distribution function of the K. The simulated maps obtained by means SGS and SIS represented the spatial distribution of available K more realistically than the kriged map. The techniques SSG and SSI showed more efficient to model the uncertainty of the spatial distribution of K than the technique KO.

Index terms: sequential Gaussian simulation; sequential indicator simulation; ordinary kriging; sugarcane.

INTRODUÇÃO

O Estado de São Paulo é o maior produtor de cana-de-açúcar, com 51,82% da área total cultivada no Brasil, segundo dados da CONAB (2012). O potássio (K) é o nutriente mais absorvido pela cultura (Malavolta, 1994). A cana-de-açúcar

consome aproximadamente 13% do total de fertilizantes utilizados anualmente no Brasil, (ANDA, 2008; Otto et al., 2010). Do total de fertilizante potássico utilizado no Brasil, 90% é importado (Kinpara, 2003). Os solos tropicais brasileiros apresentam baixos teores de potássio na forma disponível ou solúvel, isto é, em forma assimilável pelas plantas (Ernani et al., 2007; Benites et al., 2010); e a cana-de-açúcar responde bem à aplicação do fertilizante potássico (Korndörfer & Oliveira, 2005). O estudo da variabilidade espacial do K é uma forma de subsidiar informações que possibilitem o manejo adequado deste nutriente e assim reduzir os custos de produção, aumentar a produtividade das culturas, diminuindo os problemas ambientais gerados pela aplicação inadequada de fertilizantes (Sanchez et al., 2012).

A geoestatística é a principal ferramenta utilizada para a caracterização da variabilidade espacial e a estimação de atributos do solo (Sigua & Hudnall, 2008; Marques Júnior et al., 2008). Os métodos tradicionais geoestatísticos, como a krigagem, não fornecem informações suficientes para quantificar as incertezas. Porém, a avaliação da incerteza, associada aos métodos de predição, tem ganhado importância nos últimos anos (Bourennane et al., 2007; Goovaerts et al., 2008; Delbari et al., 2009; Zhao et al., 2009; Sun et al., 2012; Teixeira et al., 2012). Na geoestatística, a incerteza é uma medida indicativa da magnitude do erro, uma vez que não se pode determinar com exatidão o erro de estimação do atributo, pois para isto seria necessário o conhecimento do valor real do atributo em cada posição estimada (Isaaks & Srisvastava, 1989). O conhecimento da incerteza é uma etapa importante no processo de avaliação da qualidade do interpolador utilizado e dos riscos envolvidos nos processos de tomada de decisão.

Dentre os métodos geoestatísticos, a krigagem ordinária (KO) é o estimador mais utilizado em estudos sobre a variabilidade espacial de atributos químicos do solo (Sanchez et al., 2009; Souza et al., 2010; Sampaio et al., 2011; Camargo et al., 2013), porém a KO suaviza detalhes locais por meio da superestimação de valores pequenos e da subestimação de valores altos (Zhao et al., 2009). Além disso, a obtenção da variância da estimativa, por este método, é função apenas da distribuição dos dados e das características do variograma ajustado, não levando em

consideração os valores dos dados, integrando desta forma, uma medida incompleta da incerteza local (Soares, 2006).

Recentes estudos têm utilizado simulações estocásticas como alternativa para avaliar e quantificar a incerteza das propriedades químicas do solo (Bourennane et al., 2010; Sun et al., 2012), porém, no Brasil são poucas as publicações nesta área (Silva Jr. et al., 2012; Teixeira et al., 2011, 2012). Dentre as simulações estocásticas, a simulação sequencial gaussiana (SSG) e a simulação sequencial indicatriz (SSI) são as mais comuns. A SSG é a mais utilizada em estudos sobre propriedades químicas do solo (Bourennane et al., 2007; Chai et al., 2007; Zhao et al., 2009; Delbari et al., 2009, Sun et al., 2012), enquanto a SSI (Delbari et al., 2010) é frequentemente utilizada na área ambiental (Juang et al., 2004; Zhao et al., 2005). Ao contrário da KO, os modelos de simulação estocástica reproduzem a variabilidade espacial dos dados, o que elimina destes métodos a problemática do efeito de suavização. Os algoritmos de simulação geram um conjunto de realizações e não uma “melhor estimativa”, como no modelo da KO (Soares, 2006). Deste modo, este conjunto de realizações pode ser utilizado para mensurar a incerteza das predições geradas pelos modelos probabilísticos.

Os objetivos deste estudo foram caracterizar a variabilidade e a distribuição espacial do teor de K trocável em área de cana-de-açúcar; e avaliar o desempenho da SSG e SSI na modelagem da incerteza das predições do K, comparando com o método já consagrado da KO.

MATERIAL E MÉTODOS

Área de estudo e conjunto de dados

A área de estudo (21°05'57,11" de latitude Sul e 49°01'02,08" de longitude Oeste) localiza-se no município de Tabapuã, no noroeste do Estado de São Paulo, Brasil (Figura 3.1). O clima da região, segundo a classificação de Köppen, é do tipo mesotérmico, com inverno seco (Cwa), com precipitação pluvial média anual de 1.200 mm e chuvas concentradas no período de novembro a fevereiro. O solo foi classificado como Argissolo Vermelho-Amarelo eutrófico textura média/argilosa de

acordo o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2006). A área, de 200 hectares, apresenta um histórico de mais de 20 anos de cultivo de cana-de-açúcar com sistema de colheita queimada.

O solo foi amostrado nos pontos de cruzamento de uma malha, com intervalos regulares de 50 m, perfazendo um total de 626 pontos. Destas observações, 63 pontos (conjunto validação), cerca de 10% do total de pontos amostrados (Bourennane et al., 2007; Teixeira et al., 2011), foram sorteados aleatoriamente antes do início da modelagem geoestatística para a composição de um conjunto de dados utilizados no processo de validação da modelagem; os 563 pontos restantes (conjunto interpolação) foram utilizados para as previsões da variável nos locais não amostrados (Figura 3.1).

As amostras foram coletadas nas profundidades de 0,00-0,20 m, e o potássio trocável foi extraído utilizando o método da resina trocadora de íons, proposta por Raij et al. (2001). Esse banco de dados, juntamente com as metodologias de coleta, análise e classificação dos dados são originários de pesquisas realizadas por Sanchez et al. (2009).




Figura 3.1. Localização da área experimental e mapa de distribuição espacial dos pontos amostrais.

Estatística descritiva e variabilidade espacial

Inicialmente, foi feita a estatística descritiva dos valores observados de K (média, desvio-padrão, mínimo, máximo, coeficiente de variação, assimetria e

curtose), com o objetivo de obter informações para identificar tendência, dispersão e forma de distribuição dos dados (Bourgault et al., 1997). O software R foi utilizado para as avaliações da estatística descritiva (R Development Core Team, 2010). Adicionalmente, a reprodução dos dados amostrais, pelos modelos de simulação e estimação, foi verificada por meio das estatísticas descritivas e da função de distribuição acumulada condicional (fdac) e dos variogramas (Leuangthong et al., 2004).

A dependência espacial das amostras de K foi caracterizada por meio do variograma, que está baseado na teoria das variáveis regionalizadas, o qual é estimado por (Soares, 2006):

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [z(x_i) - z(x_i + h)]^2, \quad (3.1)$$

em que, $\hat{\gamma}(h)$ é a semivariância experimental para uma distância de separação h ; $z(x_i)$ é o valor da propriedade no ponto i , e $N(h)$ é o número de pares de pontos separados pela distância h . O variograma descreve a continuidade espacial das variáveis como função das distâncias entre duas localizações (Isaaks & Srivastava, 1989). Os ajustes dos variogramas experimentais foram feitos com base na menor soma de quadrado dos resíduos (SQR) e no maior coeficiente de determinação (R^2) (Isaaks & Srivastava, 1989).

Krigagem Ordinária

Na estimativa da krigagem ordinária (KO), a dependência espacial dos dados amostrais de fósforo foi quantificada por meio do variograma. O valor de K em um local não amostrado x_0 foi estimado usando o estimador $\hat{z}(x_0)$, definido como:

$$\hat{z}(x_0) = \sum_{i=1}^N \lambda_i z(x_i), \text{ com } \sum_{i=1}^N \lambda_i = 1, \quad (3.2)$$

em que, $\hat{z}(x_0)$ é o valor estimado de K no ponto 0; N é o número de valores utilizados na estimação; λ_i é o peso associado a cada valor observado, e $z(x_i)$ é o valor observado de K no ponto i (Soares, 2006).

A variância da KO (σ^2), no local não amostrado (x_0), foi calculada por:

$$\sigma^2(x_0) = \sum_{i=1}^N \lambda_i \gamma(x_0, x_i) + \mu, \quad (3.3)$$

em que, $\gamma(x_0, x_i)$ é a semivariância entre o local a ser estimado x_0 e o i -ésimo ponto amostrado, μ é o parâmetro de Lagrange utilizado para minimizar a variância da KO (Soares, 2006).

Simulação sequencial gaussiana

Para atender a um pré-requisito do procedimento da simulação sequencial gaussiana (SSG), os dados foram transformados para uma distribuição normal padronizada (com média igual a 0 e variância igual a 1). A normalidade da transformação dos dados de K foi verificada e confirmada por meio do teste de normalidade Shapiro-Wilk ($p > 0,05$).

O procedimento da SSG consiste em refinar a malha amostral e definir um caminho aleatório de forma que cada ponto a ser simulado seja visitado apenas uma vez. Utilizando o variograma dos dados normalizados, aliado ao estimador de krigagem simples, é determinada a fdac gaussiana. Posteriormente, é sorteado um valor normal padronizado, a partir da fdac, e adicionado ao conjunto de dados condicionais, que consiste nos pontos observados e nos previamente simulados, dentro da vizinhança do ponto a ser simulado. Este procedimento é repetido até que todos os pontos sejam simulados. Por fim, os dados normalizados são transformados para a escala original dos dados observados. Para gerar múltiplas realizações, essa sequência deve ser repetida com diferentes caminhos aleatórios para cada realização.

Simulação sequencial indicatriz

A simulação sequencial indicatriz (SSI) é baseada na abordagem sequencial que inclui os dados observados e todos os valores previamente simulados dentro de uma vizinhança. Na SSI, o estimador da krigagem indicatriz (KI) é usado para modelar as fdacs em cada ponto não amostrado, com base nas seguintes etapas:

- i. Transformar cada valor observado em um vetor de indicadores (0 ou 1), de acordo com os valores de corte z_k , utilizando a função indicadora $I(x_\alpha; z_k)$:

$$I(x_\alpha; z_k) = \begin{cases} 1 & \text{se } z(x_\alpha) \leq z_k \\ 0 & \text{caso contrário} \end{cases}, k = 1, \dots, K \quad \alpha = 1, \dots, n \quad (3.4)$$

- ii. Calcular e modelar os K variogramas indicadores, de acordo com os valores de corte z_k . Neste trabalho, foram utilizados quatro valores de corte ($1,2 \text{ mmol}_c \text{ dm}^{-3}$; $1,7 \text{ mmol}_c \text{ dm}^{-3}$; $2,2 \text{ mmol}_c \text{ dm}^{-3}$ e $3,1 \text{ mmol}_c \text{ dm}^{-3}$) que correspondem, respectivamente, aos percentis 0,2; 0,4; 0,6 e 0,8 da distribuição do K. Assim, foram gerados novos conjuntos de dados compostos de valores 0 e 1, de acordo com a função indicadora (3.4).
- iii. Estabelecer um caminho aleatório passando por todos os pontos a serem simulados, visitando cada ponto apenas uma vez.
- iv. Para cada ponto a ser simulado ao longo do caminho:
 - a) Determinar a fdac inicial usando o algoritmo da krigagem indicatriz.
 - b) Corrigir qualquer relação de desvio de ordem entre os valores estimados (maiores que 1 ou menores que 0) e determinar a fdac completa.
 - c) Obter o valor simulado a partir da fdac para aquele local e adicioná-lo ao conjunto de variáveis indicadoras condicionantes (valores observados e os previamente simulados) para modelar a fdac da próxima localização.
 - d) Proceder para a próxima localização ao longo do caminho aleatório e repetir os passos de (a) até (c).

Para obter várias realizações, o processo sequencial é repetido com diferentes caminhos aleatórios. Neste trabalho, foram geradas 200 realizações para cada método de simulação (SSG e SSI), utilizando o software WinGslib (Deutsch & Journel, 1998). Para representar o conjunto das 200 realizações e verificar a

reprodução dos valores observados de K, foram sorteadas, aleatoriamente, as realizações 11; 60; 94 e 143. Para manipular os dados das simulações individuais, obtidos no arquivo de saída gerado pelo software, contendo 172.800 linhas, foi implementado um script (Apêndice A) no software R (R Development Core Team, 2010). Este script converte esses arquivos em linhas para um arquivo com 200 colunas por 8.640 linhas.

A partir das realizações geradas por meio dos algoritmos da SSG e SSI, foram obtidas diferentes medidas de estimativa e de incerteza. A média, calculada ponto a ponto, de todos os 200 mapas simulados, forneceu uma estimativa denominada E-type (Deutsch & Journel, 1998). Da mesma forma, o desvio-padrão, calculado ponto a ponto, de todos os mapas simulados, forneceu o mapa espacial de desvio, utilizado para avaliar a incerteza local (Bourennane et al., 2007). O mapa de desvio-padrão representa a variação do teor de K nas n realizações simuladas ($n = 200$), em outras palavras, representa a incerteza local associada às predições, com base nos valores observados da malha amostral; e o mapa espacial da média das 200 realizações (E-type) representa o valor predominante do atributo K na área (Grunwald et al., 2007).

Avaliação de incertezas

A metodologia, proposta por Deutsch (1997), foi utilizada para examinar a acurácia na reprodução da fdac dos dados amostrais por parte do conjunto de realizações da SSG e da SSI. Esta consistiu em verificar as proporções de valores dos dados do conjunto de validação a que pertencem a intervalos de probabilidade (IP) - p simétricos, calculados a partir da fdac $F(u, z|(n))$. Em qualquer localização u , o conhecimento da fdac permite calcular uma série de IP - p simétricos limitados pelos quantis da fdac $(1-p)/2$ e $(1+p)/2$. Considerando os dados de validação, $F(u_j, z|(n))$, $j = 1, \dots, N_v = 63$, as frações de valores verdadeiros a que pertencem cada IP- p simétrico, foram obtidas por:

$$\bar{\xi}_{(p)} = \frac{1}{N} \sum_{j=1}^{N_v} \xi(u_j, p) \quad \forall p \in [0,1], \quad (3.5)$$

$$\text{com, } \xi(u_j, p) = \begin{cases} 1 & \text{se } \hat{F}^{-1}(u_j, (1-p)/2) < z(u_j) \leq \hat{F}^{-1}(u_j, (1+p)/2) \\ 0 & \text{caso contrário} \end{cases}$$

O algoritmo de simulação usado para gerar as fdacs é considerado acurado quando $\bar{\xi}(p) \geq p, \forall p$. O gráfico de dispersão, denominado gráfico de acurácia, foi gerado a partir das frações calculadas versus o conjunto de probabilidades p . A estatística G foi utilizada para mensurar, no gráfico de acurácia, o afastamento dos pontos em relação à linha de 45°, sendo numericamente calculada pela equação (Deutsch, 1997):

$$G = 1 - \int_0^1 [3a(p) - 2][\bar{\xi}(p) - p] dp, \quad (3.6)$$

em que, $a(p)$ é igual a 1; se $\bar{\xi}(p) \geq p$; e igual a 0, em caso contrário. Considera-se que valores de G iguais à unidade indicam máxima eficiência no ajuste do modelo, ou seja, $\bar{\xi}(p) = p, \forall p \in [0,1]$.

O software R (R Development Core Team, 2010) foi utilizado para o cálculo da estatística G (equações 5 e 6) e elaboração do gráfico de acurácia (Apêndice B).

Os valores observados do conjunto validação e os estimados, fornecidos pelos métodos de simulação, foram utilizados para o cálculo da raiz do erro quadrático médio – REQM (Bourennane et al., 2007; Teixeira et al., 2012), de acordo com a seguinte equação:

$$REQM = \left\{ \frac{1}{n} \sum_{i=1}^n [z(x_i) - \hat{z}(x_i)]^2 \right\}^{0.5} \quad (3.7)$$

em que, n é o número de valores utilizados na validação, neste trabalho $n=63$; $z(x_i)$ é o valor da propriedade no ponto i , e $\hat{z}(x_i)$ é o valor estimado da propriedade no ponto i . Menores valores de REQM estão relacionados à maior acurácia nas predições (Chai et al., 2007).

RESULTADOS E DISCUSSÃO

Estatística descritiva e variabilidade espacial

As estatísticas descritivas do conjunto validação foram próximas às do conjunto interpolação (Figura 3.2a e Quadro 3.1), não havendo diferença significativa entre os dois conjuntos de dados, de acordo com o teste de significância “t-student” ($p > 0,05$). A média dos valores observados ($2,99 \text{ mmol}_c \text{ dm}^{-3}$) (Quadro 3.1) indica a presença de altos teores de K para a cultura da cana-de-açúcar (Raij et al., 1997). Altos e médios teores de K foram relatados em trabalhos realizados por Marques Júnior et al. (2008) e Souza et al. (2010), respectivamente, em solos sob o cultivo da cana-de-açúcar. Embora a média dos teores de K esteja bem próxima à faixa de alta fertilidade ($3,1 - 6,0 \text{ mmol}_c \text{ dm}^{-3}$), os valores de K apresentaram grande amplitude ($0,30 - 11,90 \text{ mmol}_c \text{ dm}^{-3}$). O coeficiente de variação (CV) de 66,96% para os dados amostrais de K indica uma alta variabilidade, de acordo com a classificação de Warrick & Nielsen (1980). Vanni (1998) afirma que valores de $CV > 35\%$ revelam heterogeneidade dos dados e média pouco significativa. Desta forma, a aplicação do fertilizante potássico, considerando apenas o valor médio da propriedade, pode promover um subdimensionamento ou superdimensionamento das doses aplicadas.




Figura 3.2. Histogramas do potássio: conjunto interpolação e conjunto validação (a); dados amostrais com transformação normal (b).

As estatísticas referentes às quatro realizações individuais da SSG e SSI (Quadro 3.1) mantiveram os valores mínimos (Mín.) e máximos (Máx.) dos dados observados (conjunto interpolação). As realizações da SSG apresentaram valores de CV e desvio-padrão (DP) mais próximos ao conjunto interpolação do que as realizações da SSI. No procedimento da KO, as estatísticas dos dados originais não foram mantidas, sendo o valor mínimo superestimado, e o valor máximo, subestimado, revelando o efeito de suavização típico da KO. Esse mesmo cenário também foi encontrado por Delbari et al. (2010) ao analisarem as técnicas KO, SSG e SSI para a modelagem da variabilidade espacial do carbono orgânico do solo. A média, o DP e o CV da E-type de ambos os métodos de simulação apresentaram valores próximos aos da KO (Quadro 3.1), demonstrando que o número de realizações adotado foi adequado. Segundo Chilès & Delfiner (1999), é importante que os mapas E-type sejam gerados a partir de um número suficiente de realizações para que o mapa da média das realizações fique com padrões espaciais semelhantes aos do mapa da KO.

Quadro 3.1. Estatística descritiva do potássio (conjunto interpolação; conjunto validação; krigagem ordinária; E-type e realizações individuais da simulação sequencial gaussiana e simulação sequencial indicatriz).

K(mmol _c dm ⁻³)	N	Média	DP	CV	Mín.	Máx.	Ass.	Curt.
*Conjunto interpolação	563	2,99	1,54	66,96	0,30	11,90	2,38	8,18
**Conjunto validação	63	2,62	1,84	70,37	0,50	8,00	1,29	0,95
KO	8640	2,18	0,64	29,66	1,00	5,55	1,25	2,63
SSG								
E-type	8.640	2,20	0,62	28,22	0,30	11,90	3,03	27,84
Realização 11	8.640	2,26	1,48	65,46	0,30	11,90	2,34	8,07
Realização 60	8.640	2,19	1,38	63,34	0,30	11,90	2,37	8,66
Realização 94	8640	2,22	1,41	63,44	0,30	11,90	2,35	8,27
Realização 143	8.640	2,17	1,39	64,01	0,30	11,90	2,40	8,80
SSI								
E-type	8.640	2,76	0,71	25,85	0,30	11,90	1,67	11,80
Realização 11	8.640	2,82	2,50	92,06	0,30	11,90	1,92	2,86
Realização 60	8.640	2,73	2,52	92,24	0,30	11,90	2,09	3,44
Realização 94	8.640	2,72	2,54	93,20	0,30	11,90	2,04	3,38
Realização 143	8.640	2,69	2,47	91,73	0,30	11,90	2,05	3,55

N=número de observações; K=potássio; DP=desvio-padrão; CV=coeficiente de variação (%); Mín=mínimo; Máx=máximo; Ass.=coeficiente de assimetria; Curt.=coeficiente de curtose; SSG=simulação sequencial gaussiana; SSI=simulação sequencial indicatriz; KO=krigagem ordinária; *dados utilizados nos procedimentos de simulações e estimativas por krigagem ordinária; **dados utilizados na validação externa.

A caracterização da estrutura da variabilidade espacial foi determinada com o ajuste de modelos teóricos aos variogramas experimentais. Para o processo da KO, utilizou-se a transformação logarítmica nos dados de K, visando à correção da assimetria da distribuição (Quadro 3.1). A transformação logarítmica é recomendada para conjuntos de valores com assimetria positiva maior que a unidade (Webster & Oliver, 2009). A transformação normal dos dados originais de K foi realizada para atender a um pré-requisito da SSG (Figura 3.2b), sendo o modelo esférico o que apresentou os melhores ajustes para o variograma dos dados normalizados (Quadro 3.2). De acordo com a classificação de Cambardella et al. (1994), o grau de dependência espacial – GDE ($C_0/(C_0+C_1)$) foi classificado como moderado, tanto para os dados com transformação logarítmica, como para aqueles com transformação normal. O modelo esférico foi o que apresentou os melhores ajustes para os quatro variogramas indicadores (Quadro 3.2). Os variogramas dos percentis 0,20 e 0,40 apresentaram GDE fraco, enquanto os percentis 0,60 e 0,80 apresentaram moderada dependência espacial, de acordo com a classificação de Cambardella et al. (1994).

Quadro 3.2. Tipo de transformação empregada nos dados e parâmetros dos modelos ajustados aos variogramas experimentais do potássio.

Transf.	Perc	Modelo	C ₀	C ₀ +C ₁	A	GDE	SQR	R ²
Log	-	Esférico	0,19	0,30	214,52	0,63	5,62E-03	0,80
Normal	-	Esférico	0,60	0,93	277,60	0,64	0,0261	0,90
-	0,20	Esférico	0,11	0,14	145,04	0,78	4,33E-04	0,47
-	0,40	Esférico	0,17	0,22	210,84	0,77	8,92E-04	0,66
-	0,60	Esférico	0,15	0,21	160,95	0,71	3,21-03	0,63
-	0,80	Esférico	0,11	0,15	244,02	0,73	4,09E-03	0,85

Transf=transformação da distribuição dos dados; Normal=transformação normal padronizada; Log=transformação logarítmica; Perc.=percentil; C₀=efeito pepita; C₀+C₁=patamar; A=alcance; C₁=variância estrutural; GDE=grau de dependência espacial ($C_0/(C_0+C_1)$); SQR=soma do quadrado dos resíduos; R²=coeficiente de determinação.

Os mapas simulados reproduziram melhor a fdac dos dados amostrais do que o mapa da KO (Figura 3.3). Dentre os algoritmos de simulação, a SSG apresentou uma reprodução mais fiel da fdac dos dados amostrais em relação à SSI (Figura 3.3a, b). Em trabalho realizado por Goovaerts (2001), a SSI reproduziu de forma mais fiel a fdac dos dados amostrais, quando comparada à SSG.

As realizações individuais da SSG apresentaram menor variabilidade em pequena escala do que as realizações da SSI (Figura 3.4). Em estudo realizado por Zhao et al. (2005), as realizações da SSI mostraram padrões de variabilidade semelhantes para valores extremos de carbono orgânico. Os padrões espaciais das simulações individuais geradas por ambos os métodos (Figura 3.4) apresentam maior variabilidade para os teores altos e intermediários de K.




Figura 3.3. Funções densidade acumulada condicional do potássio: conjunto interpolação, simulação sequencial gaussiana e krigagem ordinária (a); conjunto interpolação, simulação sequencial indicatriz e krigagem ordinária (b).




Figura 3.4. Mapas estimados do teor de potássio disponível: realizações individuais (11; 60; 94 e 143) das simulações sequencial gaussiana e sequencial indicatriz.

A reprodução do variograma dos dados amostrais pela KO (Figura 3.5) não foi satisfatória, uma vez que esta subestimou a variabilidade em pequena escala, representada no variograma com menor efeito pepita. Este mesmo cenário é relatado por Delbari et al. (2010) e está intimamente relacionado à característica de suavização do método da KO. As realizações individuais da SSG reproduziram melhor o variograma dos dados amostrais que a KO, resultado semelhante ao de Leuangthong et al. (2004) e Bourennane et al. (2010). Em relação à SSI, Goovaerts (1997) afirma que esta reproduz apenas os modelos dos variogramas indicadores. A reprodução dos variogramas correspondentes aos quantis 0,20; 0,40; 0,60 e 0,80 da distribuição do K, pelas realizações, está ilustrada na Figura 8. A SSI (Figura 3.6) reproduziu melhor a continuidade espacial para médias e grandes escalas, enquanto os variogramas das realizações sorteadas da SSG (Figura 3.5) reproduziram melhor a variabilidade espacial para pequenas escalas.




Figura 3.5. Variogramas padronizados do potássio: realizações sorteadas da simulação sequencial gaussiana; e conjunto interpolação.

Os mapas E-type, gerados a partir da SSI e SSG (Figura 3.7), foram semelhantes ao mapa da KO. Diferentemente da KO, as estimativas E-type preservaram a variação (Mín. e Máx.) do conjunto interpolação (Quadro 3.1). Estes resultados também foram relatados em trabalhos com a KO e a SSI (Chai et al., 2004; Zhao et al., 2009) e em trabalhos usando a KO e a SSG (Bourennane et al., 2007; Goovaerts et al., 2008). Esta característica dos mapas E-type indica grande potencial prático para a definição de zonas homogêneas de manejo específico, uma vez que os mapas das realizações individuais apresentam limitações que podem

inviabilizar a sua utilização (Soares, 2006): o excesso de mapas produzidos e o alto nível de detalhamento desses mapas.




Figura 3.6. Variogramas indicadores padronizados do potássio para os valores de corte e realizações sorteadas da simulação sequencial indicatriz.




Figura 3.7. E-type das simulações sequencial gaussiana e sequencial indicatriz e krigagem ordinária do potássio.

Avaliação de incertezas

Os mapas de desvios gerados por ambos os algoritmos de simulação mostram alta incerteza espacial na parte sudoeste da área de estudo (Figura 3.8 a, b), locais estes em que os maiores teores de K foram obtidos. Entretanto, no mapa de desvios da SSI, as áreas com alta incerteza foram maiores que aquelas indicadas pela SSG. A identificação e a delimitação destas localidades favorecem o planejamento amostral da área, sendo que estas áreas devem ser amostradas mais detalhadamente, visando à diminuição das incertezas e, conseqüentemente, à melhor captação da real variabilidade do nutriente em estudo.

Os desvios-padrão locais associados às estimativas da KO apresentaram menor variação ao longo de toda a área de estudo (Figura 3.8c). Este fato se deve ao desvio-padrão da KO ser independente do valor real da amostra. Esta relação foi confirmada por meio da representação gráfica do diagrama de dispersão da E-type vs desvio-padrão (Figura 3.9c). Resultado semelhante ao observado por Bourennane et al. (2007) e Delbari et al. (2009) para estimativas do conteúdo de água do solo. Os valores médios de K, obtidos por meio de ambos os algoritmos de simulação, apresentam uma evidente relação entre os desvios-padrão locais (Figura 3.9a, b). Assim, pequenos a intermediários valores das médias locais de K ($< 3 \text{ mmol}_c \text{ dm}^{-3}$) apresentam baixa incerteza local ($< 1,5 \text{ mmol}_c \text{ dm}^{-3}$). Estes resultados destacam a necessidade da avaliação precisa da incerteza associada aos métodos de interpolação. Tais informações devem ser incorporadas aos processos de tomada de decisão, permitindo assim o estabelecimento preciso de áreas para fins de manejo específico.




Figura 3.8. Mapas de desvio-padrão do potássio obtidos por simulação sequencial gaussiana (a); por simulação sequencial indicatriz (b); e por krigagem ordinária (c).

A análise visual das Figura 3.10a e b demonstra que, para o algoritmo da SSG, os desvios dos pontos em relação à reta 1:1 foram maiores do que para o algoritmo SSI. A SSG apresentou menor valor de G (0,68) do que o calculado a partir da SSI (0,88), indicando que o desempenho, por parte da SSI, é 13 % mais acurado para modelar a fdac do K. Resultados estes, semelhantes aos relatados por Delbari et al. (2010).




Figura 3.9. Gráfico de dispersão do desvio-padrão vs média local do K obtido por meio da simulação sequencial gaussiana (a); da simulação sequencial indicatriz (b) e da krigagem ordinária (c).

O valor do REQM, calculado a partir do conjunto validação (63 pontos) e das 200 realizações obtidas de cada método de simulação (SSG e SSI), foi maior para a SSG (2,45) do que o calculado para a SSI (1,58), o que evidencia que a modelagem do K, por meio da SSI, foi 21% mais acurada do que a modelagem da SSG.




Figura 3.10. Gráfico de acurácia e estatística G para a simulação sequencial gaussiana (a); simulação sequencial indicatriz (b) do potássio.

CONCLUSÕES

1. Os mapas simulados, obtidos por meio da simulação sequencial gaussiana (SSG) e da simulação sequencial indicatriz (SSI), representaram a distribuição

espacial do potássio (K) disponível no solo de forma mais realista do que o mapa de estimação fornecido pela krigagem ordinária (KO).

2. O desempenho das técnicas SSG e SSI mostraram-se mais eficientes para modelar a incerteza da distribuição espacial do K disponível do que o desempenho da técnica da KO.

3. Os modelos de simulação podem ser utilizados na delimitação mais precisa de áreas de manejo específico.

LITERATURA CITADA

ANDA - ASSOCIAÇÃO NACIONAL PARA DIFUSÃO DE ADUBOS - Anuário Estatístico do Setor de Fertilizantes. São Paulo, 2008.

BENITES, V. M.; CARVALHO, M. C. S.; RESENDE, A. V.; POLIDORO, J.C.; BERNARDI, A. C. C. & OLIVEIRA, F. A. Potássio, cálcio e magnésio. In: PROCHNOW, L. I.; CASARIN, V. & STIPP, S. R. (Eds.). Boas práticas para o uso eficiente de fertilizantes: nutrientes. Piracicaba, IPNI, 2010. p. 137-191.

BOURENNANE, H.; DOUAY, F.; STERCKEMAN, T.; VILLANNEAU, E.; CIESIELSKI, H.; KING, D. & BAIZE, D. Mapping of anthropogenic trace elements inputs in agricultural topsoil from Northern France using enrichment factors. *Geoderma*, Amsterdam, 157:165-174, 2010.

BOURENNANE, H.; KING, D.; COUTURIER, A.; NICOULLAUD, B.; MARY, B. & RICHARD, G. Uncertainty assessment of soil water content spatial patterns using geostatistical simulations: An empirical comparison of a simulation accounting for single attribute and a simulation accounting for secondary information. *Ecol. Model.*, Amsterdam, 205:323-335, 2007.

BOURGAULT, G.; JOURNAL, A. G.; RHOADES, J. D.; CORWIN, D.L. & LESCHG, S. M. Geostatistical analysis of a soil salinity data set. *Adv. Agron.*, Maryland Heights, 58: 241-292, 1997.

CAMARGO, L. A.; MARQUES JÚNIOR, J.; PEREIRA, G. T. & ALLEONI, L. R. F. Spatial correlation between the composition of the clay fraction and contents of available phosphorus of an Oxisol at hillslope scale. *Catena*, Amsterdam, 100:100–106, 2013.

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. Sci. Soc. Am. J.*, Madison, 58:1.501-1.511, 1994.

CHAI, X.; HUANG, Y. & YUAN, X. Accuracy and uncertainty of spatial patterns of soil organic matter. *New Zealand Journal of Agricultural Research*, Singapore, 50:1.141–1.148, 2007.

CHILÈS, J.P. & DELFINER, P. *Geostatistics: Modelling spatial Uncertainty*. Wiley, New York, 695 p., 1999.

CONAB– Companhia Nacional de Abastecimento. Acompanhamento de safra brasileira: cana-de-açúcar, Segundo Levantamento, agosto/2012. Disponível em: http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12_09_05_09_11_59_boletim_cana_portugues_-_agosto_2012_2o_lev.pdf. Acesso em: out. 2012.

DELBARI, M.; AFRASIAB, P. & LOISKANDL, W. Using sequential Gaussian simulation to assess the field-scale spatial uncertainty of soil water content. *Catena*, Amsterdam, 79: 163-169, 2009.

DELBARI, M.; LOISKANDL, W. & AFRASIAB, P. Uncertainty assessment of soil organic carbon content spatial distribution using geostatistical stochastic simulation. *Aust. J. Soil Res.*, Austrália, 48: 27–35, 2010.

DEUTSCH, C. Direct assessment of local accuracy and precision. In: BAAFI, E. Y. & SCHOFIELD, N. A. (Eds.), *Geostatistics Wollongong '96*. Dordrecht, Kluwer Academic Publishing, 1997. p. 115–125.

DEUTSCH, C. V. & JOURNEL, A. G. *GSLIB: Geostatistical software Library and User's Guide*. New York, Oxford University Press, 1998. 369 p.

EMBRAPA- Empresa Brasileira de Pesquisa Agropecuária, Centro Nacional de Pesquisa de Solos. *Sistema Brasileiro de Classificação de Solos*. Rio de Janeiro, 2006. 306 p.

ERNANI, P. R.; ALMEIDA, J. A. & SANTOS, F. C. Potássio. In: NOVAIS, R. F. et al. (Eds.). *Fertilidade do Solo*. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. p. 551-594.

GOOVAERTS, P. Geostatistical modelling of uncertainty in soil science. *Geoderma*, Amsterdam, 103: 3–26, 2001.

GOOVAERTS, P. *Geostatistics for natural resources evaluation*. New York: Oxford University Press, 1997, 483p.

GOOVAERTS, P.; TRINH, H. T.; DEMOND, A. H.; TOWEY, T.; CHANG, S.-C.; GWINN, D.; HONG, B.; FRANZBLAU, A.; GARABRANT, D.; GILLESPIE, B. W.; LEPKOWSKI, J. & ADRIAENS, P. Geostatistical Modeling of the Spatial Distribution of Soil Dioxin in the Vicinity of an Incinerator. 2. Verification and Calibration Study. *Environ. Sci. Technol.*, Dordrecht, 42:3.655-3.661, 2008.

GRUNWALD, S.; REDDY, K. R.; PRENGER, J. P. & FISHER, M. M. Modeling of the spatial variability of biogeochemical soil properties in a freshwater ecosystem. *Ecological Modelling*, Amsterdam, v: 521-535, 2007.

ISAACS, E. H. & SRIVASTAVA, R. M. *A introduction to applied geostatistics*. Oxford University Press, 1989. 592 p.

JUANG, K.-W.; CHEN, Y.-S.; LEE, D.-Y. Using sequential indicator simulation to assess the uncertainty of delineating heavy-metal contaminated soils. *Environ. Pollut.*, Oxford, 127:229–238, 2004.

KINPARA, D. I. A. *Importância Estratégica do Potássio para o Brasil*. Embrapa Cerrados, Planaltina, 2003, 27p.

KORNDÖRFER, G. H. & OLIVEIRA, L. A. O potássio na cultura da cana-de-açúcar. In: YAMADA, T. & ROBERTS, T. L. (Eds.). *Potássio na agricultura brasileira*. Piracicaba: ESALQ/USP, 2005. p. 469-490.

LEUANGTHONG O.; MCLENNAN, J. A. & DEUTSCH, C. V. Minimum acceptance criteria for geostatistical realizations. *Natural Resources Research*, Nova York, 13:131–141, 2004.

MALAVOLTA, E. Importância da adubação na qualidade dos produtos: função dos nutrientes na planta. In: SÁ, M. E.; BUZZETI, S. Importância da adubação na qualidade dos produtos agrícolas. São Paulo: Ícone, 1994. p. 19-44.

MARQUES JÚNIOR, J.; SOUZA, Z. M. de; PEREIRA, G. T. & BARBIERI, D. M. Variabilidade espacial de matéria orgânica, P, K e CTC de um latossolo cultivado com cana-de-açúcar por longo período. *Revista de Biologia e Ciências da Terra*, Campina Grande, 8:143-152, 2008.

OTTO, R.; VITTI, G. C. & LUZ, P. H. C. Manejo da adubação potássica na cultura da cana-de-açúcar. *R. Bras. Ci. Solo*, 34:1137-1145, 2010.

R DEVELOPMENT CORE TEAM (2010). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, ISBN 3-900051-07-0. Disponível em: URL <http://www.R-project.org>. Acesso em 20 set. 2012.

RAIJ, B. van; ANDRADE, J. C.; CANTARELLA, H. & QUAGGIO, J. A. (eds.). Análise química para avaliação da fertilidade de solos tropicais. Campinas: Instituto Agrônomo, 2001. 285 p.

RAIJ, B. van; CANTARELLA, H.; QUAGGIO, J. A. & FURLANI, A. M. C. (Ed.). Recomendações de adubação e calagem para o Estado de São Paulo. 2.ed. Campinas: IAC, 1997. 285 p.

SAMPAIO, M. S. Avaliação do comportamento da variabilidade espacial do fósforo remanescente no solo de lavoura cafeeira. In: XV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Anais. Curitiba, INPE, 2011, p. 9.203-9.210.

SANCHEZ, R. B.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; BARACAT NETO, J.; SIQUEIRA, D. S. & SOUZA Z. M. Mapeamento das formas do relevo para estimativa de custos de fertilização em cana-de-açúcar. *Eng. Agríc.*, Jaboticabal, v.32, n.2, p. 280-292, 2012.

SANCHEZ, R. B.; MARQUES JÚNIOR, J.; SOUZA, Z. M.; PEREIRA, G. T. & MARTINS FILHO, M. V. Variabilidade espacial de atributos do solo e de fatores de erosão em diferentes pedoformas. *Bragantia*, Campinas, 68:1.095-1.103, 2009.

SIGUA, G. & HUDNALL, W. Kriging analysis of soil properties. *J. Soil Sediment*, Heidelberg, 8:193-202, 2008.

SILVA JR., J. F.; MARQUES JR., J.; CAMARGO, L. A.; TEIXEIRA, D. D. B.; PANOSSO, A. R. & PEREIRA, G. T. Simulação geoestatística na caracterização espacial de óxidos de ferro em diferentes pedoformas. *R. Bras. Ci. Solo*, 36:1395-1406, 2012.

SOARES, A. Geoestatística para ciências da terra e do ambiente. 2. ed. Lisboa: IST Press, 2006, 214 p.

SOUZA, Z. M.; CERRI, D. G. P.; COLET, M. J.; RODRIGUES, L. H.; MAGALHÃES, P. S. G. & MANDONI, R. J. A. Análise dos atributos do solo e da produtividade da cultura de cana-de-açúcar com o uso da geoestatística e árvore de decisão. Ciênc. Rural, Santa Maria, 40: 840-847, 2010.

SUN, X. ; WU, S.; WANG, H.; ZHAO, Y.; ZHAO, Y.; ZHANG, G.; MAN, Y. B. & WONG, M. H. Uncertainty Analysis for the Evaluation of Agricultural Soil Quality Based on Digital Soil Maps. Soil Sci. Soc. Am. J., Madson, 76: 1.379–1.389, 2012.

TEIXEIRA D. D. B.; BICALHO, E. S.; PANOSSO, A. R.; PERILLO, L.I.; IAMAGUTI, J. L.; PEREIRA, G. T. & LA SCALA, N. Uncertainties in the prediction of spatial variability of soil CO₂ emissions and related properties. R. Bras. Ci. Solo, 36: 1.466-1.475, 2012.

TEIXEIRA, D. B.; BICALHO, E. S.; PANOSSO, A.R.; PERILLO, L.I.; IAMAGUTTI, L.J.; PEREIRA, G. T. & SCALA JUNIOR, N. Revista de energia na agricultura, Botucatu, 26: 26-42, 2011.

VANNI, S. M. Modelos de regressão: estatística aplicada. São Paulo: Legmar Informática & Editora, 1998. 177p.

WARRICK, A. W. & NIELSEN, D. R. Spatial variability of soil physical properties in the field. In: HILLEL, D., ed. Applications of soil physics. New York, Academic, 1980. p. 319-344.

ZHAO, Y.; XU, X.; DARILEK, J.; HUANG, B.; SUN, W. & SHI, X. Spatial variability assessment of soil nutrients in an intense agricultural area, a case study of Rugao County in Yangtze River Delta Region, China. Environ. Geol., Heidelberg, 57:1.089-1.102, Berlin, 2009.

ZHAO, Y.;SHI, X.;YU,D.; WANG, H. & SUN, W. Uncertainty assessment of spatial patterns of soil organic carbon density using sequential indicator simulation, a case study of Hebei province, China. Chemosphere, Kidlington, 59:1.527–1.535, 2005.

CAPÍTULO 4 – IMPLICAÇÕES

A utilização das simulações estocásticas possibilita a identificação de áreas que apresentam maiores incertezas nas estimativas das propriedades estudadas, subsidiando informações que permitem dimensionar os riscos nos processos de tomada de decisão quanto à aplicação de insumos agrícolas, como também possibilita o planejamento amostral, visando à redução das incertezas.

Além da possibilidade de quantificar as incertezas por meio dos vários cenários fornecidos pelas realizações do método de simulação, estas realizações também podem ser utilizadas para a aplicação de fertilizantes em taxas variadas. Assim como a krigagem ordinária, o pós-processamento da média das imagens geradas pela simulação, o qual fornece um mapa único, pode ser utilizado para a aplicação desses fertilizantes.

A crescente utilização dos algoritmos de simulação estocástica pode levar alguns a considerarem os métodos de krigagem como ferramenta geoestatística ultrapassada. É importante frisar que a krigagem, em suas diversas variações, tem seu campo de aplicação a depender dos objetivos do estudo, e, ademais, em grande parte dos algoritmos de simulação estocástica, ela é implicitamente utilizada. Assim, todas as incertezas que se têm na estimativa de um atributo, em uma determinada posição, ocorrerão também nas krigagens implicitamente realizadas nas simulações estocásticas e, portanto, também as influenciará.

Um entrave em relação ao uso das simulações estocásticas é a escolha de um método específico. As diferenças entre os diversos algoritmos disponíveis e os efeitos nos resultados da modelagem precisam ser mais bem entendidos para que seja possível utilizá-los com mais confiança. Em se tratando de Brasil, a escassez de pesquisas nesta área torna a escolha de uma abordagem específica tarefa difícil para os novos usuários da simulação estocástica. A verdade é que não existe “o melhor método”, sendo necessário saber qual mais se adapta a uma aplicação em particular. Para que as simulações estocásticas tenham aplicação prática, particularmente na agricultura de precisão, é preciso que as diferenças entre os métodos, as principais características e implicações de uso estejam bem definidas.

APÊNDICES

Apêndice B – script que calcula a estatística G e elabora o gráfico de acurácia

```

validacao_simulacao<-read.table("arquivo.txt",h=T,dec=".") #arquivo (N linhas x M colunas)
#com os N #pontos de
# validação buscados nas M
# simulações

pontos _validacao<-read.table("pontos_validacao_P.txt", h=T) #arquivo com os pontos da
#validação do atributo

attach (pontos_validacao)
n<-63 # número de pontos de validação
x<-0.01 #incremento do intervalo de probabilidade
p<-seq(x,1,by=x)
fda<-list() # guarda as fdacs dos N pts de validação
for(i in 1:length(validacao_simulacao [,1])){ # calcula as fdacs dos N pts de validação
  fda[[i]]<-ecdf(as.numeric(validacao_simulacao [i,]))}
zli<-list()
zls<-list()
for (i in 1:length(validacao_simulacao [,1])){ #calcula os intervalos simétricos a partir das N
#fdacs
  zli[[i]]<-quantile(fda[[i]],(1-p)/2)
  zls[[i]]<-quantile(fda[[i]],(1+p)/2)
}
cont<-vector()
ep<-vector()

for(j in 1:length(p)){ #calcula a proporção nos intervalos
  for(i in 1:n){
    cont[i]<-length(subset(pts_validacao, pts_validacao>zli[[i]][j] &
      pts_validacao<=zls[[i]][j],1))}
    ep[j]<-sum(cont/n)/n
  }
}

```

```

ap<-vector()
for (i in 1:length(p)){          # calcula a proporção ap
  if (ep[i]>=p[i])
    ap[i]<-1
  else ap[i]<-0}

goodness<-vector()
for (j in 1:length(p)){          # calcula estatística G
  goodness[j]<-(((3*ap[j])-2)*(ep[j]-p[j]))*x
  G<-1-(sum(goodness))
}

plot(p,ep,xlim=c(0,1),ylim=c(0,1),xlab = "Probabilidade no intervalo - p", ylab =
"Proporção neste intervalo") # imprime o gráfico de acurácia
abline(0,1,col="blue",lw=2) # desenha a linha bissetriz no gráfico
text (0.8,0.2,paste("\nG =", format(G, digits=2)) # imprime o valor da estatística G no gráfico

```