

UNIVERSIDADE ESTADUAL PAULISTA – UNESP

CAMPUS DE JABOTICABAL

**SUSCETIBILIDADE MAGNÉTICA COMO COVARIÁVEL DE
ATRIBUTOS DE SOLO**

Tayna Lara Serantoni da Silveira

Engenheira Agrônoma

2023

UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CAMPUS DE JABOTICABAL

SUSCETIBILIDADE MAGNÉTICA COMO COVARIÁVEL DE
ATRIBUTOS DE SOLO

Tayna Lara Serantoni da Silveira

Orientador: Prof. Dr. Gener Tadeu Pereira

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Campus de Jaboticabal, como parte das exigências para a obtenção do título de Mestre em Agronomia (Ciência do Solo).

2023

S587 Silveira, Tayna Lara Serantoni da
Suscetibilidade magnética como covariável de atributos de
solo /Tayná Lara Serantoni da Silveira. -- Jaboticabal, 2023
50 p. : tabs., mapas

Dissertação (mestrado) - Universidade Estadual Paulista
(Unesp), Faculdade de Ciências Agrárias e Veterinárias,
Jaboticabal

1. Geoestatística. 2. Krigagem. 3. Regressão. I.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de
Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal



CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: SUSCETIBILIDADE MAGNÉTICA COMO COVARIÁVEL DE ATRIBUTOS DE SOLO

AUTORA: TAYNA LARA SERANTONI DA SILVEIRA

ORIENTADOR: GENER TADEU PEREIRA

Aprovada como parte das exigências para obtenção do Título de Mestra em Agronomia (Ciência do Solo), pela Comissão Examinadora:

Prof. Dr. GENER TADEU PEREIRA (Participação Virtual)

Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal

Documento assinado digitalmente
gov.br GENER TADEU PEREIRA
Data: 11/12/2023 19:20:16-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. ALAN RODRIGO PANOSSO (Participação Virtual)

Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal

Documento assinado digitalmente
gov.br ALAN RODRIGO PANOSSO
Data: 11/12/2023 20:46:16-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. DANIEL DE BORTOLI TEIXEIRA (Participação Virtual)

Grupo São Martinho S/A / Pradópolis/SP

Documento assinado digitalmente
gov.br DANIEL DE BORTOLI TEIXEIRA
Data: 13/12/2023 05:26:04-0300
Verifique em <https://validar.iti.gov.br>

Jaboticabal, 28 de agosto de 2023

DADOS CURRICULARES DO AUTOR

TAYNA LARA SERANTONI DA SILVEIRA – nascida em 13 de junho de 1995 em Votuporanga – SP, graduada em Engenharia Agrônômica pela Universidade Estadual Paulista Júlio de Mesquita Filho pelo Campus de Ilha Solteira em 2018. Foi bolsista CNPq de iniciação científica no período de 2015 a 2017. Atualmente é aluna de Mestrado do curso de Pós-Graduação em Agronomia Ciência do Solo pela FCAV/UNESP Jaboticabal (sendo bolsista CAPES no período de 2020 a 2022). Atua na área de Agronomia, com ênfase em Geoestatística.

AGRADECIMENTO

Agradeço primeiramente a Deus por me dar forças e me guiar em todo esse trajeto.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Campus de Jaboticabal, a seu corpo docente e todas as pessoas que nela exercem uma função, pelo apoio e incentivo aos alunos.

Ao docente Gener Tadeu Pereira, pela orientação e confiança durante esses anos pandêmicos de pós-graduação.

Aos meus pais, Maria e Carlos por me permitirem almejar uma boa formação e seguir com meus planos.

Obrigada minhas irmãs, Tayla, Tanielle e Tayane por serem meu Porto Seguro, pelo apoio e força, nunca me permitindo desistir.

A todos os companheiros de estudos, pela ajuda, a qual foi de grande importância para a estruturação deste trabalho.

Aos meus amigos, pelo suporte para enfrentar todas as dificuldades e por proporcionar ótimos momentos.

E a todos que, direta ou indiretamente, contribuíram para que muitos de meus objetivos fossem alcançados.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

SUMÁRIO

RESUMO.....	viii
ABSTRACT.....	xi
LISTA DE TABELAS	x
LISTA DE FIGURAS	xi
1 INTRODUÇÃO E JUSTIFICATIVAS.....	1
2 REVISÃO DE LITERATURA	3
2.1 Métodos de mapeamento de solos.....	3
2.2 Definição de unidades de mapeamento com o auxílio da suscetibilidade magnética (SM) e atributos do solo	4
2.3 Geoestatística.....	7
3 MATERIAIS E MÉTODOS	17
3.1 Descrição da área e amostragem.....	17
3.2 Análises de dados	18
4 RESULTADOS E DISCUSSÕES	18
5 CONCLUSÕES	28
6 REFERÊNCIAS	29

SUSCETIBILIDADE MAGNÉTICA COMO COVARIÁVEL DE ATRIBUTOS DE SOLO

RESUMO- Solos brasileiros apresentam grande diversidade dos fatores e processos de formação do solo o que, aliado a grande extensão territorial nacional, dificulta a obtenção de mapas em escalas detalhadas para todo o território. Diversas metodologias propõem auxiliar a identificação e mapeamento das unidades de solos e de seus atributos. Entretanto, há alguns fatores que podem dificultar o estudo sobre o solo e a variabilidade espacial de seus atributos, como o grande número de amostras, elevado custo e tempo de coleta e análises, além dos impactos ambientais. Um método que tem se mostrado uma alternativa para estimar atributos do solo é o mapeamento da suscetibilidade magnética (SM), que cada vez mais vem ganhando destaque, sendo que a SM é covariativa dos fatores e processos de formação dos solos e, está diretamente relacionada à mineralogia destes. Com a hipótese de que o método de predição por krigagem de regressão tem maior precisão do que as estimativas por krigagem ordinária, este trabalho tem como objetivo utilizar a SM como covariável nas estimativas por krigagem dos atributos de solo para auxiliar no delineamento de unidades de mapeamento, bem como na readequação dos limites entre unidades de solo incorporando simultaneamente informações sobre a variabilidade espacial destes atributos. A área de estudo considerada neste trabalho localiza-se no município de Guataporã/SP, possuindo 870 ha e caracterizada pela presença de Latossolos e Neossolo. Foram coletadas 349 amostras na profundidade de 0-0,25 m para a avaliação da SM, argila, areia, silte e H₂O₂, desta malha foram retirados, aleatoriamente, 20 pontos para serem utilizados nas estimativas das estatísticas dos erros da validação. A utilização da suscetibilidade magnética como covariável nas estimativas por krigagem dos atributos de solo para auxiliar no delineamento de unidades de mapeamento, bem como na readequação dos limites entre unidades de solo incorporando simultaneamente informações sobre a variabilidade espacial destes atributos se mostrou promissora.

Palavras-chave: argila, geoestatística, krigagem de regressão, variabilidade espacial.

MAGNETIC SUSCEPTIBILITY AS A COVARIABLE OF SOIL ATTRIBUTES

ABSTRACT - Brazilian soils present a great diversity of soil formation factors and processes, which, combined with the large national territorial extension, makes it difficult to obtain maps on detailed scales for the entire territory. Several methodologies propose to help identify and map soil units and their attributes. However, there are some factors that can make it difficult to study the soil and the spatial variability of its attributes, such as the large number of samples, high cost and time for collection and analysis, in addition to environmental impacts. A method that has proven to be an alternative for estimating soil attributes is the mapping of magnetic susceptibility (SM), which is increasingly gaining prominence, given that SM is a covariant of soil formation factors and processes and is directly related to their mineralogy. With the hypothesis that the regression kriging prediction method has greater precision than ordinary kriging estimates, this work aims to use SM as a covariate in kriging estimates of soil attributes to assist in the delineation of mapping units, as well as readjusting the limits between soil units, simultaneously incorporating information on the spatial variability of these attributes. The study area considered in this work is located in the municipality of Guatapar/SP, measuring 870 ha and characterized by the presence of Oxisols and Neosols. 349 samples were collected at a depth of 0-0.25 m for the evaluation of SM, clay, sand, silt and H_{Al}. From this mesh, 20 points were randomly removed to be used in estimating validation error statistics. The use of magnetic susceptibility as a covariate in kriging estimates of soil attributes to assist in the delineation of mapping units, as well as in readjusting the limits between soil units while simultaneously incorporating information on the spatial variability of these attributes has shown to be promising.

Keywords: clay, geostatistics, regression kriging, spatial variability.

Lista de tabelas

Tabela 1 - Estatísticas Descritivas das variáveis Argila, Areia Total, H_AI, Silte, SM	20
Tabela 2 - Com resultados da regressão SM com Argila, Areia Total, H_AI, Silte.	21
Tabela 3 -Variogramas ajustados às variáveis Argila, Argila com SM, Areia Total, Areia Total com SM, H_AI, H_AI com SM, Silte, Silte com SM e SM	22
Tabela 4 -Valores da validação da Krigagem Ordinária e Krigagem de regressão: SM das variáveis Argila, Areia Total, H_AI e Silte.....	28

Lista de Figuras

Figura 1 - Exemplo esquemático do conceito de krigagem de regressão em uma transeção regionalizada (Adaptado de Hengl, 2009)	8
Figura 2 - Caracterização da área de estudo. Localização da área amostral (a); mapa geológico na escala 1:500000 (SG – Serra Geral; AD – Depósito Aluvionar; ECD – Depósito ColúvioEluvionar) (b); mapa geomorfológico na escala de Escala 1:100000 (Cc – côncava; Cx – Convexa) (c); mapa pedológico na escala 1:12000 (LVAd - Latossolo Vermelho Amarelo distrófico textura média; LVd - Latossolo Vermelho distrófico textura média; LVdf - Latossolo Vermelho distroférrico textura argilosa; LVef - Latossolo Vermelho eutroférrico textura argilosa; RQod – NeossoloQuartzarênicoórtico distrófico textura arenosa) (d); distribuição espacial das amostras (e). Extraído de Teixeira (2015).	17
Figura 3 -Painel dos gráficos de dispersão, histogramas e correlações entre as variáveis Argila, Areia Total, H_AI, Silte e SM.	21
Figura 4 -Gráficos dos variogramas das variáveis: a) SM, b) Argila, c) Argila com SM, d) Areia, e) Areia com SM, f) H_AI, g) H_AI com SM, h) Silte, e i) Silte com SM..	23/24
Figura 5 -Mapas de Krigagem simples da SM (a) e das variáveis Argila (b), da Argila com a covariável SM (c), Areia total (d), Areia total com a covariável SM (e), H_AI (f), H_AI com a covariável SM (g), Silte (h) e Silte com a covariável SM (i).	25/26/27

1. INTRODUÇÃO E JUSTIFICATIVAS

O entendimento das relações complexas que existem entre os atributos do solo é possibilitado ao conhecer e modelar os padrões do comportamento espacial dos mesmos (Sánchez et al., 2009). Diversas atividades relacionadas aos processos agrícolas são beneficiadas pelo mapeamento dos atributos do solo, entre eles estão: a otimização do uso de insumos agrícolas (White; Zasoski, 1999), a otimização amostral (Pereira et al., 2013), planejamento agrícola, implantação de sistemas de cultivo para cana-de-açúcar (Campos et al., 2008), dentre outras.

Para melhor orientação sobre as práticas de manejo e um desenvolvimento de agricultura sustentável, o conhecimento do solo é fundamental, possibilitando as realizações de ações que garantem segurança alimentar de um território (Ramos et al., 2018). O crescente desenvolvimento sustentável das atividades do setor agropecuário vem sendo influenciado pela intensificação do uso da tecnologia no setor, que possibilita o aumento gradativo da produtividade. Esses avanços tecnológicos têm mostrado a importância de se medir a variação espacial e temporal dos atributos do solo das propriedades, objetivando otimizar o aproveitamento de recursos e a redução de custos (Carvalho et al., 2002). Segundo Oliveira et al. (2017), especialistas têm notado, que os diversos setores da agricultura não podem ser tratados de maneira homogênea no que diz respeito à medição de variáveis nas áreas de produção.

De acordo com Angelico (2006) as análises estatísticas de dados, no passado, consideravam as variáveis aleatórias independentes entre si, ou seja, acreditavam que as observações vizinhas não exerciam influências umas sobre as outras. Entretanto, fenômenos naturais apresentam-se frequentemente com certa estruturação entre vizinhos. Assim, pode-se dizer que as variações não ocorrem ao acaso, apresentando certo grau de dependência espacial. Considera-se indispensável a caracterização da variabilidade espacial dos atributos químicos e físicos do solo por meio de amostragem capaz de representar tais variações (Bottega et al., 2013)

Em conformidade com Oliveira et al. (2005) a variabilidade espacial das propriedades físicas do solo de campos agrícolas é ligada à natureza, como fatores

geológicos e pedológicos de formação do solo, bem como uma parcela da variabilidade pode ser induzida também pelo tipo de cultivo e das práticas de manejo adotadas.

Segundo Webster (1985) o estudo das variações do solo de uma região, acontece há vários anos. Atualmente, a utilização de tecnologias na agricultura tem se mostrado crescente quando se diz respeito a realização do mapeamento dos atributos qualitativos e quantitativos das características do solo, os quais estão ligados à produtividade das culturas, incluindo a adesão ao GPS (Global Positioning System) associado às técnicas de geoestatística (Bottega, E. et al., 2011). Para Campinas et al. (2013) as técnicas de geoestatística permitem quantificar a existência de variações espaciais dos diversos atributos físicos do solo, tornando possível obter uma descrição detalhada destas propriedades no tempo e no espaço.

Para Souza, Marques Júnior e Pereira (2004) conhecer a variabilidade espacial de atributos físicos do solo em cultivos como o da cana-de-açúcar, que são altamente tecnificados, é fundamental no que diz respeito à redução dos custos associados aos sistemas de produção. Entretanto, há alguns fatores que podem dificultar o estudo sobre a variabilidade espacial, haja vista que para que seja realizado é necessário um grande número de amostras, acarretando no aumento dos custos, além do tempo de coleta e das análises dos atributos e os impactos ambientais que podem ser provocados pela utilização de reagentes.

De acordo com Demattê et al. (2007) relata que os altos custos das análises de solos podem interferir, por exemplo, na adesão à agricultura de precisão na América do Sul. Para melhores resultados para determinação de atributos do solo são necessárias metodologias que sejam menos agressivas ao meio ambiente, menos onerosas, e que contribuam para um mapeamento da variabilidade desses atributos com maiores níveis de detalhe. Também utilizados pela agricultura de precisão, esses princípios podem ser a explicação dos altos valores investidos no melhoramento genético das culturas agrícolas, por exemplo (Marques Júnior et al., 2009).

Ao considerar todos esses critérios, um método que tem se mostrado uma alternativa para estimar atributos do solo é o mapeamento da suscetibilidade

magnética (Grimley&Vepraskas, 2000), que cada vez mais vem ganhando destaque como um dos métodos mais utilizados para fins ambientais (Grimley et al., 2004). A suscetibilidade magnética é covariativa dos fatores e processos de formação do solo, e está diretamente relacionada à mineralogia dos mesmos (Camargo et al., 2014). Sua utilização crescente deve-se a simplicidade e baixo custo em sua determinação (Dearing, 1994), e a sua alta relação com os atributos físicos, químicos e mineralógicos do solo (Siqueira et al., 2010). Para Dearing et al. (1996) a suscetibilidade magnética é ideal para estudos que demandam uma quantidade considerável de amostras. E, de acordo com Marques Júnior et al. (2009), além da importância do tamanho da amostra para representar uma área, outro fator que merece atenção é a metodologia estatística utilizada para o estudo.

Com a hipótese de que o método de predição por Krigagem de regressão tem maior precisão do que as estimativas por KO, este trabalho tem como objetivo utilizar a SM como covariável nas estimativas por krigagem dos atributos de solo para auxiliar no delineamento de unidades de mapeamento, bem como na readequação dos limites entre unidades de solo incorporando simultaneamente informações sobre a variabilidade espacial destes atributos.

2. REVISÃO DE LITERATURA

2.1. Métodos de mapeamento dos solos

Devido a sua extensa área territorial, são vários os tipos de solos brasileiros, estes apresentam uma grande diversidade nos fatores e processos de formação como material de origem, paisagem, entre outros. Por essa perspectiva, a obtenção de mapas de unidade de mapeamento em escalas detalhadas para todo o território é dificultada (Minasny et al., 2010; Siqueira, 2013).

São diversas as metodologias que propõem auxiliar a identificação e mapeamento destas unidades de solos e de seus atributos. Algumas utilizam conceitos determinísticos e matemáticos associados, sendo considerada uma nova classe de mapeamento intitulada de mapeamentos híbridos. Tais métodos possibilitam o conhecimento dos solos e seus atributos, com menor subjetividade do que a apresentada pelos métodos tradicionais (McBratney et al., 2000).

Áreas de produção de cana-de-açúcar bem como as classificações mais técnicas, a exemplo o mapa de capacidade e uso do solo, são definidos de acordo com os levantamentos taxonômicos de solo. Tais levantamentos não consideram a variabilidade dos atributos do solo de forma detalhada. Deste modo, os levantamentos de solos com controle da variabilidade espacial dos atributos, sendo utilizados para definir os ambientes de produção, teriam habilidade de informação semelhante às zonas mínimas de manejo, ou áreas de manejo específico, conceituação utilizado em agricultura de precisão.

A proposta de Garrity e Agustin (1995) e Marques Júnior (2009) é de que utilizem a análise espacial quantitativa dos atributos do solo nos estudos sobre manejo deste, de maneira que seja possível identificar e mapear áreas de manejo específicas. De forma que, em locais onde a variabilidade dos atributos do solo é mínima, próximo à homogeneidade, possibilita a transferência de tecnologia para áreas semelhantes (Mallarino et al., 2001; Siqueira et al. 2010).

De acordo com McBratney et al. (2003), uma das justificativas do reduzido conhecimento sobre a variabilidade dos atributos do solo é em função do custo elevado e alta demanda de tempo exigido para a realização dos levantamentos convencionais. Assim, métodos alternativos para quantificação dos atributos do solo (pedometria) se fazem necessários, de maneira que possibilitam aumentar o número de amostras coletadas sem que ocorra o aumento nos custos e período de análise.

Pode-se dizer que o conhecimento sobre a variabilidade espacial dos atributos do solo é possibilitado pelo emprego das informações espaciais produzidas por metodologias geoestatísticas, sendo esta, uma das principais informações empregadas para o delineamento das unidades de mapeamento do solo, de modo que a variabilidade espacial dos atributos do solo seja mínima dentro de uma unidade de solo e máxima entre unidades (Castrignanò et al., 2009).

2.2. Definição de unidades de mapeamento com o auxílio da suscetibilidade magnética (SM) e atributos do solo

Para definições de unidades de solos (Siqueira, 2013) ou estimativas de atributos do solo (Teixeira et al., 2013b) também podem ser utilizadas informações

adicionais quantitativas. Assim, variáveis que forem selecionadas devem demonstrar forte relação com propriedades do solo, ser de fácil obtenção e variar suavemente no espaço (Goovaerts, 1997). Neste segmento, algumas técnicas têm tido destaque ao possibilitar a caracterização da variabilidade e mapeamento dos atributos do solo. Entre as técnicas de destaque estão: espectroscopia de reflectância difusa (ERD) (Barrón et al., 2000), condutividade elétrica (Brenning et al., 2008), suscetibilidade magnética (SM) (Camargo, 2013; Marques Jr. et al., 2014).

Os métodos geofísicos mais utilizados como função de pedotransferência para mapear a variabilidade espacial dos atributos do solo de maneira indireta são os de resistividade elétrica e condutividade (Johnson et al., 2001; Brenning et al., 2008). Entretanto, as medições feitas por estes podem oscilar devido ao teor de água no solo.

As funções de pedotransferência (FP) podem ser conceitualizadas como modelos matemáticos empregues para obtenção das estimativas de atributos dos solos com base em outros atributos medidos mais facilmente e com custo reduzido. As FPs, em sua maioria, foram desenvolvidas para estimativas de propriedades hidráulicas do solo, todavia seu uso não se restringe para essa finalidade. A exemplo, inúmeras FPs desenvolvidas para estimar atributos físicos, químicos e biológicos do solo foram apresentadas por McBratney et al. (2002)

Haja vista que a coleta de amostras é a etapa mais intensiva e onerosa, na avaliação quantitativa dos atributos do solo considerando o planejamento agrícola (McBratney et al., 2002), as funções de pedotransferência são bem úteis nesta etapa, uma vez que têm sido desenvolvidas e utilizadas na ciência do solo para reduzir os custos na obtenção de informações e como auxílio para assimilar melhor como funciona os processos do solo e como estes refletem na resposta das culturas agrícolas.

A suscetibilidade magnética é outro método alternativo com grande potencial para o mapeamento e a quantificação indireta de atributos do solo (Resende et al., 1981; Grimley e Vepraskas, 2000; Becegato et al., 2005). A SM é o grau de magnetização de um material em resposta a um campo magnético aplicado e de acordo com Craik (1995) e Luque (2008) ela é produzida por indução do campo

magnético terrestre durante a cristalização do mineral presente na rocha ou no solo, e se origina das propriedades de rotação dos elétrons.

De acordo com Marques Jr. (2009), em regiões onde ocorre a transição dos materiais de origem dos solos, a exemplo na transição arenito-basalto, a avaliação da suscetibilidade magnética deve ser utilizada para melhorar a precisão e acurácia dos limites entre classes de solos. Segundo o levantamento elaborado pelo IPT em 1981, na escala 1:1.000.000, a transição arenito-basalto abrange aproximadamente 3,5 % (873 mil ha) do Estado de São Paulo e é nessa região que se situa os principais polos sucroalcooleiros do Estado.

É fato que no ambiente natural, existem diferentes espécies de minerais, sendo assim o que é estimado na verdade é a SM resultante, ou seja, a que representa o mineral de maior expressão naquela área. Por conseguinte, a existência de minerais magnéticos no solo em determinado ambiente é identificada por medidas de SM (Costa et al., 1999; Torrent et al., 2010; Jordanova et al., 2016). Sendo esta, uma característica dos minerais presentes nas rochas e no solo.

A SM têm se mostrado muito promissora como ferramenta no mapeamento das regiões podendo ser utilizada para outras finalidades além da quantificação indireta de atributos do solo, como para a identificação de áreas com diferentes potenciais de risco à erosão (Royall, 2001), aptidão quali-quantitativa da cultura da cana-de-açúcar (Marques Jr., 2009), aplicação de vinhaça (Peluco et al., 2013), mapeamentos detalhados em áreas de cana-de-açúcar (Siqueira, 2013), determinação do potencial de perda de solos (Barbosa, 2014), produtividade de cana-de-açúcar (Marques Jr., 2014), emissão de CO₂ do solo (Leal et al., 2015), adsorção de fósforo (Peluco et al., 2015), dentre outros.

Considerada covariativa dos fatores e processos de formação do solo em função da sua forte relação com os principais minerais deste nas regiões tropicais, a SM tem sido utilizada especialmente em solos contendo óxidos de ferro, que respondem pela magnetização do solo, principalmente os ferrimagneticamente ordenados, como magnetita e maghemita (Silva et al., 2005). Entretanto, modelos que utilizam a SM e as análises convencionais, necessitam de calibração para, assim, determinar os níveis de acurácia das estimativas. Também é necessário

verificar se esses modelos são válidos para áreas distintas, para o entendimento da variabilidade espacial dos resultados, bem como conferir seu potencial de uso na identificação de áreas de manejo específicas.

2.3. Geoestatística

Faz-se cada vez mais necessária a compreensão da variabilidade espacial das características em áreas agrícolas para que assim consiga fazer um melhor uso, de maneira consciente e adequada. Assim, a descrição quantitativa da variabilidade espacial dos atributos do solo e a estimativa não tendenciosa da variância mínima de valores desses atributos em locais não amostrados é possibilitada pela modelagem geoespacial, sendo uma importante ferramenta na caracterização e mapeamento de atributos dos solos (Kumar et al., 2012) em grandes áreas que apresentam complexidade litológica e geomorfológica.

Para Camargo (1998) a integração de procedimentos geoestatísticos em SIG's (Sistemas de Informações Geográficas), fundamentados em técnicas de krigagem, é significativa, uma vez que essa combinação beneficia os procedimentos tradicionais de ambos os sistemas em função da qualidade do estimador e, principalmente, pela informação precisa fornecida nesse modelo inferencial.

A krigagem se diferencia de outros métodos de interpolação pois além de fornecer estimadores exatos com propriedades não tendenciosas, ela estima uma matriz de covariância espacial que define os pesos atribuídos às amostras distintas, o tratamento da redundância dos dados, a vizinhança a ser considerada no procedimento inferencial e o erro associado ao valor estimado (Camargo, 1998).

Segundo o relato de Huijbregts (1975) a relevância do variograma como ferramenta básica de suporte às técnicas de krigagem, possibilitando a representação quantitativa da variação de um fenômeno regionalizado no espaço, ilustrando um semivariograma experimental com características muito próximas do ideal. Assim, é esperado que áreas vizinhas, ou seja, observações mais próximas geograficamente tenham um comportamento mais semelhante entre si do que aquelas mais distanciadas.

Uma abordagem mais teórica da modelagem geoestatística, proposta por Matheron é apresentada a seguir. Matheron (1969) propôs que um valor de uma variável alvo em algum local pode ser modelado como uma soma dos componentes determinísticos e estocásticos:

$$Z(x) = m(x) + \epsilon'(x) + \epsilon''(x), \quad (1)$$

Uma ilustração é apresentada na Fig. 1 abaixo




Figura 1. Exemplo esquemático do conceito de krigagem de regressão em uma transeção regionalizada (Adaptado de Hengl, 2009).

O modelo da equação 1 é denominado de modelo universal de variação espacial. Os componentes determinísticos e estocásticos da variação espacial podem ser modelados separadamente. Combinando as duas abordagens, para um específico local x_0 , temos:

$$\hat{z}(x_0) = m(x_0) + \hat{\epsilon}'(x_0) = \sum_{k=0}^K \beta_k q_k(x_0) + \sum_{i=1}^n \lambda_i \epsilon(x_0), \quad (2)$$

em que $\hat{m}(x_0)$ é a parte determinística ajustada, $\hat{\epsilon}(x)$ é o resíduo interpolado, $\hat{\beta}_k$ são os coeficientes determinísticos estimados do modelo ($\hat{\beta}_0$ é o intercepto estimado), λ_i

são pesos de krigagem determinados pela dependência espacial estrutura do resíduo e $\epsilon(x_0)$ é o resíduo no local x_0

Os coeficientes de regressão $\hat{\beta}_k$ podem ser estimados a partir da amostra por algum método de ajuste, por exemplo, mínimos quadrados ordinários (OLS) ou, idealmente, usando o método Mínimos Quadrados Generalizados, na forma matricial (Cressie, 1993):

$$\hat{\beta}_{GLS} = (q^T C^{-1} q)^{-1} q^T C^{-1} z, \quad (3)$$

em que, $\hat{\beta}_{GLS}$ é o vetor de coeficientes de regressão estimados, C é a matriz de covariância dos resíduos, q é uma matriz de preditores nos locais de amostragem e z é o vetor de valores medidos da variável alvo.

A estimativa GLS de coeficientes de regressão é, de fato, um caso especial de regressão geograficamente ponderada. Neste caso, os pesos são determinados objetivamente para levar em conta o espaço a auto correlação entre os resíduos.

Uma vez estimada a parte determinística da variação, o resíduo pode ser interpolado com krigagem e adicionada à tendência estimada (Fig. 2).

A estimativa dos resíduos e seu modelo de variograma é um processo iterativo: primeiro a parte determinística da variação é estimada usando mínimos quadrados ordinários (OLS), então a função de covariância dos resíduos é usada para obter os coeficientes GLS.

Em seguida, eles são usados para recalcular os resíduos, a partir dos quais uma função de covariância atualizada é calculada, e assim por diante (Schabenberger e Gotway, 2004).

Embora isso seja recomendado como procedimento adequado por muitos geoestatísticos, Kitanidis (1994) mostrou que o uso da função de covariância derivada dos resíduos OLS (ou seja, uma única iteração) é muitas vezes satisfatório, porque não é diferente o suficiente da função derivada após várias iterações; isto é não afeta muito as previsões finais. Minasny e McBratney (2007) relataram

resultados semelhantes: muitas vezes é mais importante usar dados mais úteis e de maior qualidade do que usar métodos estatísticos mais sofisticados.

Em algumas situações, no entanto, o modelo precisa ser ajustado usando a técnica mais sofisticada para evitar fazer previsões tendenciosas.

Na notação matricial, a krigagem de regressão é comumente escrita como (Christensen, 2001):

$$\hat{z}_{KS}(x_0) = \mathbf{q}^T \hat{\beta}_{GLS} + \lambda_0^T (\mathbf{z} - \mathbf{q} \hat{\beta}_{GLS}), \quad (4)$$

em que: $\hat{z}_{KS}(x_0)$ é o valor previsto no local x_0 , $\mathbf{q}_0$ é o vetor de $p + 1$ preditores e λ_0 é o vetor de n pesos de krigagem usados para interpolar os resíduos.

O modelo definido acima é considerado o Melhor Preditor Linear de dados espaciais (Christensen, 2001; Schabenberger e Gotway, 2004).

Ele tem uma variância de predição que reflete a posição de novos locais (efeito de extrapolação) tanto no espaço geográfico quanto no espaço de recursos:

$$\hat{\sigma}_{KS}^2 = (\mathbf{C}_0 + \mathbf{C}_1) - \mathbf{c}_0^T \mathbf{C}^{-1} \mathbf{c}_0 + (\mathbf{q}_0 - \mathbf{q}^T \mathbf{C}^{-1} \mathbf{c}_0)^T (\mathbf{q}^T \mathbf{C}^{-1} \mathbf{q})^{-1} (\mathbf{q}_0 - \mathbf{q}^T \mathbf{C}^{-1} \mathbf{c}_0), \quad (5)$$

em que: $\mathbf{C}_0 + \mathbf{C}_1$ é a variação do patamar e $\mathbf{c}_0$ é o vetor de covariâncias de resíduos no local não visitado.

A geoestatística vem se tornando uma ferramenta amplamente utilizada para o planejamento dos recursos naturais, possibilitando a modelagem da dispersão espacial das grandezas que os definem.

Aplica-se a geoestatística ao estudo do comportamento das variáveis regionalizadas, que possuem características intermediárias entre um comportamento totalmente aleatório e totalmente determinísticos. Ainda que não correspondam por completo os requisitos de um processo ergódico, as variáveis são correlacionadas.

Os métodos geoestatísticos se fundamentam em funções que reúnem a dependência espacial que considera a proximidade – correlação espacial – e a direção – isotropia ou anisotropia –, frequentemente empregada em estudos sobre o comportamento espacial de fenômenos naturais que não apresentam padrão de distribuição que possa ser caracterizado pelos métodos da estatística clássica (Resende; Sturion, 2001). O variograma é o componente básico para a estruturação da análise de dados na geoestatística, e permite a representação da média de variação de um atributo em relação à distância (Andriotti, 1988; Wang; Hou, 2009).

Os valores de um atributo para pontos não amostrados são concebidos por interpoladores não geoestatísticos através de uma combinação linear dos valores dos pontos vizinhos levando em consideração a relação de distância entre eles e, portanto, dependem diretamente da posição de todos esses pontos. Esses métodos geralmente são aplicados para espacializar ocorrências em que os dados apresentam natureza contínua, com normalidade e frequência. As inferências para os valores da ocorrência espacializada não excedem o conjunto de valores dos pontos observados.

Os modelos geoestatísticos e os interpoladores, utilizados nos dados obtidos por estudos e pesquisas, podem proporcionar melhor caracterização e compreensão do fenômeno estudado. A geoestatística demonstra ser um instrumento de confiança para estimar fenômenos naturais, devido ao seu fundamento matemático que garante a confiabilidade do método e sua aplicação, proporciona resultados robustos, quando correlacionada ao conhecimento físico do problema (Vicente, 2004; Giacomini et al., 2014).

A compreensão de fenômenos naturais requer o uso de ferramentas matemáticas avançadas para diferentes fins, como: desenvolvimento de processos, otimização, controle, classificação, clustering e predição. Os modelos geoestatísticos híbridos são de grande importância, visto que relacionam o significado físico do modelo determinístico com a habilidade de reduzir a complexidade dos modelos estocásticos para aperfeiçoar a estratégia de modelagem, ao passo que direcionam a uma precisão desejada (Zendehboudi et al., 2018).

Para descrever, classificar e estudar os padrões de variação espacial dos solos na paisagem, tem sido sugerido a modelagem quantitativa dos solos, a qual objetiva melhorar a compreensão da variabilidade espacial, da precisão e da qualidade da informação, através das variadas técnicas quantitativas, que constituem o conjunto da pedometria. Muitos fatores têm proporcionado o progresso de estudos envolvendo esse conjunto, entre eles estão os avanços em teorias matemáticas e métodos estatísticos, assim como sistemas remotos de aquisição de dados e informática (Bui, 2007).

Segundo Gonzáles e Zak (1994) os atributos do solo não estão distribuídos de forma aleatória nos ecossistemas ou na paisagem e são compostos por variáveis regionalizadas. Considerando a distância que separa suas localizações, algumas amostras de solo são mais similares do que outras. Para desenvolver estimativas mais precisas das propriedades do solo, é necessário o entendimento da distribuição espacial dos elementos de estudo a partir do reconhecimento dessa variabilidade espacial.

Essa necessidade de entender o comportamento espacial dos elementos de estudo de um ecossistema, tem carecido da utilização de variados métodos de predição espacial, usufruindo de fatores mais específicos do que apenas pontos amostrais, para a construção de superfícies contínuas. Esses métodos podem variar desde mapas gerados por interpoladores determinísticos e métodos geoestatísticos, como a Krigagem Ordinária, Bloco de Krigagem, Simulação Sequencial Gaussiana, até métodos ainda mais sofisticados como Krigagem de regressão e geoestatística baseada em modelo linear misto.

Diversas técnicas geoestatísticas podem ser encontradas para mapear variáveis ambientais. Entretanto, a maioria busca por técnicas mais flexíveis, abrangentes e robustas, principalmente se estiverem associadas a softwares de fácil manuseio. Muitos geoestatísticos acreditam que existe apenas um modelo de Melhor Predição Linear Imparcial (BLUP) para dados espaciais, e que as outras técnicas poderiam ser derivadas dele (Gotway e Stroup, 1997; Stein, 1999; Christensen, 2001). Uma dessas técnicas de mapeamento é a krigagem de regressão, sendo outras vistas como seus casos especiais, como é o caso da krigagem comum, a

correlação ambiental, a média de valores por polígonos ou a interpolação inversa de distância.

A Krigagem tem apresentado o melhor estimador linear não enviesado entre os métodos de interpolação espacial, e tem sido utilizada de forma ampla para mapear as propriedades do solo. A krigagem de regressão (KR), uma das variantes da krigagem, por conseguir agregar a variação dos fatores ambientais formadores do solo – chamadas covariáveis ambientais – na variação da propriedade do solo alvo, o que atrai uma maior atenção (Knotters et al., 1995; Kravchenko e Robertson, 2007; Vasques et al., 2010). A krigagem de regressão pode ter aplicações em diversas áreas, desde a agricultura de precisão (Grunwald et al., 2015) até o mapeamento global (Hengl et al., 2014), ao englobar dados remotos, de campo e de laboratório e métodos estatísticos em uma estrutura de estimativa quantitativa para propriedade do solo ou mapeamento digital do solo.

A KR é empregada na engenharia para a otimização da área. A técnica foi originalmente aplicada na geoestatística (Hengl; Heuvelink; Rossiter, 2007), com a finalidade de avaliar condições de regiões desconhecidas através de análises amostrais de dados. A técnica de Krigagem possui outras variações que, de acordo com os autores, a krigagem de regressão é tida como uma forma universal.

Para os modelos de predição linear para dados especiais, como o uso da técnica de mapeamento de KR, é esperado que sejam mais precisos e confiáveis (Hengl, 2007). A KR é uma técnica de interpolação espacial que combina a regressão de uma variável dependente de variáveis auxiliares – como parâmetros de superfície, imagens de satélite e mapas temáticos – com a krigagem dos resíduos da regressão/krigagem ordinária dos resíduos (Pebesma, 2006). (Hengl et al. 2007).

A KR é um modelo geoestatístico híbrido que representa à combinação da regressão multivariada com a krigagem ordinária, que permite predizer uma variável pela associação da modelagem de componentes determinísticos e estocásticos, elaboradas separadamente (Hengl, 2009; Scolforo, 2014; Carvalho, 2016). Como dito, o modelo considera a autocorrelação espacial da variável de interesse, a correlação entre a variável de interesse e variáveis auxiliares e a estimativa espacial não-tendenciosa com variância minimizada (Meng et al. 2013).

O termo Krigagem, foi cunhado em 1963 por Matheron em homenagem ao engenheiro de minas, Daniel Krige. O engenheiro foi o primeiro precursor do método chamado de Krigagem (Forrester; Sóbester; Keane, 2008). Na krigagem de regressão primeiro emprega um modelo de regressão (linear, multi-linear ou não-linear) para conseguir estimativas de atributos principais em função de atributos secundários e após utiliza-se os resíduos adquiridos dos locais onde se tem o atributo principal para estimá-los por krigagem nos locais onde se empregou a regressão, assim, o valor final dos atributos é adquirindo a partir da soma dos valores estimados.

A krigagem, como explicitada, é um método de estimativa fundada em médias ponderadas de dados, onde os pesos são definidos pelo modelo de continuidade espacial do atributo na área. Outra possibilidade, quando se sabe sobre os atributos secundários nas áreas a serem estimadas, seria aplicar os modelos de regressão para estimarem por meio da modelagem da relação entre o atributo principal e atributos secundários.

Conforme Omuto e Vargas (2015), para a representação de tendências em larga escala adota-se a componente determinística, e para modelá-las se utiliza análise de regressão, que fornece uma visão geral do comportamento da variável principal. Em contrapartida, para a autocorrelação em curta escala adota-se a componente estocástica, sendo modelada com a análise da Krigagem.

É fundamental que tenha uma correlação dos dados elaborados com base no modelo de regressão, para que o mapa final apresente um melhor detalhamento. Desse modo, a KR é aplicada, com o objetivo de corrigir as tendências, aos resíduos gerados pelo modelo, incorporando um aspecto estocástico ao mapeamento. As técnicas geoestatísticas híbridas vêm sendo cada vez mais empregadas, uma vez que elas permitem a utilização de informações secundárias disponíveis e alcançam previsões locais mais precisas, considerando, desta forma, as correlações ambientais (Mello, 2013).

De acordo com Sassi et al. (2012), a regressão linear múltipla possibilita a redução de variáveis e permite a detecção dos principais padrões de similaridade, associação e correlação entre elas, sendo assim, considerada um mecanismo

multivariado. Para aumentar o grau de correlação entre dados teóricos e reais, a introdução de novas variáveis na equação de ajuste pode ser feita. O modelo apresenta um único valor como resultado, que caracteriza uma combinação do conjunto inteiro de variáveis que melhor abrange o objetivo da análise multivariada específica.

Em conformidade com Hengl et al. (2003), alguns tipos de Krigagem são considerados pertencentes ao grupo dos modelos híbridos, que são geralmente utilizadas em ocasiões de não estacionariedade dos dados, como é o caso da krigagem universal, da krigagem com deriva externa e da krigagem de regressão. Cada tipo de Krigagem se comporta de uma maneira, na primeira a tendência é modelada em função somente das coordenadas, tendo como base os valores de localização para desenvolver a regressão. Na krigagem com deriva externa a tendência é definida por meio de variáveis auxiliares. E, na krigagem de regressão, a tendência e resíduos são modelados separadamente e somados posteriormente.

Segundo Dixon e Uddameri (2016), a autocorrelação espacial é analisada através do ajuste do semivariograma e retrata as relações espaciais de dados geográficos, valendo-se da estrutura de covariância espacial em dados de atributos. Ao invés de considerar que os valores nos locais sem amostragem são ordenados de forma uniforme sobre um espaço geográfico, a análise de autocorrelação verifica como os valores das variáveis de um local são afetados pelas variáveis e seus valores encontradas em locais próximos.

A autocorrelação espacial pode ser melhor esclarecida pela Primeira Lei da Geografia de Tobler (Tobler, 1970), que afirma que todas as coisas – considerando fenômenos espaciais – se relacionam, mas as coisas mais próximas possuem uma relação mais forte do que as distantes. Assim, locais e posições na paisagem são comparados para determinar a similaridade ou dissimilaridade.

As análises e modelagem de semivariograma apresentam como o principal objetivo a construção de um modelo que possibilita uma melhor estruturação da autocorrelação espacial do processo estocástico. O semivariograma é um gráfico de semivariância em função do vetor de distância h entre os pontos amostrados. Em sua totalidade, os pares de amostras possíveis são agrupados em classes com

distâncias semelhantes, chamadas de lags. A escolha da distância entre os pontos ocorre com o processo de tentativa e erro, o qual procura obter o máximo de detalhes com uma menor distância (lagdistance) (Englund; Sparks, 1991; Dixon; Uddameri, 2016).

O processo de estimativa dos resíduos é sequencial e repetitivo, visto que primeiro se consegue o drift por regressão e consequentemente, os resíduos, que será a base para a modelagem da continuidade espacial. Com a continuidade espacial pode-se obter novos coeficientes de regressão aplicando-se mínimos quadrados generalizados, que consideram a correlação espacial na estimativa do drift (Cressie, 1993). Desse modo, conseguindo novos resíduos e consequente novo modelo de continuidade espacial e assim sucessivamente. Kitanidis (1994) mostrou, entretanto, que uma única repetição geralmente é satisfatória, não sendo necessário a aplicação de mínimos quadrados generalizados.

Diversos estudos, como os de Kotters et al. (1995), Odeh et al. (1994, 1995), Goovaerts (1999b), McBratney et al. (2000), Bishop e McBratney (2001), Hengl et al. (2004), Minasny e McBratney (2007), Rivero et al. (2007), Yan et al. (2007), aplicaram a KR e também a comparação dessa com outras técnicas de estimativa, como regressão (multi)linear, krigagem ordinária, krigagem universal, cokrigagem ordinária, entre outras. Em geral, os melhores resultados foram obtidos pela técnica de KR, que foram superiores ao da krigagem ordinária, quando há informação auxiliar correlacionada; foram similares aos da cokrigagem, porém podendo gerar resultados superiores (Goovaerts, 1999), além de ser uma técnica mais simples, uma vez que não requer a modelagem da continuidade espacial cruzada.

Conforme Odeh et al. (1995) não existe melhor método, dependendo do cenário. Entretanto, concluem que KR dá melhores resultados que os métodos univariados quando há correlação entre atributos.

Nas ciências do solo a KR é bem conhecida pela sua fácil aplicação, associando o benefício dos métodos tradicionais de regressão, em que geralmente são utilizados mapas de sensoriamento remoto e geológicos como referência auxiliar na modelagem do drift, com os métodos geoestatísticos, considerando a correlação espacial entre os atributos, na modelagem dos resíduos.

3. MATERIAL E MÉTODOS

3.1. Descrição da área e amostragem

O banco de dados de atributos do solo que será utilizado neste trabalho faz parte do legado do banco de dados do Grupo CSME (www.csme.com.br)

A área de estudo (Figura 2), localiza-se no município de Guataporã no estado de São Paulo – Brasil, sendo suas coordenadas centrais 21°28'40"S e 48°01'38"O. A vegetação natural da área era constituída por floresta tropical subcaducifolia. Atualmente, é cultivada com cana-de-açúcar sob o sistema de colheita mecanizada há mais de 15 anos. De acordo com Thornthwaite (1948), o clima da região pode ser definido como B1rB'4a', Tipo Mesotérmico Úmido, com pequena deficiência hídrica, sendo a evapotranspiração de verão menor que 48% da evapotranspiração anual. É caracterizada pela transição geológica Basalto – Depósito Aluvionar - Depósito ColúvioEluvionar, formas da paisagem côncavas e convexas e presença de Latossolos e Neossolo.




Figura 2. Caracterização da área de estudo. Localização da área amostral (a); mapa geológico na escala 1:500000 (SG – Serra Geral; AD – Depósito Aluvionar; ECD – Depósito ColúvioEluvionar) (b); mapa geomorfométrico na escala de Escala 1:100000 (Cc – côncava; Cx – Convexa) (c); mapa pedológico na escala 1:12000 (LVAd - Latossolo Vermelho Amarelo distrófico textura média; LVd - Latossolo

Vermelho distrófico textura média; LVdf - Latossolo Vermelho distroférico textura argilosa; LVef - Latossolo Vermelho eutroférico textura argilosa; RQod – Neossolo Quartzarênico órtico distrófico textura arenosa) (d); distribuição espacial das amostras (e). Fonte: Extraído de Teixeira (2015).

Na área experimental foi instalada uma malha de amostragem regular contendo 349 pontos separados por distâncias mínimas variando de 145 m a 174 m, abrangendo uma área total de cerca de 870 ha. A densidade amostral resultante (0,4 amostras/ha) está de acordo com o indicado pelos Procedimentos Normativos de levantamentos pedológicos (Embrapa, 1995). Sob cada ponto da malha amostral foram coletadas amostras na profundidade de 0-0,25 m para a determinação da SM e teor de argila. Desta malha foram retirados, aleatoriamente, 20 pontos para serem utilizados nas estimativas das estatísticas dos erros da validação.

3.2. Análises de dados

A suscetibilidade magnética (SM) em baixa frequência (0,47 kHz) foi determinada em 10 g de terra fina seca ao ar utilizando o equipamento BartingtonMS2, acoplado ao sensor BartingtonMS2B (Dearing, 1994). O teor de argila foi determinado pelo método da pipeta, utilizando solução de NaOH 0,1 mol L⁻¹ como dispersante químico e agitação mecânica em aparato de baixa rotação por 16 horas (EMBRAPA, 2007).

A variabilidade das variáveis foi previamente descrita por meio da estatística descritivas, tais como, valor mínimo, 1º quartil, média, mediana, erro padrão, 3º quartil, valor máximo, coeficientes de: variação, assimetria e curtoses e valor de p da estatística do teste normalidade de Shapiro-Wilk. Também foram realizadas análises geoestatísticas através do software R.

4. RESULTADOS E DISCUSSÕES

A KR juntamente com o método do balanço de massa de cloreto foi utilizada por Crosbie et al. (2018) para estimaram a recarga da água subterrânea. O método combinado foi elaborado com a finalidade de aumentar as estimativas pontuais de recarga usando o balanço de massa de cloreto para obter estimativas robustas e sua

incerteza associada. O estudo foi feito nas bacias de carvão orientais de New South Wales (Austrália) e apontou que a recarga é menor nas Unidades Permianas (~1% da precipitação) e maior em aquíferos produtivos, como as dunas costeiras (acima de 100 mm/ano), Arenito Hawkesbury (até 100 mm/ano) e Arenito Pilliga (até 10 mm/ano).

O método de KR foi aplicada por De Laco et al. (2017) para a modelagem e predição das concentrações do gás radônio (Rn) no solo do distrito de Lecce, região da Apúlia na Itália. Também realizaram uma análise comparativa entre as técnicas de interpolação espacial KR e KO, baseados em covariáveis obtidas por SIG. A análise revelou que ao serem comparados, a utilização do método de KR melhora a confiabilidade das estimativas. O estudo apontou que a maior parte das regiões com altos níveis de concentração de Rn no solo estão localizadas em áreas residenciais, bem urbanizadas e com grande número de edifícios de escolas públicas, principalmente creches e escolas primárias.

As técnicas de KO e KR foram utilizadas por Menezes et al. (2016) para avaliar as propriedades físico-químicas do solo na camada superficial. Ao realizarem o estudo em duas bacias com diferentes características, concluíram que em áreas com alta correlação linear entre covariáveis ambientais e atributo do solo, a KR foi quem melhor performou.

A KR também foi utilizada para descrever solos baseados em dados de sensoriamento remoto obtidos de um campo de algodão do Mississippi, EUA. O estudo realizado por Ge et al. (2011) apontou que se agregado devidamente a correlação espacial dos resíduos de regressão, o modelo KR apresenta aptidão para futuras aplicações em agricultura de precisão, como o mapeamento digital de solos e o desenvolvimento de sensores de solo em tempo real.

Pelos resultados da tabela 1 dos coeficientes de assimetria das variáveis, percebe-se que estas apresentam distribuições levemente assimétricas a direita, exceto a variável areia que apresenta uma assimetria mais forte. Como são dados de um experimento a campo, não se espera que os dados sigam uma distribuição normal, o que é confirmado pelo valor de p do teste de normalidade de Shapiro-Wilk,

mas pode-se concluir que estas variáveis apresentam uma assimetria moderada o que é suficiente para aplicação das técnicas geoestatísticas.

Tabela 1- Estatísticas Descritivas das variáveis Argila, Areia Total, H_AI, Silte, SM

Estatísticas	Variáveis				
	Argila	Areia Total	H_AI	Silte	SM
N	349	349	349	349	349
Mínimo	49,00	97,82	0,87	0,50	14,00
Q1(1º Quartil)	187,00	345,40	1,82	12,80	520,00
Média	333,00	575,47	2,77	90,98	2273,00
Mediana	302,00	629,80	2,50	53,80	1427,00
Erro-padrão	9,09	13,30	0,06	4,87	107,00
Q3(3º Quartil)	494,00	96,90	3,43	151,20	3960,00
Máximo	665,00	945,06	7,20	403,12	7458,00
CV(%)	50,90	43,20	42,10	100,00	87,80
Assimetria	0,14	-0,33	0,77	1,00	0,61
Curtose	-1,70	-1,20	0,28	0,02	-0,90
Valor de p¹	0,0	0,00	0,00	0,00	0,00

¹ – valor de p do teste de normalidade de Shapiro-Wilk

Os altos valores dos coeficientes de variação de todas as variáveis deste estudo, evidenciam a necessidade de se utilizar técnicas geoestatísticas para entender melhor a variabilidade espacial destas variáveis nesta área.

A Figura 3 apresenta e ilustra as correlações entre as variáveis Argila, Areia Total, H_AI, Silte e SM. Os resultados apresentados na última coluna desta Figura 3 mostram as altas correlações entre as variáveis e a SM, ou seja, 0,89 com Argila, - 0,92 com Areia Total, 0,69 com H_AI, e 0,85 com Silte. Estas altas correlações é uma condição fundamental para a aplicação da técnica da KR.




Figura 3 – Painel dos gráficos de dispersão, histogramas e correlações entre as variáveis Argila, Areia Total, H_AI, Silte e SM.

A tabela 2 apresenta as estimativas dos coeficientes da regressão, intercepto e coeficiente da inclinação com seus respectivos valores de p do teste t-student destes coeficientes e o coeficiente de determinação R^2 do ajuste linear.

Tabela 2 - Com resultados da regressão SM com Argila, Areia Total, H_AI, Silte.

VARIÁVEL	a	b	R ²
Argila X SM	1,611*	7,576*	0,7895
Areia X SM	835,7413*	0,1147*	0,8397
H_AI X SM	1,855*	3,99E-04*	0,4779
Silte X SM	2,8649 ^{NS}	0,0389*	0,7198

a – intercepto, b – coeficiente da inclinação e R² coeficiente de determinação do ajuste.

Todos os coeficientes da inclinação das retas ajustadas são significativos ($p < 2,00 \times 10^{-16}$), ou seja, a relação linear existe as variáveis Argila, Areia Total, H_AI,

Silte com SM. Somente a estimativa do intercepto da regressão entre Silte x SM não foi significativo ($p=0,481$), para este ajuste o intercepto pode ser considerado nulo.

A tabela 3 apresenta os modelos de variogramas ajustados às variáveis SM, Argila, Areia, H_AI e Silte, isoladamente, bem como, estas mesmas variáveis com a SM como covariável. O modelo esférico foi o modelo que melhor se ajustou aos variogramas experimentais das variáveis segundo os critérios da menor soma de quadrados dos resíduos do ajuste.

As variáveis Argila, Areia e SM apresentaram um forte grau de aleatoriedade com estimativas de 11,89 e 9,91 e 0, respectivamente. As outras variáveis Argila com SM, Areia com SM, H_AI, H_AI com SM, Silte, Silte com SM apresentaram grau de aleatoriedade mediana.

Tabela 3- Variogramas ajustados às variáveis Argila, Argila com SM, Areia Total, Areia Total com SM, H_AI, H_AI com SM, Silte, Silte com SM e SM.


Variável	Modelo	C_0	C_1	$a(m)$	$C_0/(C_0+C_1)$ (%)	SQR
Argila	Esférico	1573,518	11661,581	1283,802	11,89	16455,95
Argila X SM	Esférico	2798,9400	2724,4800	1616,070	50,67	2406,10
Areia	Esférico	2584,696	23507,231	1454,647	9,91	42865,22
Areia X SM	Esférico	2634,9400	5013,0020	671,617	34,45	17619,89
H_AI	Esférico	0,4016	0,4053	1495,888	49,77	1,807e-05
H_AI X SM	Esférico	0,4190	0,2118	1045,548	66,42	2,00E-05
Silte	Esférico	961,474	2840,505	1420,978	25,29	1362,31
Silte X SM	Esférico	1037,1140	1068,2610	744,383	49,26	358,06
SM	Esférico	0	5297949	2649,100	0	2254191570

C_0 = efeito pepita; C_1 = patamar; a_{max} = alcance; $C_0/(C_0 + C_1)$ = grau de aleatoriedade; SQR = soma dos quadrados dos resíduos.

Para as variáveis analisadas, o melhor modelo ajustado para todas as variáveis foi o modelo esférico, considerando que este modelo tem a menor soma de quadrados para todas as variáveis. O grau de aleatoriedade, $C_0/(C_0 + C_1)$,

apresentou estimativas forte (<25%) para as variáveis Argila, Areia Total e SM e estimativas de grau de aleatoriedade moderada dependência espacial, entre 25% e 75%, para as variáveis Argila com SM, Areia com SM, H_AI, H_AI com SM, Silte e Silte com SM. Estes modelos ajustados aos variogramas experimentais foram posteriormente usados nas técnicas de krigagem ordinária (KO) ou krigagem simples (KS).

A Figura 4, abaixo, ilustra graficamente os ajustes dos modelos dos variogramas experimentais apresentados na tabela3.

















Figura 4 – Gráficos dos variogramas experimentais modelados das variáveis: a) SM, b) Argila, c) Argila com SM, d) Areia, e) Areia com SM, f) H_AI, g) H_AI com SM, h) Silte, e i) Silte com SM.

Os mapas espaciais das variáveis SM, Argila, Argila com SM, Areia, Areia com SM, H_AI, H_AI com SM, Silte, e Silte com SM, obtidos pelas técnicas da KO e KS e da KR, são apresentados na Figura 5. Assim, pode-se visualizar os mesmos padrões de comportamento das variabilidades espaciais das variáveis Argila, Argila com SM, Areia, Areia com SM, H_AI, H_AI com SM, Silte, e Silte com SM com o mapa da variabilidade espacial da SM. Estes mapas espaciais são uma forma de se ver, espacialmente, as altas correlações entre as variáveis e a SM, estimadas pela estatística clássica na área estudada.








Figura 5 –Mapas de Krigagem simples da SM (a) e das variveis Argila (b), da Argila com a covarivel SM (c), Areia total (d), Areia total com a covarivel SM (e), H_AI (f), H_AI com a covarivel SM (g), Silte (h) e Silte com a covarivel SM (i).

No geral notamos que, para as variveis que apresentam correlao positiva com a varivel SM, a parte superior (norte), a parte intermediria e a parte inferior (sul) destes mapas, apresentam os altos valores, os valores medianos e os baixos de valores, os quais coincidem com altos valores, com os valores medianos, e com baixos valores da covarivel SM nas mesmas regies dos mapas. Somente com a varivel Areia Total, cuja correlao  negativa com a covarivel SM, esta situao nos mapas se inverte.

Esse fenmeno pode ser explicado por diversos fatores, incluindo material de origem do solo presente na rea ou at mesmo a declividade da rea em estudo, mostrando que a tcnica tem potencial para realizar o mapeamento dos atributos utilizando a SM como covarivel.

Os resultados da validao apresentados na tabela 4 mostram que quase todas as medidas dos erros da KR apresentaram valores menores dos erros da KO ou KS, exceto a REMQ para a varivel Areia total e o EM, e a REMQ para a varivel Silte destacados em negrito na tabela 4, os quais foram menores que os valores

correspondentes da KO e da KS. Assim, de uma maneira geral, as estimativas pela KR com a covariável SM mostram-se mais eficiente do que as estimativas da KO e da KS das variáveis isoladamente.

Tabela 4- Valores da validação da Krigagem Ordinária e krigagem de regressão: SM das variáveis Argila, Areia Total, H_{Al} e Silte.

Técnicas de Krigagem	Erro Médio (EM)	Erro Médio Quadrático (EMQ)	Razão do Erro Médio Quadrático (REMQ)
KO Argila	13,1114	9767,3322	2,4612
KR Argila X SM	7,089	8411,4400	2,3177
KO Areia Total	16,4246	17527,4185	2,5912
KR Areia Total X SM	15,7748	15853,9372	3,2724
KO H_{Al}	0,2351	0,6349	1,1727
KR H_{Al} X SM	0,1813	0,6067	1,1481
KO Silte	0,4853	1594,3592	1,0379
KR Silte X SM	-1,8386	1705,5612	1,1145

A validação cruzada fornece um meio de escolher entre modelos permissíveis para variogramas. Isso é possível a partir dos valores de erros. Assim, para os valores de EM, o ideal é que este seja próximo de 0, entretanto a krigagem nesse caso é imparcial, o que não auxilia muito neste estudo. Já a EMQ proporciona um melhor diagnóstico, mas caso seja necessário escolher um dos três critérios, o melhor seria o REMQ, que deve alcançar um valor próximo a 1. Assim, possibilitando conferir o melhor modelo do variograma utilizado, o que pode ser observado na tabela 4.

5. CONCLUSÕES

- Os erros da validação cruzada por meio da KR foram, de forma geral, menores na área de estudo quando comparados a KO;
- A KR se mostrou muito robusta no mapeamento da variabilidade espacial das variáveis do solo estudadas neste trabalho;
- A utilização da suscetibilidade magnética como covariável nas estimativas por krigagem dos atributos de solo para auxiliar no delineamento de unidades de mapeamento, bem como na readequação dos limites entre unidades de solo

incorporando simultaneamente informações sobre a variabilidade espacial destes atributos se mostrou promissora.

6. REFERÊNCIAS

Andriotti, J. L. S. Introdução à Geoestatística. Acta Geologica. Acta Geológica Leopoldensia, São Leopoldo, v. 11, n.27, p. 5-81, 1988.

Angelico, J. C. (2006). Desempenho da co-krigagem na determinação da variabilidade de atributos do solo. Revista Brasileira de Ciência do Solo, 30(6), 931-936.

Barbosa, R. S. Erodibilidade de Latossolos predita pela suscetibilidade magnética e espectroscopia de reflectância difusa. 2014. 65 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 2014.

Barrón, V.; Mello, J. W. V.; Torrent, J. Caracterização de óxidos de ferro em solos por espectroscopia de Reflectância Difusa. In: Novais, R. F.; Alvarez, V. V. H.; Schaefer, C. E. G. R. (Ed.). Tópicos em ciência do solo, Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. p.139-162.

Becegato, V. A., Ferreira, F. J. F. Gamaespectrometria, resistividade elétrica e suscetibilidade magnética de solos agrícolas no noroeste do estado do Paraná. Revista Brasileira de Geofísica, v.23, p.371–405, 2005.

Bishop, T F A e McBratney, A B, 2001. A comparison of prediction methods for the creation of field-extent soil property maps, Geoderma, 103:149-160.

Bottega, E. L.; Bottega, S. P.; Silva, S. de A.; Queiroz, D. M. de; Souza, C. M. A. de; Rafull, L. Z. L. Variabilidade espacial da resistência do solo à penetração em um Latossolo Vermelho distroférico. Revista Brasileira de Ciências Agrárias, v.6, n.2, p. 331- 336, 2011.

Bottega, E. L., Queiroz, D. M., Pinto, F. A. C., & Souza, C. M. A. (2013). Variabilidade espacial de atributos do solo em sistema de semeadura direta com rotação de culturas no cerrado brasileiro. *Revista Ciência Agronômica*, 44(1), 1-9.

Brenning, A., Koszinski, S., Sommer, M. Geostatistical homogenization of soil conductivity across field boundaries. *Geoderma*, Amsterdam, v.143, p.254-260, 2008.

Bui, E. A review of digital soil mapping in Australia. In: Lagacherie, P.; McBratney, A.B.; Voltz, M. (Ed.). *Digital soil mapping: an introductory perspective*. Amsterdam: Elsevier, 2007. p.25-37.

Camargo, E. C. G. Geoestatística: fundamentos e aplicações. In: Câmara, G. & Medeiros, J.S. eds. *Geoprocessamento para projetos ambientais*. São José dos Campos: INPE, 1998. Disponível em: http://www.dpi.inpe.br/gilberto/tutoriais/gis_ambiente/5geoest.pdf.

Camargo, L. A. Mineralogia da argila por difração de raios x e espectroscopia de reflectância difusa em Latossolos sob diferentes superfícies geomórficas. 2013. 125 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 2013.

Camargo, L.A., Marques Jr, J., Pereira, G.T, Bahia, A.S.R.S., 2014. Clay mineralogy and magnetic susceptibility of Oxisols in geomorphic surfaces. *Sci. Agric.* 71, 244-256.

Campinas, D. do S. N.; Farias, P. R. da S.; Lima, H. V. de; Oliveira, F. J. de. Variabilidade espacial dos atributos físicos de solos em dois sistemas de manejo na Amazônia Oriental. *Revista Científica Eletrônica de Agronomia*, Garça, v.24, n.2, p.78-87, dez. 2013.

Campos, M.C.C., Marques Jr., J., Pereira, G.T., Souza, Z.M., Barbieri, D.M., 2008. Fertilizer and limestone applications after the harvest of sugarcane as determined by geostatistics techniques. *Cienc. Rural* 38, 974-980.

Carvalho, J. R. P., Da Silveira, P. M., & Vieira, S.R. (2002). Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos. *Pesquisa Agropecuária Brasileira*, 37(8), 1151-1159.

Carvalho, T. M. Modelagem digital de atributos de solo da Fazenda Edgárdia – Botucatu – SP. 145 f. 2016. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2016.

Castrignanò, A.; Costantini, E. A. C.; Barbetti, R.; Sollitto, D. Accounting for extensive topographic and pedologic secondary information to improve soil mapping. *Catena*, Amsterdam, v. 77, n. 1, p. 28-38, 2009.

Christensen, R., 2001. *Linear Models for Multivariate, Time Series, and Spatial Data*, 2nd Edition. Springer Verlag, New York, p. 393.

Craik, D. *Magnetism, Principles and Applications*, John Wiley and Sons, p. 1-459. 1995.

Cressie, N. A. C., 1993. *Statistics for Spatial Data*, revised edition. John Wiley & Sons, New York, p. 416.

Crosbie, R. S. et al. Estimating groundwater recharge and its associated uncertainty: Use of regression kriging and the chloride mass balance method. *Journal of Hydrology*, v. 561, p. 1 063-1080, 2018.

Costa, A.C.S., Bigham, J.M., Rhoton, F.E., Traina, S.J., 1999. Quantification and characterization of maghemite in soils derived from volcanic rocks in southern Brazil. *Clay. Clay. Miner.* 4, 466-473.

De Laco, S. et al. Radon Predictions with Geographical Information System Covariates: From Spatial Sampling to Modeling. *Geographical Analysis*, v. 49, p. 215 - 235, 2017.

Dearing, J. A. *Environmental magnetic susceptibility. Using the BartingtonMS2 System*. British Library, England. 1994. 104 p.

Dearing, J.A., Hay, K.L., Baban, S.M.K., Huddleston, A.S., Wellington, E.M. H., Loveland, P.J. Magnetic susceptibility of soil: an evaluation of conicting theories using a national data set. *Geophysical Journal International*, v.127, p.728–734, 1996.

Demattê, J.A.M., Galdos, M.V., Guimarães, R.V., Genú, A.M., Nanni, M.R., Zullo Jr., J. 2007. Quantification of tropical soil attributes from ETM+/LANDSAT -7 data. *Int. J. Remote Sens.* 28, 3813-3829

Dixon, B; Uddameri, V. *GIS and Geocomputation for Water Resource Science and Engineering*. West Sussex: Wiley, 2016. 568 p.

EMBRAPA, 1995. Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. Normative Procedures for SoilSurveys. Embrapa, Brasília. (in Portuguese).

EMBRAPA, 2007. Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. Manual ofsoilanalysismethods. Embrapa, Rio de Janeiro. (in Portuguese)

Englund, E. J.; Sparks, A. R. GEO-EAS (Geostatistical environmental assessment software) user's guide. Washington: Battelle Columbus Labs, 1991. 132 p. Disponível em: <https://www.epa.gov/water-research/geostatistical-environmental-assessment-software-geoeas>. Acesso em: jun. de 2022.

Forrester, A. I. J.; Sóbester, A.; Keane, A. J. *Engineering design via surrogate modelling: A practical guide*. University of Southampton. 2008. 218 p.

Garrity, D.P.; Agustin, P.C. Historical land use evolution in a tropical acid upland agroecosystem *Agriculture, Ecosystems and Environment*, Amsterdam, v.53, n.1, p.83- 95, 1995.

Ge, Y. et al. Regression-kriging for characterizing soils with remote sensing data. *Frontiers of Earth Science*, v. 5, p. 239–244, 2011.

Giacomin, G. et al. Análise comparative entre métodos interpoladores de modelos de superfícies. *Revista Brasileira de Cartografia*, v. 66, p. 1315-1329, 2014.

Gonzalez, O. J.; Zak, D. R. Geostatistical analysis of soil properties in a secondary tropical dry forest, St. Lucia, West Indies. *Plant and Soil*, Berlin, v.163, p. 45-54, 1994.

Goovaerts, P. *Geostatistics for Natural Resources Evaluation*. New York: Oxford University Press, 1997. 483 p.

Gotway, C. A., Stroup, W. W., 1997. A Generalized Linear Model approach to spatial data analysis and prediction. *Journal of Agricultural, Biological, and Environmental Statistics* 2 (2): 157–198.

Grimley, D.A., Arruda, N.K., Bramstedt, M.W. Using magnetic susceptibility to facilitate more rapid, reproducible, and precise delineation of hydric soils in the midwestern USA. *Catena*, Amsterdam, v.58, p.183–213, 2004.

Grimley, D.A., Vepraskas, M.J. Magnetic Susceptibility for Use in Delineating Hydric Soils. *Soil Science Society of America Journal*, Madison, v.64, p.2174-2180, 2000.

Grunwald, S.; Vasques, G.M.; Rivero, R.G. Fusion of soil and remote sensing data to model soil properties. *Advances in Agronomy*, v.131, p.1-109, 2015. DOI: 10.1016/bs.agron.2014.12.004.

Hengl, T. *A practical guide to geostatistical mapping*. 2 ed. Luxembourg: Office for Official Publications of the European Communities, 2009.

Hengl, T. et al. Comparison of kriging with external drift and regression-kriging: Technical note, ITC. Enschede, 2003.

Hengl, T. et al. Methods to interpolate soil categorical variables from profile observations: lessons from Iran. *Geoderma*, Amsterdam, v.140, p. 417-427, 2007.

Hengl, T.; Heuvelink, G. B. M.; Rossiter, D. G. About regression-kriging: from equations to case studies. *Elsevier*, v. 33, p. 1301-1315. 2007.

Hengl, T.; Jesus, J. M.; Macmillan, R. A.; Batjes, N. H.; Heuvelink, G. B. M.; Ribeiro, E.; Samuel-Rosa, A.; Kempen, B.; Leenaars, J. G. B.; Walsh, M. G.; Gonzalez, M. R.

SoilGrids1km — Global Soil Information Based on Automated Mapping. Plos One, San Francisco, v. 9, n. 8, 2014.

Hengl, T, Heuvelink, G B M e Stein, A, 2004. A generic framework for spatial prediction of soil variables based on regression-kriging, *Geoderma*, 120:75-93.

Huijbregts, C. J. Regionalized variables and quantitative analysis of spatial data. In: Davis, J. C.; McCullagh, M. J. (Eds.). *Display and analysis of spatial data*. New York: J. Wiley, 1975. p.38-53.

Johnson, C.K., Doran, J.W., Duke, H.R., Wienhold, B.J., Eskridge, K.M., Shanahan, J.F. Field-scale electrical conductivity mapping for delineating soil condition. *Soil Science Society of America Journal*, Madison, v. 65, p. 1829– 1837, 2001.

Kitanidis, P. K., 1994. Generalized covariance functions in estimation. *Mathematical Geology* 25: 525–540.

Knotters, M.; Brus, D.J.; Oude Voshaar, J.H. A comparison of kriging, co-kriging and kriging combined with regression for spatial interpolation of horizon depth with censored observations. *Geoderma*, v.67, p.227-246, 1995.

Kravchenko, A.N.; Robertson, G.P. Can topographical and yield data substantially improve total soil carbon mapping by regression kriging? *Agronomy Journal*, v.99, p.12-17, 2007. DOI:10.2134/agronj2005.0251.

Kumar, S. V.; Reichle, R. H.; Harrison, K. W.; Peters-Lidard, C. D.; Yatheendradas, S.; Santanello, J. A. A comparison of methods for a priori bias correction in soil moisture data assimilation. *Water Resources Research*, v.48, W03515, 2012.

Leal, F. T.; França, A. B. C.; Siqueira, D. S.; Teixeira, D. D. B.; Marques Jr., J.; La Scala Jr., N. Characterization of potential CO₂ emissions in agricultural areas using magnetic susceptibility. *Scientia Agricola*, Piracicaba, 2015.

Legros, J. P. Mapping of the soil. Science Pub Inc, 2006. 411 p.

Luque, E. C. L. Propiedades magnéticas de los óxidos de hierro en suelos mediterráneos. 2008. 179 f. Tese de doutorado - Escuela Técnica Superior de Ingenieros Agrónomos y de Montes, Universidad de Córdoba, Córdoba, 2008.

Mallarino, A. P.; Mazhar, U. H.; Wittry, D.; Bermudez, M. Variation in Soybean Response to Early Season Foliar Fertilization among and within Fields, *Agronomy Journal*, Madison, v. 93, n. 6, p.1220-1226, 2001.

Marques Jr, J. Caracterização de áreas de manejo específico no contexto das relações solo-relevo. 2009. 113 f. Tese (Livre-Docência) - Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 2009.

Marques Jr., J.; Siqueira, D. S.; Camargo, L. A.; Teixeira, D. D. B.; Barron, V.; Torrent, J. Magnetic susceptibility and diffuse reflectance spectroscopy to characterize the spatial variability of soil properties in a Brazilian Haplustalf. *Geoderma*, Amsterdam, v. 219-220, p. 63-71, 2014.

Matheron, G., 1969. Le krigeage universel. Vol. 1. Cahiers du Centre de Morphologie Mathématique, École des Mines de Paris, 79 Fontainebleau, p. NA.

McBratney, A. B.; Odeh, I. O. A.; Bishop, T. F. A.; Dunbar, M. S.; Shatar, T. M. An overview of pedometric techniques for use in soil survey. *Geoderma*, Amsterdam, v. 97, n. 3-4, p. 293-327, 2000.

McBratney, A.B., Minasny, B., Cattle, S.R., Vervoort, R.W., 2002. From pedotransfer functions to soil inference systems. *Geoderma* 109, 41–73.

McBratney, A. B.; Santos, M. L. M.; Minasny, B. On digital soil mapping. *Geoderma*, Amsterdam, v. 117, n. 1-2, p. 3-52, 2003.

Mello, C.R. Hidrologia: Princípios e Aplicações. Lavras: UFLA, 2013. 455 p.

Menezes, M. D. et al. Spatial prediction of soil properties in two contrasting physiographic regions in Brazil. *Scientia Agricola*, Piracicaba, v. 73, n. 3, p. 274- 285, May/June 2016.

Milone, G.; Angelini, F. Estatística aplicada. São Paulo: Atlas, 1995. 286 p.

Minasny, B.; ALEX, B.; McBratney, A. B.; Hartemink, A. E. Global pedodiversity, taxonomic distance, and the World Reference Base. *Geoderma*, Amsterdam, v. 155, n. 3-4, p. 132–139, 2010.

Minasny, B., McBratney, A. B., 2007. Spatial prediction of soil properties using EBLUP with Matérn covariance function. *Geoderma* 140: 324–336.

Odeh, I O A, McBratney, A B e Chittleborough, D J, 1994. Spatial prediction of soil properties from landform attributes derived from a digital elevation model, *Geoderma*, 63:197-214.

Odeh, I. O. A. et al. Further results on prediction of soil properties from terrain attributes: heterotopic cokriging and regression-kriging. *Geoderma*, Amsterdam, v. 67, n. 3/4, p. 215-226, 1995.

Oliveira, R. B.; Silva, S. A., Souza, G. S., Passos, R. R., Prezotti, L. C., & Lima, J. S. S. (2017). Análise espacial de variáveis indicadoras de fertilidade do solo sob cultivo de cafeeiro conilon. *Anais. X Encontro Latino Americano de Iniciação Científica e VI Encontro Latino Americano de Pós-Graduação – Universidade do Vale do Paraíba*, 2787-2790.

Omuto, C. T.; Vargas, R. R. Re-tooling of regression-kriging in R for improved digital mapping of soil properties. *Geosciences Journal*, v. 19, n. 1, p. 157-165, 2015.

Pebesma, E.J. The Role of External Variables and GIS Databases in Geostatistical Analysis. *Transactions in GIS*, v.10, p.615-632, 2006. DOI: 10.1111/j.1467-9671.2006.01015.x.

Peluco, R. G.; Marques Jr., J.; Siqueira, D. S.; Pereira, G. T.; Barbosa, R. S.; Teixeira, D. D. B. Mapeamento do fósforo adsorvido por meio da cor e da suscetibilidade magnética do solo. *Pesquisa Agropecuária Brasileira*, Brasília, v. 50, n. 3, p. 259-266, 2015.

Peluco, R. G.; Marques Jr., J.; Siqueira, D. S.; Pereira, G. T.; Barbosa, R. S.; Teixeira, D. D. B.; Adame, C. R.; Cortez, L. A. Suscetibilidade magnética do solo na estimação da capacidade de suporte à aplicação de vinhaça. *Pesquisa Agropecuária Brasileira*, Brasília, v. 48, n. 6, p. 661-672, 2013.

Pereira, G. T.; Souza, Z. M.; Teixeira, D. D. B.; Montanari, R.; Marques JR., J. Optimization of the sampling scheme for maps of physical and chemical properties estimated by kriging. *Revista Brasileira de Ciência do Solo*, Viçosa, v. 37, n. 5, p. 1128-1135, 2013.

Resende, M. D. V.; Sturion, J. A. Análise Genética de Dados com Dependência Espacial e Temporal no Melhoramento de Plantas Perenes via Modelos Geoestatísticos e de Séries Temporais Empregando REML/BLUP ao Nível Individual. Colombo: Embrapa Florestas, 2001, 79 p.

Rivero, R G, Grunwald, S e Bruland, G L, 2007. Incorporation of spectral data into multivariate geostatistical models to map soil phosphorus variability in a Florida wetland, *Geoderma*, 140:428-443.

Royall, D. Use of mineral magnetic measurements to investigate soil erosion and sediment delivery in a small agricultural catchment in limestone terrain. *Catena*, Amsterdam, v.46, p.15-34, 2001.

Sanchez, P. A.; Ahamed, S.; Carre, F.; Hartemink, A. E.; Hempel, J.; Huising, J.; Lagacherie, P.; McBratney, A. B.; McKenzie, N. J.; Mendonça-Santos, M. L.; Minasny, B.; Montanarella, L.; Okoth, P.; Palm, C. A.; Sachs, J. D.; Shepherd, K. D.; Vagen, T. G.; Vanlauwe, B.; Walsh, M. G.; Winowiecki, L. A.; Zhang, G. L. Digital soil map of the world. *Science*, v. 325, n. 5941, p. 680-681, 2009.

Sassi, C. P. et al. Modelos de regressão linear múltipla utilizando os softwares R e Statistica: uma aplicação a dados de conservação de frutas. São Carlos: ICMC-USP, n. 377, 2012. Disponível em: http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos_enviados/BIBLIOTECA_113_RT_377.pdf. Acesso em: ago. de 2021.

Schabenberger, O., Gotway, C., 2004. Statistical methods for spatial data analysis. Chapman & Hall/CRC, Boca Raton, FL, p. 524.

Scolforo, H. F. Interpoladores espaciais na estimativa da distribuição do estoque de carbono da vegetação arbórea em Minas Gerais, Brasil. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2014.

Silva, F.D., Couceiro, PR.C., Fabris, J.D., Goulart, A.T., Ker, J.C. Magnesioferrita e caminho pedogenético de transformação de óxidos de ferro magnéticos em dois perfis de solo derivados de tufito da Região do Alto Paranaíba (MG). Revista Brasileira de Ciência do Solo, Viçosa, v.29, p.763-775, 2005.

Siqueira, D.S., Marques JR., J., Pereira, G.T. The use of landform to predict the variability of soil and orange attributes. Geoderma v. 155, 55-66, 2010.

Siqueira, D. S. Mapeamento de atributos e planejamento amostral para Latossolos utilizando suscetibilidade magnética, cor e relação solo-paisagem. 2013. 109 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 2013.

Souza, Z. M. de; Marques JR., J.; Pereira, G. T. Variabilidade espacial de atributos físicos do solo em diferentes formas do relevo sob cultivo de cana-de-açúcar. Revista Brasileira de Ciência do Solo, v. 28, n. 6, p. 937-944, 2004.

Stein, M. L., 1999. Interpolation of Spatial Data: Some Theory for Kriging. Series in Statistics. 36 Springer, New York, 247 p.

Teixeira, D. D. B.; Bicalho, E. S.; Panosso, A. R.; Cerri, C. E. P.; Pereira, G. T.; La Scala, N. Spatial variability of soil CO₂ emission in a sugarcane area characterized by secondary information. Scientia Agricola, Piracicaba, v. 70, n. 3, p. 195-203, 2013b.

Teixeira, D. D. B. Suscetibilidade magnética e análise de incertezas em mapeamento de solos. Tese (Doutorado em Produção Vegetal) – Faculdade de Ciências Agrárias e veterinárias, Universidade Estadual Paulista, Jaboticabal, 2016.

Tobler, W. R. A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*, v. 46, p. 234, jun. 1970.

Vasques, G.M.; Grunwald, S.; Comerford, N.B.; Sickman, J.O. Regional modelling of soil carbon at multiple depths within a subtropical watershed. *Geoderma*, v.156, p.326-336, 2010. DOI: 10.1016/j.geoderma.2010.03.002.

Vicente, J. Estudo comparativo de métodos geoestatísticos aplicados em agricultura de precisão. 163 f. 2004. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciência e Tecnologia, Universidade Estadual Paulista, Presidente prudente, 2004.

Wang, Y.; Hou, S. A new interpolation method for Antarctic surface temperature. *Progress in Natural Science: Materials International*. v. 19, n. 12, p. 1843 - 1849, 2009.

Webster, R. Quantitative spatial analysis of soil in the field. *Advances in Soil Science*. New York, 3:1-70, 1985.

White, J. G.; Zasoski, R. J. Mapping Soil Micronutrients. *Field Crops Research*, Amsterdam, v. 60, n. 1-2, p. 11-26, 1999.

Yan, L I, Zhou, S H I, Ci-fang, W U, Hong-yi, L I e Fend, L I, 2007. Improved prediction and reduction of sampling density for soil salinity by different geostatistical methods, *Agricultural Sciences in China*, 6(7):832-841.