

MODELO EM ESPAÇO DE ESTADOS PARA O RELACIONAMENTO ENTRE ATRIBUTOS DO SOLO E PRODUTIVIDADE DA SOJA

STATE-SPACE MODEL FOR THE RELATIONSHIP BETWEEN SOYBEAN PRODUCTIVITY AND SOIL CHARACTERISTICS

MÁRCIO P. DE OLIVEIRA ¹

MARIA H. F. TAVARES ²

ROSANA K. NIEDZIALKOSKI ²

LUIS C. TIMM ³

¹ COMAT/UTFPR – Universidade Tecnológica Federal do Paraná – Brasil. Brasil. (e-mail: marcioliveira@utfpr.edu.br)

² CCET/UNIOESTE – Universidade Estadual do Oeste do Paraná – Brasil.

(e--mail: mhstavar@gmail.com; sanakrauss@hotmail.com)

³ Faculdade de Agronomia Eliseu Maciel/UFPEL – Universidade Federal de Pelotas – Brasil.

(e-mail: lctimm@ufpel.edu.br)

Resumo

O objetivo do presente trabalho é estudar o relacionamento entre os atributos do solo – conteúdo de fósforo, potencial hidrogeniônico e densidade do solo – com a produtividade da soja. As amostras foram coletadas em um Latossolo Vermelho, em área localizada no município de Braganey-PR, no Paraná, cultivada com soja (*Glycine Max L*). Na área experimental foram demarcados 84 elementos amostrais ao longo de uma transeção de 252 metros, com os elementos espaçados metros entre si. Para a análise da dependência espacial foram construídos autocorrelogramas, identificando-se correlação entre as observações de produtividade da soja, teor de fósforo, pH e densidade do solo. Na análise da dependência espacial cruzada foram empregados correlogramas cruzados, os quais mostraram dependência espacial cruzada entre produtividade da soja e pH. Os modelos estatísticos construídos para estimar a produtividade da soja foram os modelos autoregressivos em Espaço de Estados e o modelo de regressão linear simples. A análise realizada mostrou que o modelo em Espaço de Estados foi mais eficiente em comparação com o modelo de regressão linear simples.

Palavras-chave: autocorrelação, correlação cruzada, dependência espacial.

Abstract

The objective of this study was to assess the relationship between soybean productivity and soil chemical properties. The experimental data were obtained at a Rhodic Acrudox soil, from Braganey County, State of Parana, in an area where soybean was grown. The data sets were sampled along 84 points on a 254 meters long spatial transect, 3 m spaced from each other. At each site, soybean crop samples were collected for yield quantification and soil samples were collected in the 0.10 - 0.20 m deep layer. At the experimental area, the samples were sampled along 84 points on a spatial transect, 3.0 meters spaced from each other. The State-Space approach was used to assess soybean yield estimate on position i , influenced by soybean yield, pH and phosphorus on position $i-1$. With the implementation of a space of states, only the variable pH showed significant correlation at 5% significance level, with the dependent variable, with the coefficient R^2 equal to 0.852. This does possible to show the influence of independent variable pH on the response variable, which is the soybean yield. With the implementation of a space of states, only the variable pH showed significant correlation at 5% significance level, with the dependent variable, with the coefficient R^2 equal to 0.852.

Keywords: autocorrelation, cross correlation, spatial dependence.

1. Introdução

O Brasil é destaque mundial na produção de soja, sendo atualmente o segundo maior produtor mundial do grão. Para que o país preserve esta produtividade e venha a aumentá-la, é importante o manejo adequado da fertilidade do solo, pois esta afeta de maneira direta a aptidão agrícola das terras.

Uma abordagem empregada pelos pesquisadores ligados à área agronômica estuda a variabilidade das propriedades do solo por meio da estatística clássica, desconsiderando sua localização na área. No entanto, estudos indicam que observações adjacentes de alguns atributos do solo são não independentes. Assim, a dependência

espacial dos dados deve ser considerada na análise estatística dos dados (Timm *et al.*, 2004).

Segundo Reichert *et al.* (2008), a variabilidade dos atributos do solo, muitas vezes, não é puramente aleatória, mas apresenta dependência espacial ocasionada por diversos fatores, agindo em diferentes escalas no espaço e no tempo.

Li *et al.* (2002) destacaram a importância de se estudar tanto a variabilidade espacial quanto a variabilidade temporal dos atributos do solo, ressaltando que elas também devem ser levadas em consideração no momento de se incorporar novos procedimentos e tecnologias à agricultura. Para que isso ocorra de forma eficiente, é necessário utilizar técnicas estatísticas como os modelos em Espaço de Estados, os quais permitam estudar ambas as variabilidades dos dados obtidos em campo.

A dependência da produtividade do algodão com os atributos químicos e físicos de um solo amarelo arenoso na camada de 0,0-0,30 m, estudada por meio de modelos em Espaço de Estados, permitiu uma descrição da associação destes atributos, de modo a obter um manejo eficiente do conteúdo de água e do nitrogênio do solo para a produtividade do algodão (Li *et al.*, 2001).

Mello *et al.* (2006), em estudo realizado sobre solo Argiloso Vermelho-Amarelo com atributos químicos e físicos, identificaram dependência espacial entre as observações de fósforo (P) e potencial hidrogeniônico (pH) na camada 0,0–0,20 m.

Johann *et al.* (2004), com o emprego de modelos de semivariogramas, identificaram estrutura de dependência espacial das variáveis produtividade da soja, densidade do solo, teor de água no solo e resistência do solo a penetração nas camadas 0,0-0,10 m, 0,10-0,20 m e 0,20-0,30 m em um Latossolo Distroférico.

O método de estimação pelos modelos em Espaço de Estados ou modelo de regressão linear dinâmico pode ser usado para avaliar a estimativa da produtividade de culturas por meio da relação entre vizinhos bem como da relação entre vizinhos das variáveis relacionadas ao processo (Joschko *et al.*, 2009).

A modelagem em Espaço de Estados de um processo espacial ou temporal linear ou não linear fornece uma estimativa adequada da variável dependente, bem como intervalos de confiança e resíduos por meio da consideração das diferenças na densidade das observações entre as variáveis (Wang *et al.*, 2009)

Nesse contexto, a abordagem em Espaço de Estados pode ser empregada como um recurso adicional na agricultura de precisão, na obtenção de estimativas por interpolação espacial ou temporal de dados (Timm *et al.*, 2004).

O objetivo deste trabalho foi analisar a variabilidade espacial dos atributos químicos do solo fósforo (P) e potencial hidrogeniônico (pH) e do atributo físico densidade do solo (DS) bem como a produtividade da soja (PD) e estudar por meio dos

modelos em Espaço de Estados e de regressão linear simples a relação entre a PD e os atributos do solo P, pH e DS.

2. Material e métodos

A área experimental onde foi realizada a coleta dos dados está localizada no município de Braganey-PR, coordenadas 24°54'45'' latitude Sul e 53°08'46'' longitude Oeste de Greenwich, altitude 750 m. O clima da região é temperado mesotérmico e super-úmido. O solo da região foi classificado como Latossolo Vermelho Distroférrico, substrato basalto e relevo suavemente ondulado (EMBRAPA, 2006).

A área do experimento vem sendo cultivada há mais de cinco anos em sistema de plantio direto. A soja (*Glycine Max L*), variedade Dom Mário transgênica, foi semeada no dia 20 de outubro de 2008 e colhida entre os dias 14 e 16 de março de 2009.

Na área experimental foi traçada uma transeção de 252 m, onde foram delimitados 84 elementos amostrais espaçados 3 m entre si, demarcados com o auxílio de uma trena e georreferenciados com auxílio de um aparelho GPS.

As amostras de solo foram coletadas nos 84 elementos amostrais, na profundidade de 0,0-0,20 m, para realização da análise química do solo. As amostras foram secas ao ar livre, destorroadas, passadas na peneira 0,02 m e estocadas para obtenção dos parâmetros.

As amostras de solo foram analisadas para potencial hidrogeniônico (pH) em CaCl_2 0,01 mol L⁻¹, na proporção 1: 2,5 e conteúdo em fósforo (P), com técnicas descritas por Raij *et al.* (2001).

A produtividade da soja foi avaliada através da coleta de amostras em cada um dos 84 elementos amostrais, com a unidade de análise correspondente a uma área de 1 m quadrado. Após a coleta, a soja foi trilhada e peneirada manualmente. A umidade dos grãos foi determinada pelo método padrão da estufa (Mara, 1992). Posteriormente, foi determinada a produtividade da soja, considerando apenas a quantidade de massa seca.

A autocorrelação entre as variáveis $Z_j(x_i)$ na posição x_i com $Z_j(x_i + h)$ na posição $x_i + h$, pode ser determinada pelas Equações (1) e (2):

$$C_j(h) = \frac{1}{(n-1-h)} \left[\sum_{i=1}^{n-h} (Z_j(x_i) - \bar{Z}_j(x))(Z_j(x_i + h) - \bar{Z}_j(x)) \right] \quad (1)$$

$$r_j(h) = \frac{C_j(h)}{S^2} \quad (2)$$

em que $C_j(h)$ é a covariância entre as variáveis $Z_j(x_i)$ e $Z_j(x_i + h)$, n é o número de pares $Z_j(x_i)$ e $Z_j(x_i + h)$ separados pela distância h , $\bar{Z}_j(x)$ é a média aritmética

da variável $Z_j(x)$, $r_j(h)$ é coeficiente de autocorrelação amostral dos pares da variável $Z_j(x_i)$, com $-1 \leq r_j(h) \leq 1$ e S^2 a variância amostral de $Z_j(x_i)$ (Reichardt & Timm, 2008). O coeficiente de correlação cruzada amostral ($r_{ju}^c(h)$) para os pares de variáveis distintas $Z_j(x_i)$ e $Z_u(x_i)$ observadas no ponto x_i , separadas por uma distância h , foi determinada pela Equação (3):

$$r_{ju}^c(h) = \frac{C(Z_j(x_i), Z_u(x_i + h))}{\sqrt{S_{z_j}^2 S_{z_u}^2}} \quad (3)$$

em que $C(Z_j(x_i), Z_u(x_i + h))$ é a covariância entre $Z_j(x_i)$ e $Z_u(x_i + h)$, $S_{z_j}^2$ é a variância amostral da variável $Z_j(x_i)$ e $S_{z_u}^2$ é a variância amostral da variável $Z_u(x_i)$ (Reichardt & Timm, 2008).

Para determinar os limites dos intervalos de confiança (IC) de autocorrelação e de correlação cruzada é aplicada a função de probabilidade acumulada p ($p = \pm 1,96$ para 95% confiança) para a função de distribuição normalizada (Davis, 1986; Nielsen & Wendroth, 2003) com o número de observações n , temos a Equação (4):

$$CI = \pm \frac{p}{\sqrt{n}} \quad (4)$$

Os conjuntos de dados na abordagem de espaço de estados foram normalizados por meio da Equação (5):

$$Z_j^*(x_i) = \frac{[Z_j(x_i) - (m - 2S)]}{4S} \quad (5)$$

em que $Z_j^*(x_i)$ é o dado normalizado, $Z_j(x_i)$ é o dado medido, m é a média amostral e S o desvio padrão amostral de $Z_j(x_i)$. Os dados usados na abordagem em Espaço de Estados foram analisados utilizando-se o programa Applied Statistical Time Series Analysis (ASTSA), desenvolvido por Shumway & Stoffer, 2000.

2.1 Modelos

O modelo em Espaço de Estados é uma forma de representar um sistema linear ou não a partir de um sistema de duas equações dinâmicas. A forma pela qual o vetor das observações $Y(x_i)$ do processo é gerado em função do vetor de estado não

observado $Z(x_i)$, denominada equação das observações, dado pela Equação (6) para cada elemento x_i , com $i = 1, \dots, n$:

$$Y(x_i) = M_{pp} Z(x_i) + v_i \quad (6)$$

em que o elemento do vetor de observação $Y(x_i)$ é relacionado ao vetor de estado $Z(x_i)$ através do i -ésimo elemento da matriz de observação M_{pp} e por um erro (ou ruído) de observação v_i .

A evolução dinâmica do vetor de estado não observado $Z(x_i)$, denominada equação de estado ou do sistema dado pela Equação (7), para cada elemento $i, i=1, \dots, n$:

$$Z(x_i) = \phi_{ii} Z(x_{i-1}) + w_i \quad (7)$$

em que o elemento do vetor de estado $Z(x_i)$ na posição x_i é relacionado ao mesmo na posição $(i-1)$ por meio dos elementos da matriz dos coeficientes de estado ϕ_{pp} (matriz de transição) e um erro (ou ruído) associado ao estado w_i .

Segundo Hui *et al.* (1998), quando os dados são transformados por meio da Equação (5), os coeficientes da matriz de transição tem magnitudes diretamente proporcionais à sua contribuição em cada variável de estado usada na análise.

Assume-se que os erros v_i e w_i são variáveis aleatórias normalmente distribuídas, independentes e não correlacionados entre si para todas as defasagens, com média zero e variância constante.

A formulação de um modelo de regressão linear pode ser apresentada de forma teórica pela Equação (8):

$$Y(x_i) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + e_i \quad (8)$$

em que $Y(x_i)$ é a variável explicativa, β_0 , β_1 e β_2 são os parâmetros, X_1 e X_2 as variáveis explicativas e e_i o erro do modelo.

2.2 Eficiência do modelo

Um modo de comparar a qualidade de diferentes modelos é definido por Akaike (1973) e pode ser adaptado para técnicas de regressão. O critério é baseado nos resíduos entre os valores observados e estimados, pela Equação (9), como:

$$QMR = \frac{1}{n} \sum_{i=1}^n [Y(x_i) - Y(x_i)^*]^2 \quad (9)$$

O Critério de Informação de Akaike (AIC) considera o número de coeficientes de regressão k e o número de observações n , conforme a Equação (10):

$$AIC = \ln(QMR) + \frac{2k}{n} \quad (10)$$

3. Resultados e discussão

As medições de produtividade da soja (PD) tiveram um valor médio de 2,78 t ha⁻¹ (Tabela 1), em termos de massa seca, haja vista que o acúmulo de matéria seca é responsável pela produtividade das culturas, e a produtividade da soja foi mensurada por meio da massa seca dos grãos de soja. O coeficiente de variação (CV) de 15,45 % indica uma distribuição de dados com homogeneidade.

As observações da variável conteúdo em fósforo (P) apresentaram CV de 34,52% (Tabela 1), o que indica heterogeneidade dos dados em relação média de 2,40 mg dm⁻³.

O potencial hidrogeniônico (pH), com CV de 7,05% (Tabela 1), indica uma distribuição de dados homogênea em torno da média de 5,79.

A densidade do solo (DS) apresentou valor médio de 1,24 m³ m⁻³. A homogeneidade da série de dados dessa variável foi identificada pelo coeficiente de variação com valor de 0,03%.

O teste de Kolmogorov-Smirnov indicou que os dados de produtividade da soja, pH e fósforo possuem distribuição normal de probabilidade, ao nível de 5 % de significância.

Tabela 1. Estatística descritiva das variáveis produtividade da soja (PD), conteúdo em fósforo (P) e potencial hidrogeniônico (pH).

Variável	N	Média	DP	CV (%)	Mínimo	Máximo	Normal (KS)
PD (t ha ⁻¹)	84	2,78	0,43	15,45	1,81	3,79	Sim
P (mg dm ⁻³)	84	2,40	0,83	34,52	1,09	4,54	Sim
pH	84	5,79	0,40	7,05	4,88	6,73	Sim
DS (m ³ m ⁻³)	84	1,24	0,04	0,03	1,13	1,37	Sim

DP – Desvio Padrão; CV – Coeficiente de Variação; KS – Teste de normalidade de Kolmogorov-Smirnov com 5% de significância

A Figura 1 apresenta a distribuição espacial das observações das series de dados das variáveis produtividade da soja (Figura 1A), conteúdo em fósforo (Figura 1B), potencial hidrogeniônico (Figura 1C) e densidade do solo (Figura 1D). Para as variáveis PD, P, pH e DS se observa que os valores das variáveis ao longo da transeção apresentam oscilação, com uma tendência crescimento/decrescimento em torno da média, linha pontilhada horizontal, ao longo dos elementos amostrais, o que indica comportamento estacionário das séries de dados.

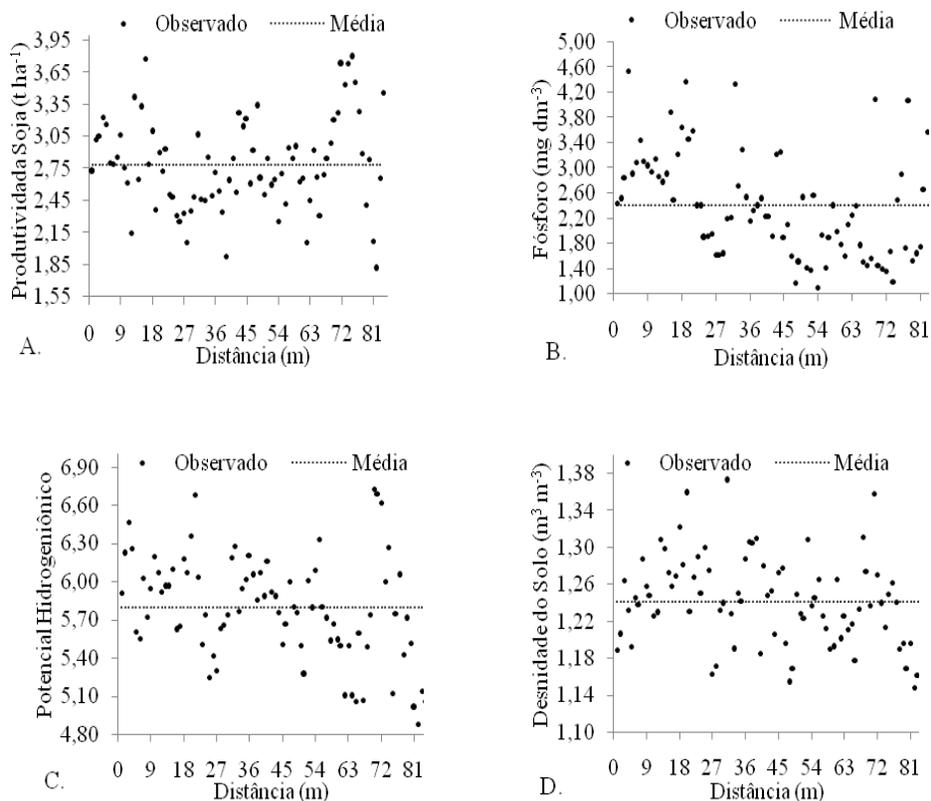


Figura 1. Séries de dados observados das variáveis produtividade da soja (A), fósforo (B), potencial hidrogeniônico (C) e densidade do solo (D) ao longo da transeção.

Nos autocorrelogramas (Figura 2), as linhas tracejadas horizontais representam os limites das bandas com nível de 95% de confiança. Os valores dos coeficientes acima e abaixo desses limites indicam a correlação entre as observações das variáveis.

A variável PD (Figura 2A) apresenta correlação de ordem 3, o que indica

dependência espacial de até 9 m entre as observações. Johan *et al.* (2004) também encontraram dependência espacial para PD em um mesmo tipo de solo.

A variável conteúdo em fósforo (Figura 2B) apresentou correlação de ordem 3, indicando dependência espacial de até 9 m entre as observações.

A variável pH (Figura 2C) apresentou correlação de ordem 2 com dependência espacial até 6 m entre as observações. A dependência espacial das variáveis fósforo e pH também foi identificada por Mello *et al.* (2006) em estudo sobre Argissolo Vermelho-Amarelo.

No caso da variável DS (Figura 2D) a correlação obtida foi de ordem 1, o que indica uma dependência espacial de 3 m. A estrutura de dependência espacial da DS também foi identificada por Johan *et al.* (2004).

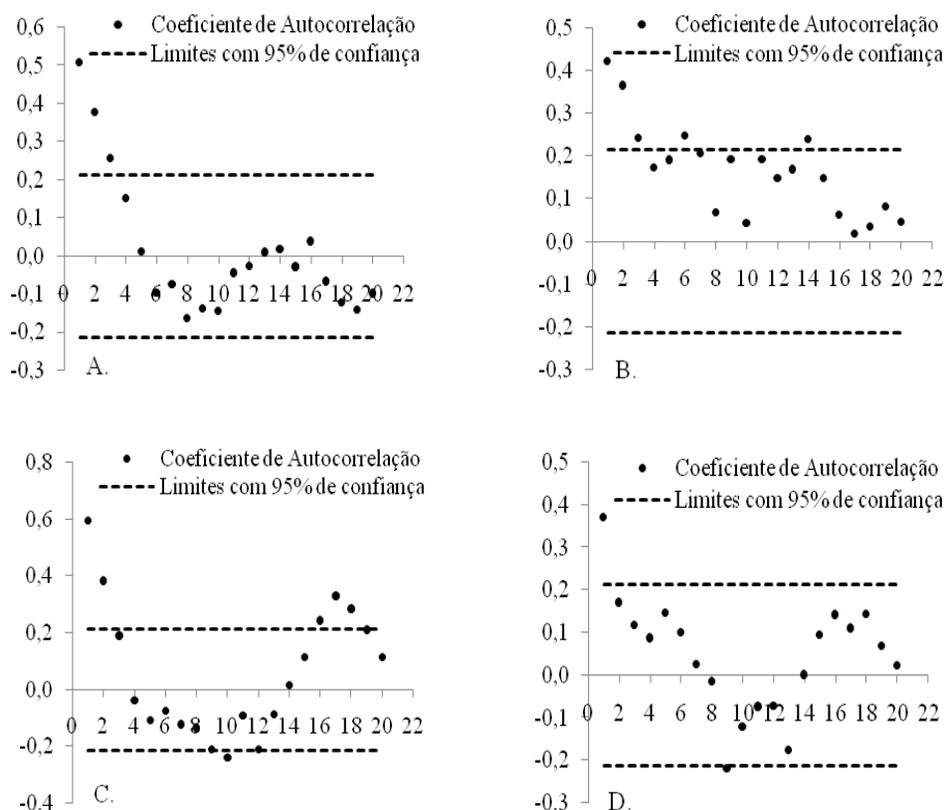


Figura 2. Acorrelogramas para as séries de dados das variáveis produtividade da soja (A), fósforo (B), potencial hidrogeniônico (C) e densidade do solo (D).

Nos correlogramas cruzados (Figura 3), as linhas tracejadas paralelas ao eixo horizontal representam os limites das bandas de confiança ao nível de 95%.

O correlograma cruzado entre as variáveis PD e P (Figura 3A) identificou ausência de correlação entre as observações dessas variáveis com 5% de significância.

O correlograma cruzado das variáveis PD e pH (Figura 3B) indica que as duas variáveis apresentam uma correlação cruzada de ordem 1, o que indica que as observações de PD e pH possuem dependência espacial de até 3 m com 5% de significância. O resultado obtido foi semelhante ao apresentado por Reichert *et al.* (2008) em um estudo sobre a relação entre pH e produtividade da soja em um Planossolo Hidromórfico Distrófico típico.

No caso do correlograma cruzado entre as variáveis PD e DS (Figura 3C), não foi identificada correlação entre as observações dessas variáveis ao nível de 5% de significância.

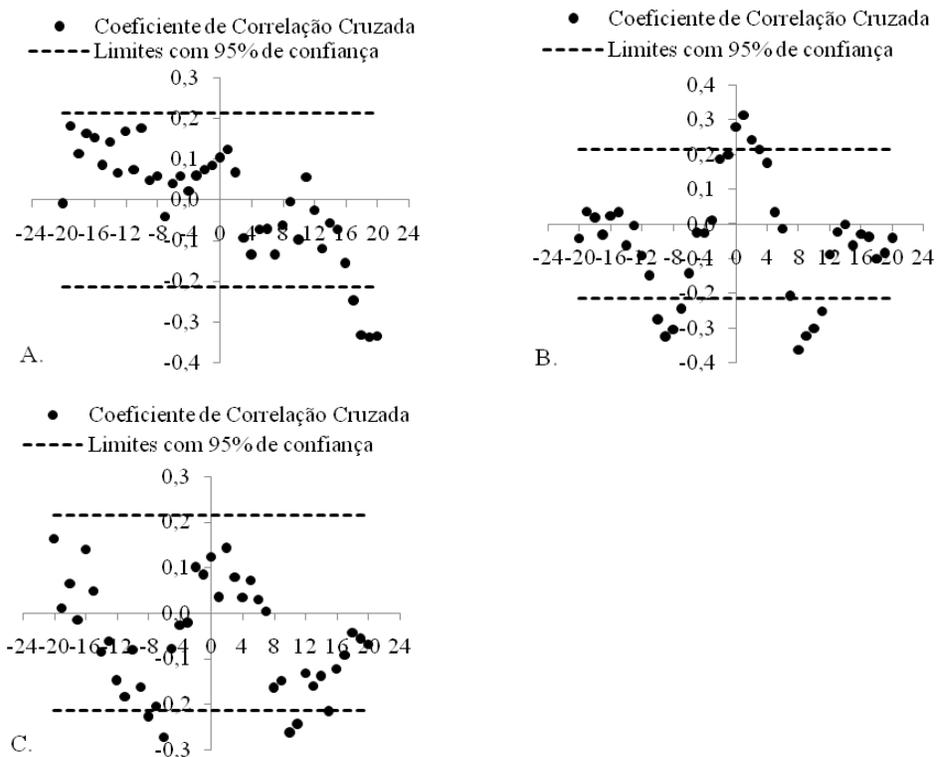


Figura 3. Correlogramas cruzados entre as séries de dados de produtividade da soja com fósforo (A), produtividade da soja com potencial hidrogeniônico (B) e produtividade da soja com densidade do solo (C).

As variáveis PD, P, pH e DS apresentaram autocorrelação entre as observações. Porém, apenas a variável pH apresentou correlação cruzada com a PD com coeficientes de correlação cruzada (Figura 3B) acima dos limites das bandas de confiança de 95%. Assim a construção de modelos autoregressivos em Espaço de Estados pode ser realizada somente para as variáveis PD e pH, uma vez que seus elementos amostrais apresentaram correlação entre si.

Os modelos autoregressivo em Espaço de Estados e de regressão linear simples apresentados nas Tabelas 2 e 3 estão acompanhados dos valores dos coeficientes de informação de Akaike (AIC), obtidos por meio do quadrado médio dos resíduos do modelo que é um estimador para a variância de modelo.

No modelo autoregressivo em Espaço de Estados apresentado na Tabela 2, verifica-se que as variáveis PD e pH observadas na posição $i-1$ contribuem, respectivamente, com 78,5 % e 19,4% na estimativa da PD na posição i . O AIC obtido para o modelo foi de -4,4274.

**Tabela 2. Modelo em espaço de estados para a estimativa da produtividade da soja (PD)
 com os valores do potencial hidrogeniônico (pH).**

Modelo Espaço de Estados	AIC
$PD_i = 0,7859 PD_{i-1} + 0,1943 pH_{i-1} + \varepsilon_i$	-4,4274

ε_i – erro aleatório.

No caso do modelo de regressão simples apresentado na Tabela 3, o qual considera a variável PD como dependente da variável pH, verifica-se que a cada variação de uma unidade da variável pH ocorre uma variação de 0,2960 na variável PD. O AIC para o modelo foi de -1,6972.

**Tabela 3. Modelo de regressão simples para a estimativa da produtividade da soja (PD)
 com os valores do potencial hidrogeniônico (pH).**

Modelo de Regressão	AIC
$PD = 1,0700 PD + 0,2960 pH + \varepsilon_i$	-1,6972

ε_i – erro aleatório.

Os valores estimados de produtividade da soja obtidos pela equação de estado e de regressão linear simples encontram-se na área compreendida entre as linhas superior e inferior, tracejadas, dos limites de confiança de 95% (Figuras 4 A-B). Por meio da

análise do gráfico das estimativas geradas pelo modelo autoregressivo em Espaço de Estados da Figura 4A, observa-se que parte dos valores medidos concentra-se dentro dos limites de confiança de 95%. No caso do gráfico gerado pelo modelo de regressão linear simples (Figura 4B), observa-se, de modo similar ao da Figura 4A, que ocorre uma concentração dos valores medidos no intervalo das bandas de confiança de 5% de significância.

Por meio da análise dos coeficientes de Akaike dos modelos apresentados nas Tabelas 2-3, observa-se que o valor dos resíduos das estimativas geradas pelo modelo em Espaço de Estados é menor comparativamente aos resíduos gerados pelo modelo de regressão linear simples, já que o coeficiente de Akaike do primeiro modelo foi de - ,4274 e do segundo foi de -1,6972. Resultados similares foram obtidos por Timm *et al.*, 2004; Wendroth *et al.*, 2003.

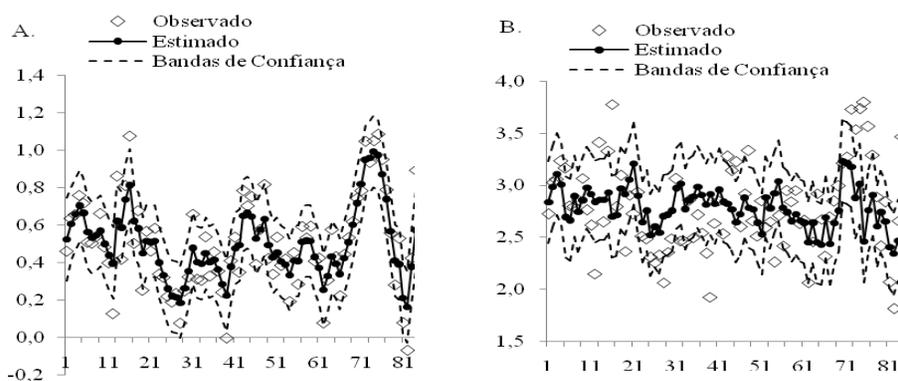


Figura 4. Estimativas em Espaço de Estados para a produtividade da soja (PD) na posição i , como função da PD e do pH na posição $i-1$ (A) e Estimativas do modelo de regressão linear simples para a PD como função do pH (B).

4. Conclusões

1. Constatou-se que a produtividade da soja, as propriedades químicas pH e fósforo bem como a densidade do solo apresentaram dependência espacial entre vizinhos.

2. A dependência espacial cruzada entre produtividade da soja e os atributos químicos e físico analisados foi identificada para o par de variáveis produtividade da soja e pH do solo.

3. No modelo em Espaço de Estados a contribuição atribuída à variável pH foi de 19,43%, menor do que a de 78,59% atribuída à variável produtividade da soja em $i-1$ para a estimativa da produtividade no ponto i .

4. A análise do modelo em Espaço de Estados comparativamente ao modelo de regressão linear simples equivalente mostrou que o primeiro teve maior eficiência nas estimativas dos valores de produtividade da soja.

REFERÊNCIAS BIBLIOGRÁFICAS

- Akaike, H. (1973). Information theory and extension of the maximum likelihood principle. *Journal of the Royal Statistical Society, v. 51*: 469-483.
- Davis, J.C. (1986). *Statistics and data analysis in geology*. 2nd ed. New York, John Wiley & Sons.
- EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. (2006). *Sistema Brasileiro de Classificação de Solos*. Brasília: Centro Nacional de Pesquisa de Solos.
- Hui, S.; Wendroth, O.; Parlange, M.B.; Nielsen, D.R. (1998). Soil variability: infiltration relationships of agroecosystems. *Journal of Balkan Ecology, 1*: 21-40.
- Johann, J. A.; Opazo, M. A. U.; Souza, E. G. S.; Rocha, J. V. (2004). Variabilidade espacial dos atributos físicos do solo e da produtividade em um Latossolo Bruno distrófico da região de Cascavel, PR. *Revista Brasileira de Engenharia Agrícola e Ambiental, v. 8, n. 2-3*: 212-219.
- Joschko, M.; Gebbers, R.; Barkusky, D.; Rogasik, J.; Höhn, W.; Hierold, W.; Fox, C. A.; Timmer, J. (2009). Location-dependency of earthworm response to reduce tillage on sandy soil. *Soil & Tillage Research, 102*: 55-66.
- Li, H.; Lascano, R. J.; Booker, J.; Wilson, L. T.; Bronson, K. F.; Segarra, E. (2002). State-space description of heterogeneity: Water and nitrogen use in cotton. *Soil Science Society of America Journal, v. 66, n. 2*: 585-595.
- Li, H.; Lascano, R. J.; Booker, J.; Wilson, L. T.; Bronson, K. F. (2001) Cotton lint yield variability in a heterogeneous soil at a landscape scale. *Soil & Tillage Research, v. 58*: 245-258.
- MARA – Ministério da Agricultura e Reforma Agrária (1992). *Regras para análise de sementes*. Brasília: Departamento Nacional de Defesa Vegetal.
- Mello, G.; Bueno, C. R. P.; Pereira, G. (2006). Variabilidade espacial das propriedades físicas e químicas do solo em áreas intensamente cultivadas. *Revista Brasileira de Engenharia Agrícola e Ambiental, v. 10, n. 2*: 294-305.
- Nielsen, D.R.; Wendroth, O. (2003). *Spatial and Temporal Statistics - Sampling Field Soils and Their Vegetation*. Reiskirchen, Catena Verlag.
- Raij, B. V.; Andrade, J. C.; Cantarella, H.; Quaggio, J. A. (2001). *Análise química para avaliação da fertilidade de solos tropicais*. Campinas: Instituto agrônomo.
- Reichert, J. M.; Dariva, T. A.; Reinert, D. J.; Silva, V. R. (2008). Variabilidade espacial de Planossolo e produtividade de soja em várzea sistematizada: análise geoestatística e análise de regressão. *Ciência Rural, v. 38, n. 4*: 981-988.
- Reichardt, K.; Timm, L.C. (2008). *Solo, Planta e Atmosfera: Conceitos, processos e aplicações*. 1^ª ed. Barueri, Manole.
- Shumway, R. H. & Stoffer, D. S. (2000). *Time series analysis and its applications*. New York, Springer.
- Timm, L. C.; Reichardt, K.; Oliveira, J. C. M.; Cassaro, F. A. M.; Tominaga, T. T.; Bacchi, O. O. S.; Dourado-Neto, D.; Nielsen D. R. (2004). State-space approach to evaluate the relation between soil physical and chemical properties. *Revista Brasileira de Ciência do Solo, v. 28, n. 1*: 49-58.
- Wang, Z.; Woodward W. A.; Gray H. L. (2009). The application of the Kalman filter to nonstationary time series through time deformation. *Journal of Time Series Analysis, v. 30*: 559-574.
- Wendroth, O.; Reuter, H.L.; Kersebaum, K.C. (2003). Predicting yield of barley across a landscape: a state-space modeling approach. *Journal of Hydrology, v. 272*: 250-263.

Recebido: 23 de julho de 2012.

Aceite: 31 de dezembro de 2012.