

MÉTODOS GEOESTATÍSTICOS NA ANÁLISE DA PRODUTIVIDADE DA SOJA

GUSTAVO H. DALPOSSO¹, MIGUEL A. URIBE-OPAZO², FERNANDA DE BASTIANI³

¹ Matemático, Doutor em Engenharia Agrícola, UTFPR/Toledo, (45) 3379-6800, gustavodalposso@utfpr.edu.br

² Estatístico, Doutor em Estatística, UNIOESTE/PGEAGRI/Cascavel, (45) 3220-3228, miguel.opazo@unioeste.br

³ Matemática, Doutora em Estatística, UFPE/Recife, (81) 2126-8421, fernandadebastiani@gmail.com

Apresentado no
XLIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2020
23 a 25 de novembro de 2020 - Congresso On-line

RESUMO: Neste trabalho uma área de 127,16 ha, cultivada com soja, foi monitorada nos anos-safras 2012/2013 à 2017/2018. Verificou-se que os valores de produtividade variaram entre os anos-safras, principalmente, devido a fatores climáticos não controláveis. A retirada de pontos influentes proporcionou alterações nos mapas e a utilização de semivariogramas escalonados permitiu obter mapas semelhantes aos elaborados sem pontos influentes, sem a necessidade de exclusão de pontos. A utilização de um modelo com repetições permitiu identificar regiões em que a produtividade foi menor e a utilização de covariáveis permitiu elaborar um mapa temático mais acurado no ano-safra 2017/2018.

PALAVRAS-CHAVE: variabilidade espacial, semivariograma escalonado, mapa do erro padrão.

GEOSTATISTIC METHODS IN ANALYSIS OF SOYBEAN PRODUCTIVITY

ABSTRACT: In this work, an area of 127.16 ha, cultivated with soybeans, was monitored in the 2012/2013 to 2017/2018 crop years. It was found that the productivity values varied between crop years, mainly due to uncontrollable climatic factors. The removal of influential points led to changes in the maps and the use of scaled semivariograms allowed to obtain maps similar to those produced without influential points, without the need to exclude points. The use of a model with repetitions allowed the identification of regions where productivity was lower and the use of covariables allowed the elaboration of a more accurate thematic map in the 2017/2018 crop year.

KEYWORDS: spatial variability, scaled semivariogram, prediction standard error map.

INTRODUÇÃO:

Como o cultivo da soja tem um alto custo de produção devido ao uso de fertilizantes, pesticidas, máquinas e sementes, os mapas de produtividade visam auxiliar na identificação de regiões de menor e maior potencial produtivo. Estas regiões podem ser gerenciadas de forma diferenciada, otimizando insumos, melhorando os lucros e reduzindo os impactos ambientais. Dentre as diversas metodologias utilizadas para criação de mapas temáticos destacam-se os métodos geoestatísticos (Dalposso et al., 2019), que têm sido amplamente aplicados na agricultura de precisão.

Embora o resultado final de uma análise geoestatística seja, na maioria das vezes, um mapa, cabe destacar que esta análise pode compreender uma elevada quantidade de técnicas que visam a obtenção de mapas mais acurados. Como exemplo, podemos citar o uso de técnicas de influência local (Grzegorzewski et al., 2013), semivariogramas escalonados (Wendpap et al., 2015), modelos espaciais lineares com repetições (De Bastiani et al., 2017), métodos bootstrap (Dalposso et al., 2019) e análises em um contexto espaço-temporal (Bottega et al., 2017).

Neste sentido, o objetivo deste trabalho foi utilizar métodos geoestatísticos para monitorar uma área agrícola cultivada com soja durante seis anos-safras consecutivos. Investigou-se o impacto da retirada de pontos influentes e a utilização de semivariogramas escalonados na construção dos mapas. Elaborou-se um mapa da produtividade de soja no intervalo variando de 2012/2013 à 2016/2017 e considerou-se um modelo espacial com covariáveis para obter um mapa mais acurado na safra 2017/2018.

MATERIAL E MÉTODOS:

O conjunto de dados de produtividade de soja ($t\ ha^{-1}$) foi coletado em seis anos-safras consecutivos (2012/2013 à 2017/2018) em uma área agrícola com 127,16 ha localizada na região oeste do estado do Paraná, próxima da cidade de Cascavel (Figura 1).

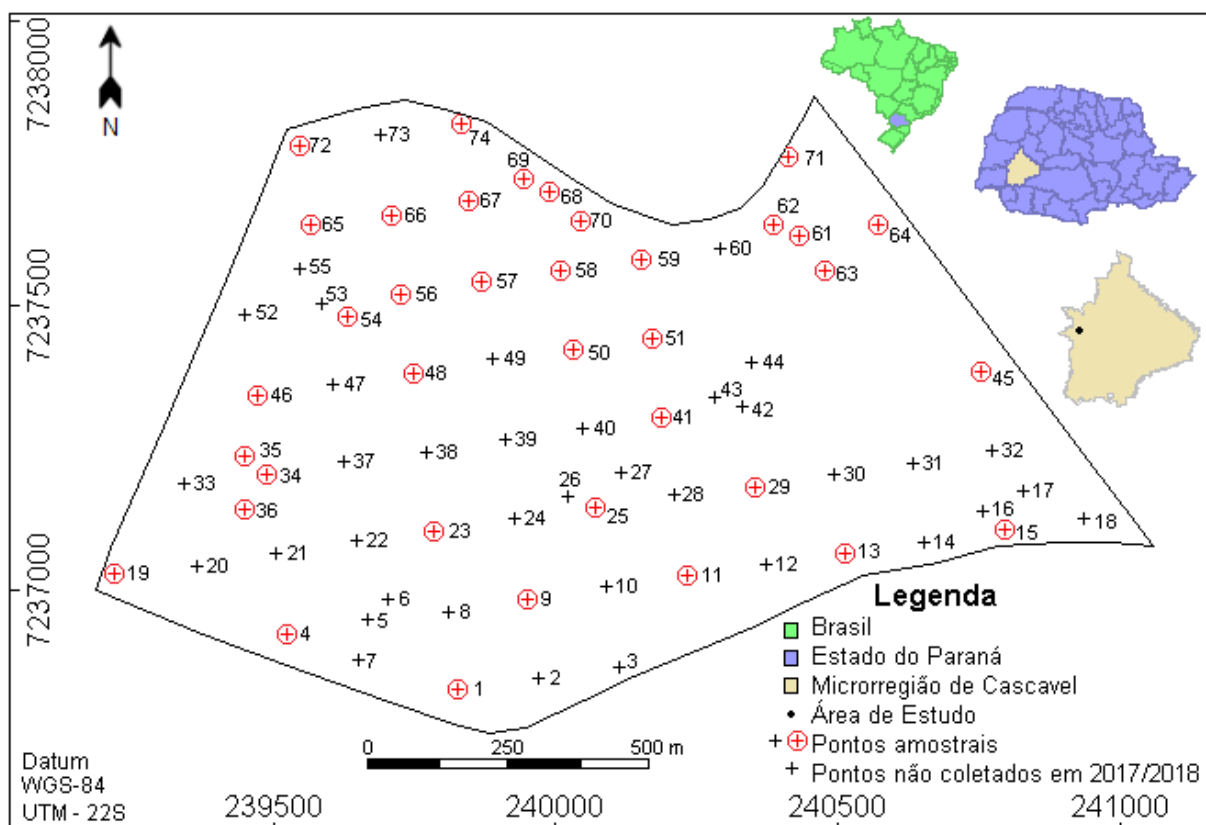


FIGURA 1. Área de estudo evidenciando a localização dos pontos amostrais coletados.

Nos anos-safras 2012/2013 à 2016/2017 foram coletados 370 pontos amostrais (74 por ano-safra) e no ano-safra 2017/2018, 37 pontos amostrais. Para observar o comportamento dos dados, realizou-se uma análise descritiva, e para identificar as estruturas espaciais, construíram-se semivariogramas experimentais omnidirecionais utilizando o

estimador de Matheron (Cressie, 2015). Para modelar as estruturas de dependência espacial foram utilizados os modelos da família Matérn com os parâmetros de forma $k = \{1,0; 1,5; 2,0\}$ e $k \rightarrow \infty$ (Matérn, 1986).

Para investigar a existência de pontos influentes, realizou-se uma análise de diagnóstico de influência local na variável resposta (Uribe-Opazo et al., 2012) utilizando o gráfico *Bi versus i*, apresentado por Poon and Poon (1999) como medida de diagnóstico.

Os semivariogramas experimentais nos anos-safras 2012/2013 à 2017/2018 foram escalonados (Vieira et al., 1991) para determinar um semivariograma mais representativo. Elaborou-se um modelo espacial linear com repetições (De Bastiani et al., 2017) considerando as amostras da produtividade de soja nos anos-safras 2012/2013 à 2017/2018 como repetições.

Os valores da produtividade da soja nos anos 2012/2013 à 2016/2017, coletados nos mesmos 37 pontos amostrais obtidos no ano-safra 2017/2018, foram considerados como covariáveis com objetivo de se obter um mapa mais acurado para o ano-safra 2017/2018.

Os modelos foram ajustados utilizando o método da máxima verossimilhança (Diggle e Ribeiro Jr 2007) e no estudo com o semivariograma escalonado utilizou-se o método dos mínimos quadrados ordinários (Diggle e Ribeiro Jr 2007)

Foram elaborados mapas do erro padrão considerando os valores das variâncias das predições. As comparações entre os mapas foram realizadas pelo índice Kappa seguindo os níveis de concordância propostos por Landis e Kock (1977). Para evidenciar as diferenças entre os mapas no ano-safra 2017/2018 foi elaborado um mapa da diferença de produtividade de soja ($t\ ha^{-1}$) em módulo.

As predições em locais não amostrados, necessárias para elaboração dos mapas, foram realizadas utilizando krigagem ordinária (Cressie, 2015) e krigagem com drift externo (KDE) (Wackernagel 1995), esta última utilizada especificamente na elaboração do mapa com covariáveis.

RESULTADOS E DISCUSSÃO:

Os maiores valores de produtividade da soja ocorreram nos dois primeiros períodos monitorados, sendo $3,26\ t\ ha^{-1}$ no ano-safra 2012/2013 e $4,23\ t\ ha^{-1}$ no ano-safra 2013/2014 (Figura 2). Nos anos-safras 2014/2015 e 2015/2016 foram observadas as menores produtividades sendo que em 2015/2016 destaca-se o ponto amostral 66 como discrepante, com uma produtividade de $0,67\ t\ ha^{-1}$ (Figura 2). Os anos-safras 2016/2017 e 2017/2018 apresentaram médias de produtividade semelhantes, $3,06\ t\ ha^{-1}$ e $3,07\ t\ ha^{-1}$ respectivamente, entretanto, na safra 2016/2017 destacam-se quatro valores discrepantes (Figura 2).




FIGURA 2. Boxplots da produtividade de soja ($t\ ha^{-1}$) nos anos-safras monitorados.

A produtividade média de soja obtida no ano-safra 2012/2013 (3,26 t ha⁻¹) foi satisfatória, tendo em vista ter ficado próxima da média obtida no Paraná (3,35 t ha⁻¹), o estado brasileiro que obteve a segunda maior produtividade média neste ano-safra (CONAB, 2019). No ano-safra 2013/2014 a produtividade média de soja obtida (4,23 t ha⁻¹) foi superior à média do estado de Roraima (3,18 t ha⁻¹), o maior produtor neste ano-safra (CONAB, 2019). A produtividade média obtida no ano-safra 2014/2015 foi baixa ao comparar-se com as médias nacional (2,300 t ha⁻¹) e paranaense (3,29 t ha⁻¹) no mesmo ano-safra (CONAB, 2019).

A baixa produtividade no ano-safra 2014/2015 pode ser explicada pela ocorrência de estresses hídricos ocorridos durante o desenvolvimento da cultura. No ano-safra 2015/2016 a produtividade média obtida (2,46 t ha⁻¹) foi inferior à média estadual (3,09 t ha⁻¹) e este baixo valor também é reflexo de adversidades climáticas, pois estas limitaram a produção e causaram perdas de 10% na safra (SEAB, 2016). As produtividades obtidas nos anos-safras 2016/2017 e 2017/2018 (3,06 t ha⁻¹ e 3,07 t ha⁻¹, respectivamente) foram baixas quando comparadas com as produtividades estadual (3,73 t ha⁻¹ e 3,51 t ha⁻¹) e nacional (3,36 t ha⁻¹ e 3,39 t ha⁻¹).

Os modelos ajustados considerando a quantidade total de dados em cada ano-safra são apresentados na Tabela 1(A). No ano-safra 2012/2013 o modelo geostatístico selecionado por validação cruzada apresentou um alcance de 101,25 m e um efeito pepita relativo de 0,753, indicando uma fraca dependência espacial (Tabela 1(A)). A validação cruzada indicou o modelo gaussiano (M_{inf}) como melhor ajuste em 66% dos anos-safras monitorados, destacando uma dependência espacial forte nos anos-safras 2013/2014 e 2016/2017 e uma moderada nos anos-safras 2014/2015 e 2015/2016 (Tabela 1(A)). No último ano-safra monitorado a validação cruzada indicou o modelo exponencial (M_{0.5}) como melhor ajuste, modelo este que apresentou o maior raio de dependência espacial (326,23 m) dentre todos os modelos ajustados (Tabela 1(A)).

Tabela 1 – Modelos geostatísticos ajustados aos dados de produtividade da soja (t ha⁻¹) nas safras 2012/2013 à 2017/2018.

	Ano-safra	Modelo	$\hat{\beta}$	$\hat{\varphi}_1$	$\hat{\varphi}_2$	$\hat{\varphi}_3$	alcance(m)	E(%)
(A)	2012/2013	M _{2.0}	3,259	0,159	0,052	018,861	101,25	75,4
	2013/2014	M _{inf}	4,227	0,000	0,289	037,701	065,25	0,00
	2014/2015	M _{inf}	2,374	0,056	0,021	156,422	270,74	72,7
	2015/2016	M _{inf}	2,460	0,043	0,034	119,917	207,55	55,8
	2016/2017	M _{inf}	3,084	0,066	0,211	107,573	186,19	23,8
	2017/2018	M _{0.5}	3,015	0,138	0,138	108,899	326,23	50,0
(B)	2012/2013	M _{0.5}	3,256	0,000	0,214	048,360	144,87	0,00
	2013/2014	M _{inf}	4,235	0,000	0,293	044,585	077,16	0,00
	2014/2015	M _{inf}	2,376	0,048	0,030	127,372	220,45	61,5
	2015/2016	M _{inf}	2,457	0,033	0,046	133,491	231,05	41,8
	2016/2017	M _{inf}	3,098	0,184	0,248	103,345	178,87	42,6
	2017/2018	M _{inf}	2,918	0,000	0,261	130,854	226,48	0,00

(A): Modelagem utilizando todos os dados; (B): Modelagem retirando os pontos influentes; $\hat{\beta}$: média estimada do modelo; $\hat{\varphi}_1$: estimativa do efeito pepita; $\hat{\varphi}_2$: estimativa da contribuição; $\hat{\varphi}_3$: estimativa do parâmetro que define o alcance; E: efeito pepita relativo. $E = [\hat{\varphi}_1 / (\hat{\varphi}_1 + \hat{\varphi}_2)] \cdot 100$. *O efeito pepita relativo (E) apresenta a segunda classificação: forte dependência espacial ($E \leq 25\%$), moderada dependência espacial ($25\% < E \leq 75\%$), e fraca dependência espacial ($E > 75\%$) (Cambardella et al., 1994).

As análises de influência local, indicaram como influentes as amostras 61 e 5 no ano-safra 2012/2013, 69 e 15 em 2013/2014, 55 e 42 em 2014/2015, 54 e 67 em 2015/2016, 34 e 54 em 2016/2017 e as amostras 11 e 12 em 2017/2018. Conforme destacam Dalposso et al

(2012), amostras influentes podem mudar algum tipo de decisão na determinação de modelos geoestatístico e/ou construção de mapas temáticos e desta forma, optou-se por realizar uma nova modelagem removendo os elementos amostrais potencialmente influentes (Tabela 1(B)).

Comparando os modelos ajustados sem os pontos influentes (Tabela 1(B)) com os modelos completos (Tabela 1(A)), verifica-se que para os anos-safras em que a validação cruzada manteve o modelo gaussiano como melhor ajuste (a saber, 2013/2014 à 2016/2017), as estimativas dos parâmetros foram afetadas. Por exemplo, no ano-safra 2016/2017 o efeito pepita estimado do modelo completo foi 0,066 (Tabela 1(A)) enquanto que no modelo sem os pontos influente foi de 0,184. Esta pequena diferença ocasionou uma alteração do raio de dependência espacial (de 186,19 m para 178,87 m) entretanto, a interpretação destes modelos continua parecida pois ambos apresentam forte dependência espacial. Em uma análise semelhante considerando o ano-safra 2012/2013 verifica-se que a retirada dos pontos influentes proporcionou uma considerável mudança. Além dos modelos selecionados por validação cruzada serem diferentes, o grau de dependência espacial se alterou (passando de fraca para forte) e o raio de dependência espacial teve um aumento de 43,62 m. Estas mudanças corroboram com os resultados apresentados por Uribe-Opazo et al. (2012) de que os pontos identificados como influentes afetam as estimativas de parâmetros.

Após o ajuste dos modelos ao semivariograma escalonado, os valores da validação cruzada indicaram como melhor ajuste o modelo exponencial ($M_{0.5}$) com parâmetros $\hat{\phi}_1 = 0,000$, $\hat{\phi}_2 = 1,027$, $\hat{\phi}_3 = 82,48$ e alcance de 247,09 m. Analisando os parâmetros deste modelo destaca-se a forte dependência espacial.

Para observar o comportamento da produtividade em locais não amostrados e quantificar os impactos gerados pela exclusão dos pontos influentes e pela utilização do semivariograma escalonado, foram elaborados os mapas temáticos da produtividade de soja nos anos-safras monitorados (Figura 3).

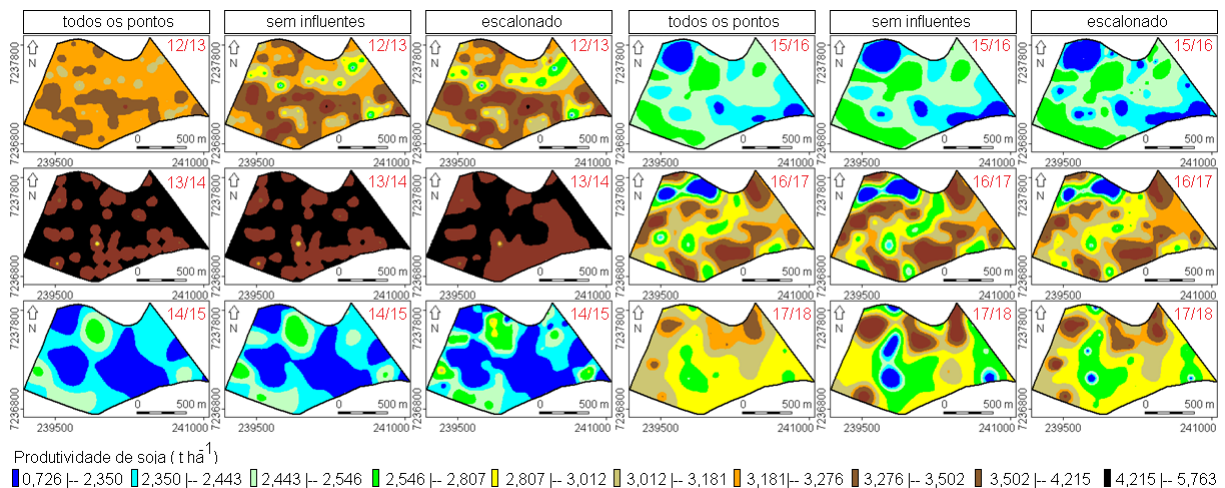


FIGURA 3. Mapas da produtividade de soja ($t\ ha^{-1}$) nos anos-safras 2012/2013 à 2017/2018.

Comparando os mapas do ano-safra 2012/2013 (Figura 3), verifica-se uma maior semelhança entre o mapa gerado sem os pontos influentes e o mapa gerado com o semivariograma escalonado. No ano-safra 2013/2014 destaca-se uma semelhança muito boa ($Kappa = 0,90$) entre o mapa obtido com todos os pontos e o obtido sem os pontos influentes. No entanto, evidencia-se a formação de regiões circulares próximas aos pontos amostrais, fenômeno conhecido como “*bull eyes effect*”, que ocorre quando o modelo geoestatístico apresenta um raio de dependência espacial próximo a distância mínima entre pontos.

No ano-safra 2014/2015 o maior índice Kappa calculado foi 0,76 na comparação entre o mapa obtido com todos os pontos e o mapa obtido sem os pontos influentes, indicando uma boa semelhança. No ano-safra 2015/2016 todas as comparações entre mapas indicaram uma boa semelhança e no último ano-safra monitorado destaca-se que a retirada dos pontos influentes proporcionou uma considerável mudança no mapa temático.

As semelhanças identificadas nos mapas ao longo do tempo são destacadas no mapa temático da produtividade de soja (Figura 4(A)) proveniente do ajuste de um modelo espacial linear tendo os valores de produtividade de soja nos anos-safra 2012/2013 à 2016/2017 assumidos como repetições. A Figura 4(B) apresenta o mapa do erro padrão de predição e observa-se que os erros são maiores em regiões que não apresentavam pontos amostrais.

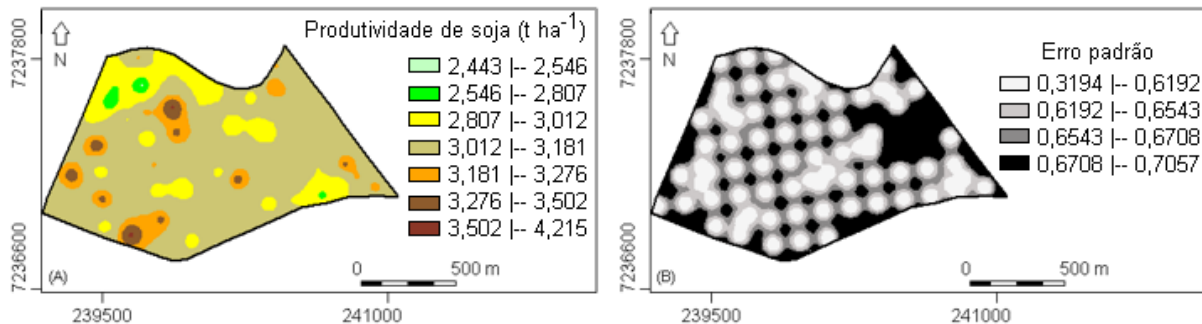


FIGURA 4. (A) Mapa da produtividade de soja ($t\ ha^{-1}$) no período compreendido entre os anos-safra 2012/2013 e 2016/2017; (B) Mapa do erro padrão dos valores preditos.

Em relação ao mapa temático da produtividade da soja nos anos-safra 2012/2013 à 2016/2017 (Figura 4(A)), destaca-se que, por ele apresentar o comportamento médio da produtividade durante um longo período, é esperado que possibilite definir zonas de manejo mais fidedignas. Isto é possível, pois, conforme explicam Fleming et al. (2000), o fato de tomar como base o histórico de produção no passado permite a identificação de diferentes zonas de manejo na área agrícola. Na prática, observou-se que as regiões noroeste e sudeste apresentaram as áreas com os menores valores de produtividade assim, um tratamento diferenciado nestas regiões tende a elevar a produtividade em safras futuras. Cabe ressaltar que as pequenas regiões com indicativo de menor produtividade, espalhadas na região em estudo (Figura 4(A)), podem dificultar uma aplicação localizada. Conforme destacam Al-Kaisi et al. (2016), este é um dos problemas relacionados a mapas que apresentam pequenas regiões, pois neste caso, existe uma dificuldade em definir zonas de manejo para uma aplicação localizada de fertilizantes.

A constatação de que o erro padrão de predição é mais baixo próximo aos pontos de interpolação e que ele aumenta gradualmente com o afastamento dos pontos (Figura 4(B)) é uma característica deste tipo de mapa.

O mapa temático da produtividade de soja ($t\ ha^{-1}$) para o ano-safra 2017/2018 (Figura 5(A)) obtido do modelo espacial linear gaussiano, considerando as informações de produtividade de soja nos anos-safra anteriores (2012/2013 à 2016/2017) como covariáveis, claramente apresenta diferenças (destacadas na Figura 5(B)) quando comparado com o mapa gerado somente com os pontos amostrais coletados no ano-safra 2017/2018 (Figura 3).

A menor precisão do mapa temático da produtividade de soja ($t\ ha^{-1}$) no ano-safra 2017/2018 (Figura 3), fica evidenciada em seu mapa do erro padrão dos valores preditos (Figura 5(C)), pois a redução da quantidade de pontos amostrais (50% a menos), implicou no surgimento de uma considerável área em que os erros de predição são elevados (última classe da legenda). Neste sentido, a utilização de um modelo espacial linear considerando covariáveis foi eficaz para a elaboração de um mapa temático mais preciso, fato este

observado no mapa do erro padrão dos valores preditos do mapa gerado utilizando krigagem com deriva externa (Figura 5(D)).

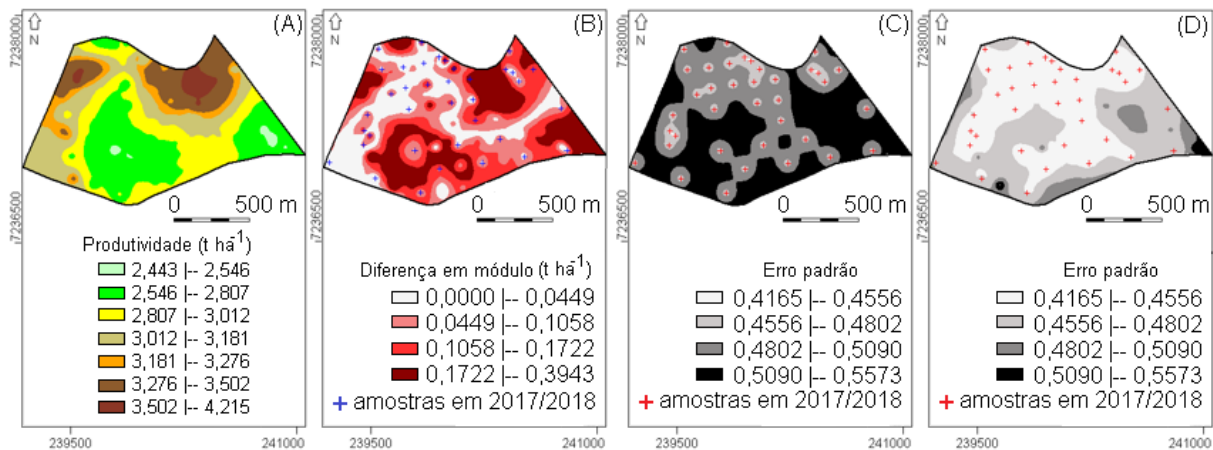


FIGURA 5. (A) Mapa da produtividade de soja ($t\ ha^{-1}$) no ano-safra 2017/2018 gerado por KDE; (B) Mapa da diferença da produtividade de soja ($t\ ha^{-1}$) em módulo entre o mapa com todos os pontos em 2017/2018 (Figura 3) e o mapa gerado por KDE (Figura 5(A)); (C) Mapa do erro padrão dos valores preditos do mapa obtido por krigagem ordinária (Figura 3) e (D) Mapa do erro padrão dos valores preditos do mapa gerado utilizando KDE (Figura 5(A)).

CONCLUSÕES:

Os resultados mostraram que em uma mesma área agrícola a produtividade da soja pode apresentar consideráveis variações, muitas vezes derivadas de fatores não controláveis como os relacionados a eventos climáticos. Foi verificado que a retirada de pontos influentes pode promover alterações em um mapa temático, no entanto, a utilização de semivariogramas escalonados permite obter mapas representativos sem a exclusão de pontos amostrais.

Embora a produtividade da soja tenha mostrado um comportamento não homogêneo entre os anos-safras, foi possível identificar regiões em que a produtividade foi menor (noroeste e sudeste da área monitorada), fato este evidenciado no mapa gerado com repetições. A elaboração de mapas do erro padrão dos valores preditos foi essencial para além de destacar que regiões desprovidas de pontos amostrais apresentam valores com menor precisão, mostrar que a utilização de covariáveis proporciona predições mais acuradas.

AGRADECIMENTOS:

Os autores agradecem a UTFPR Câmpus Toledo e a UNIOESTE Câmpus Cascavel pelo apoio no desenvolvimento deste trabalho. Os autores também agradecem ao CNPq a Capes e a Fundação Araucária por sempre apoiarem os projetos que ocorreram durante os anos-safras monitorados. Finalmente, os autores agradecem todos os pesquisadores do LEA – Laboratório de Estatística Aplicada e LEE – Laboratório de Estatística Espacial que durante todo este período participaram das coletas de campo.

REFERÊNCIAS:

AL-KAISI, M.M.; ARCHONTOULIS, S.; KWAW-MENSAH, D. 2016. Soybean spatiotemporal yield and economic variability as affected by tillage and crop rotation. **Journal of the American Society of Agronomy**, v.108, p.1267-1280, 2016.

BOTTEGA, E. L.; QUEIROZ, D. M.; PINTO, F. A. C.; VALENTE, D. S. M.; SOUZA, C. M. A. Precision agriculture applied to soybean: Part III - Spatial and temporal variability of yield. **Australian Journal of Crop Science**, v.11, n.07, p.799-805, 2017

CAMBARDELLA, C. A.; MOORMAN, T.B.; PARKIN, T.B.; NOVACK, J.M.; KARLEN, D.L.; TURCO, R. F.; KNOPKA, A.E. Field-scale variability of soil properties in Central Iowa Soils. **Soil Science Society of America Journal**, v.58, n.4, p.1501-1511, 1994.

CONAB. **Soja – Brasil: Série histórica de produtividade**. Brasília, DF, 2019. Disponível em: <<http://www.conab.gov.br>>. Acesso em: dez. 2019.

CRESSIE, N. A. C. **Statistics for spatial data**. Wiley classics library. New York, 2015. 928p.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; MERCANTE, E.; JOHANN, J. A.; BORSSOI, J. A. Comparison measures of maps generated by geostatistical methods. **Engenharia Agrícola**, Jaboticabal, v.32, n.1, p.174-183, 2012.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; JOHANN, J. A.; DE BASTIANI, F.; GALEA, M. Geostatistical modeling of soybean yield and soil chemical attributes using spatial bootstrap. **Engenharia Agrícola**, Jaboticabal, v.39, n.3, p.350-357, 2019.

DE BASTIANI, F.; GALEA, M.; CYSNEIROS, A.H.M.A.; URIBE-OPAZO, M.A. Gaussian spatial linear models with repetitions: An application to soybean productivity. **Spatial Statistic**, v.21, p. 319-335, 2017.

DIGGLE, P.J.; RIBEIRO JR, P.J. 2007. **Model -based Geostatistics**. Springer, New York, USA, 2017, 229 p.

FARACO, M.A.; URIBE-OPAZO, M.A.; SILVA, E.A.A.; JOHANN, J.A.; BORSSOI J. Seleção de modelos de variabilidade espacial para elaboração de mapas temáticos de atributos físicos do solo e produtividade da soja. **Revista Brasileira de Ciência do Solo**, Viçosa, v.32, n.2, p.463-476, 2008.

FLEMING, K.L.; WESTFALL, D.G.; WIENS, D.W.; BRODAHL, M.C. 2000. Evaluating farmer defined management zone maps for variable rate fertilizer application. **Precision Agriculture**, v.2, p.201-215, 2000.

GRZEGOZEWSKI, D. M.; URIBE-OPAZO, M. A.; DE BASTIANI, F.; GALEA, M. Local influence when fitting Gaussian spatial linear models: an agriculture application. **Ciencia e Investigacion Agraria**, Santiago, v.40, n.3, p.537-545, 2013.

MATÉRN, B. (1986) **Spatial Variation**. Lecture notes in Statistics. 2. ed. New York: Springer

POON, W.; POON, Y.S. Conformal normal curvature and assessment of local influence. **Journal of the Royal Statistical Society: Series B**, v.61, n.1, p. 51-61, 1999.

Seab, 2016. **Soja – Informativo 01 de Agosto – 2016**. Curitiba, PR, 2016. Disponível em: <<http://www.agricultura.pr.gov.br>>. Acesso em: jan. 2019.

URIBE-OPAZO, M. A.; BORSSOI, J.A.; GALEA, M. Influence Diagnostics in Gaussian Spatial Linear Models. **Journal of Applied Statistics**. v.39, n.3, p.615-630, 2012.

VIEIRA, S. R.; LOMBARDI NETO, F.; BURROWS IT, I.T. Mapeamento da chuva máxima provável para o Estado de São Paulo. **Revista Brasileira de Ciência do Solo**, n.15, v.1, p.93-98, 1991.

WACKERNAGEL, H. **Multivariate geostatistics**. Springer-Verlag, Berlin, 1995, 256 p.

WENDPAP, B. G.; URIBE-OPAZO, M. A.; JOHANN, J. A.; VILAS BOAS, M. A.; SOUZA, E. G. Geostatistical models in a study on the spatio-temporal dependence of agricultural data. **International Journal of Agriculture, Environment and Food Sciences**, Diyarbakır, v.13, n. 3&4, p.21-28, 2015.