

Produtividade agrícola do arroz no Brasil: uma análise espacial

Leticia Marasca^{1†}, Cláudia A. S. Ramser¹, Adriano M. Souza²

¹Doutoranda do Programa de Pós-Graduação em Administração – PPGA, da Universidade Federal de Santa Maria - UFSM

²Professor Doutor Titular do Departamento de Estatística da Universidade Federal de Santa Maria – UFSM

Resumo: O arroz é um grão que faz parte da alimentação de grande parte da população mundial, e sua produção desempenha um importante papel econômico e social. Essa pesquisa objetiva determinar a autocorrelação espacial da produtividade agrícola do arroz entre as microrregiões brasileiras, com a utilização da metodologia Análise Exploratória dos Dados Espaciais (AEDE), contribuindo para a investigação dos efeitos espaciais da produtividade agrícola de arroz no país. Seus resultados indicaram a presença de autocorrelação espacial positiva entre as variáveis, o que significa que microrregiões com alta ou baixa produtividade agrícola estão agrupadas em áreas específicas do mapa, rodeadas por microrregiões com características semelhantes para essa variável, tornando possível identificar efeitos de transbordamento da produtividade agrícola de grãos entre as microrregiões vizinhas. Pode-se concluir que a variável produtividade agrícola dos grãos se distribui de maneira heterogênea entre as microrregiões do país, ou seja, a produtividade agrícola está cada vez mais autocorrelacionada espacialmente ao longo do tempo.

Palavras-chave: produtividade agrícola do arroz; autocorrelação espacial; análise exploratória de dados espaciais;

Abstract: Rice is a grain that is part of the diet of a large part of the world's population, and its production plays an important economic and social role in Brazil and in the world. This research aims to determine the spatial autocorrelation of rice agricultural productivity among Brazilian microrregions, using the Exploratory Spatial Data Analysis (AEDE) methodology, contributing to the investigation of the spatial effects of rice agricultural productivity in the country. Their results indicated the presence of positive spatial autocorrelation between the variables, which means that microrregions with high or low agricultural productivity are grouped in specific areas of the map, surrounded by microrregions with similar characteristics for this variable, making it possible to identify productivity spillover effects between neighboring microrregions. It can be concluded that grains agricultural productivity variable has a heterogeneous distribution among country microrregions, in other words, agricultural productivity is increasingly autocorrelated spatially over time.

Keywords: rice agricultural productivity; spatial autocorrelation; exploratory analysis of spatial data;

Introdução

O arroz é um grão que faz parte da alimentação de grande parte da população mundial, estando presente em todos os continentes, tanto no consumo quanto no cultivo (EMBRAPA, 2020). A produção de arroz desempenha um importante papel econômico e social, sendo considerado a cultura mais importante em diversos países em desenvolvimento, como a Oceania e a Ásia, este último respondendo por 90% da produção mundial, e além de produzida, consumida em seu território, de acordo com a Agência Embrapa de Informação Tecnológica (AGEITEC, 2019). De grande balanceamento nutricional, propicia 20% da energia e 15% da proteína que o ser humano necessita. Outro benefício desse grão é que ele se adapta a diferentes climas, e essa característica o coloca como um alimento potencial para o combate da fome no mundo (EMBRAPA, 2020). Atualmente é a base na alimentação de 2,5 bilhões de pessoas no mundo e a previsão é que nas próximas três décadas, a população atendida seja dobrada (FAO, 2019).

†Autora correspondente: leticiamarasca@yahoo.com.br.

O Brasil se destaca entre os dez principais produtores mundiais de arroz, sendo o maior produtor fora do continente Asiático (POERSCHKE; MORAIS, 2014). O arroz é o segundo grão com maior extensão de terras cultivadas no país, ficando atrás somente do trigo. O cultivo do arroz no país representa 75% da produção nacional de grãos, sendo essa cultura considerada estabilizadora da safra, pois essa cultura independe do clima para seu desenvolvimento. Com base no exposto, essa pesquisa objetiva determinar a autocorrelação espacial da produtividade agrícola do arroz entre as microrregiões brasileiras, com a utilização da metodologia Análise Exploratória dos Dados Espaciais (AEDE), contribuindo para a investigação dos efeitos espaciais da produtividade agrícola de arroz no país.

Metodologia

Para a realização da AEDE, o primeiro passo é a estimação do Modelo Clássico de Regressão Linear (MCRL), pelo Método dos Mínimos Quadrados Ordinários para a variável selecionada, que é a produtividade agrícola do arroz. Logo após, analisa-se os resíduos da regressão, utilizando-se a estatística I de Moran. Como resultado, há a rejeição da hipótese nula de aleatoriedade espacial, confirmando assim a autocorrelação espacial negativa (PASCHOALINO et al., 2017). Assim, define-se a matriz de pesos espaciais, ou matriz W, selecionando a matriz que apresentou maior valor para a estatística I de Moran, pois foi a que melhor captou a autocorrelação espacial presente nos dados (ALMEIDA; PEROBELLI; FERREIRA, 2008). A matriz selecionada para a variável produtividade agrícola do arroz foi a matriz binária de distância geográfica, a matriz dos k vizinhos mais próximos, (*k-nearest neighbors weight matrix*) ($W_{ij}(k)$), Equação (1), na qual regiões mais próximas geograficamente tem maior interação espacial do que regiões mais distantes.

$$W_{ij}(k) = \begin{cases} 1, & \text{se } d_{ij} \leq d_i(k) \\ 0, & \text{se } d_{ij} > d_i(k) \end{cases} \quad (1)$$

onde: $d_i(k)$ é a distância de corte para a região i , a fim de que a região i tenha k vizinhos; $W_{ii}(k) = 0$.

Para testar a hipótese de distribuição aleatória, utiliza-se o primeiro coeficiente de autocorrelação espacial proposto, o I de (MORAN, 1948) Equação (2).

$$I = \frac{n}{S_0} \frac{\sum_i \sum_j W_{ij} Z_i Z_j}{\sum_{i=1}^n Z_i^2} \quad (2)$$

onde: n é o número de regiões; Z são os valores da variável de interesse padronizada; WZ são os valores médios da variável de interesse padronizada nos vizinhos, definidos segundo uma matriz de ponderação espacial W, ou de maneira geral, o termo z defasado espacialmente; W_{ij} é um elemento da matriz de ponderação espacial, referente à região i e a região j ; S_0 corresponde a $\sum \sum W_{ij}$, indicando que todos os elementos da matriz de pesos espaciais W devem ser somados.

O Indicador Local de Associação Espacial (*Local Indicator of Spatial Association – LISA*) também foi gerado (Equação (3)), definindo o índice local de associação espacial, como uma decomposição do índice global de autocorrelação espacial (ANSELIN, 1995).

$$I_i = Z_i \sum_{j=1}^j W_{ij} Z_j \quad (3)$$

onde: y é uma variável padronizada, observada na região i , Z_i .

Esses indicadores LISA são mapeados no mapa de significância LISA map, um mapa de clusters da associação espacial (TEIXEIRA; BERTELLA, 2015).

A metodologia descrita nesse item compreende a AEDE, etapa exploratória da econometria espacial (ALMEIDA, 2012), que possibilita a definição dos padrões espaciais da produtividade agrícola do arroz entre as microrregiões brasileiras. O banco de dados utilizado para a modelagem corresponde à produtividade agrícola do arroz referente às 558 microrregiões brasileiras, analisando-se os anos 1992, 1997, 2002, 2007, 2012 e 2017, em um total de 3.348 observações, com periodicidade anual. Os sites utilizados para coleta dos dados e do *shapefile* são o IBGE, na pesquisa de Produção Agrícola Municipal (PAM) do Sistema IBGE de Recuperação Automática (Sidra) e os *softwares* utilizados para a modelagem dos dados foram o *GeoDa* e o *Qgis*.

Resultados e discussão

A estatística I de *Moran* foi calculada para a variável produtividade agrícola do arroz para todos os anos em análise (1992, 1997, 2002, 2007, 2012 e 2017) e seu valor esperado é -0.00179. A partir desse valor, são calculadas e analisadas suas estatísticas, conforme a Tabela 1).

Tabela 1. Valor esperado e calculado do Índice I de *Moran**

Variável	Ano	I de <i>Moran</i> Esperado	I de <i>Moran</i> Calculado	Matriz
Produtividade agrícola do arroz	1992	-0.00179533213644**	0.809247	k (3)
	1997	-0.00179533213644**	0.752341	k (5)
	2002	-0.00179533213644**	0.739656	k (3)
	2007	-0.00179533213644**	0.754401	k (2)
	2012	-0.00179533213644**	0.766171	k (4)
	2017	-0.00179533213644**	0.707435	k (5)

Fonte: Organização do autor (2018).

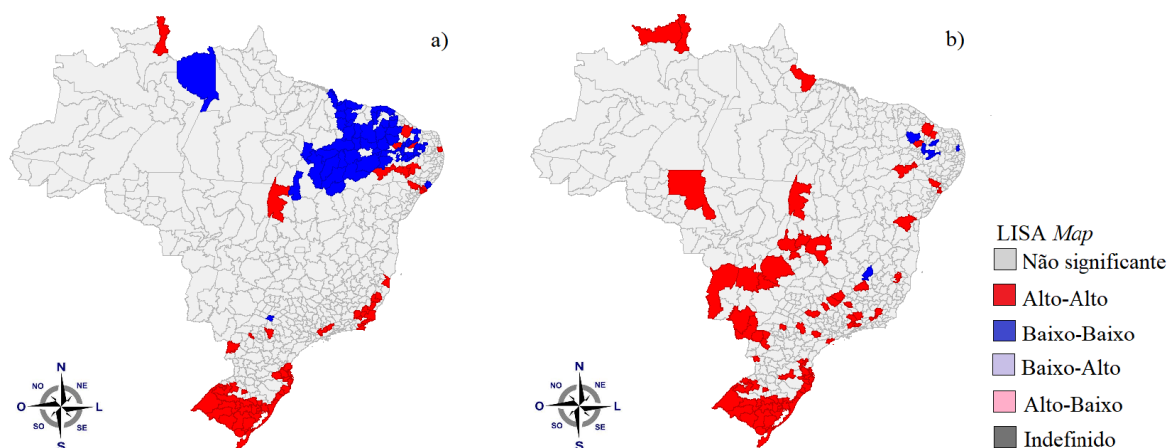
*H0: aleatoriedade espacial; H1: autocorrelação espacial

**Significativo a $p < 0,05$

Observando-se a Tabela 1, percebe-se que para todos os períodos em análise, o teste I de *Moran* calculado resultou na aceitação da hipótese H1, pois o I de *Moran* calculado é maior que o seu valor esperado, confirmando a autocorrelação espacial presente nos dados, com a rejeição da hipótese nula de aleatoriedade dos dados. Pode-se verificar também a rejeição da hipótese H0 no teste de nível *alpha*, se p -valor $< 0,05$. A autocorrelação espacial é considerada positiva, confirmada pelos coeficientes positivos, indicando similaridade entre a variável produtividade agrícola do arroz e sua localização espacial. Com base nesses resultados, confirma-se a formação de *clusters* de alta e baixa produtividade agrícola do arroz entre as microrregiões do país, o que indica que as microrregiões com alta produtividade estão agrupadas em determinadas regiões do país, rodeadas de regiões vizinhas com valores também altos para essa variável, bem como microrregiões com baixa produtividade encontram-se agrupadas em outra região do país, rodeadas por vizinhos que também apresentam baixa produtividade.

A Figura 1, mapa a) representa a produtividade agrícola do arroz para o ano de 1992. Observa-se que sessenta e uma microrregiões compõem três *clusters* na cor vermelho intenso (microrregiões caracterizadas como alto-alto) e cinquenta e sete microrregiões compõem um *cluster* azul intenso (microrregiões caracterizadas como baixo-baixo), além de quatrocentas e quarenta microrregiões que não apresentaram o índice I de *Moran* como significativo. Ainda se observando a Figura 1, mapa b), correspondente à produtividade agrícola do arroz para o ano de 1997, percebe-se oitenta e duas microrregiões que formam cinco *clusters* caracterizado como alto-alto, em vermelho intenso e quarenta e duas microrregiões compõem os três *clusters* caracterizado como baixo-baixo (azul-intenso), além de quatrocentas e trinta e quatro microrregiões sem significância.

Figura 1. LISA map das microrregiões brasileiras para a produtividade agrícola do arroz nos anos de 1992 e 1997

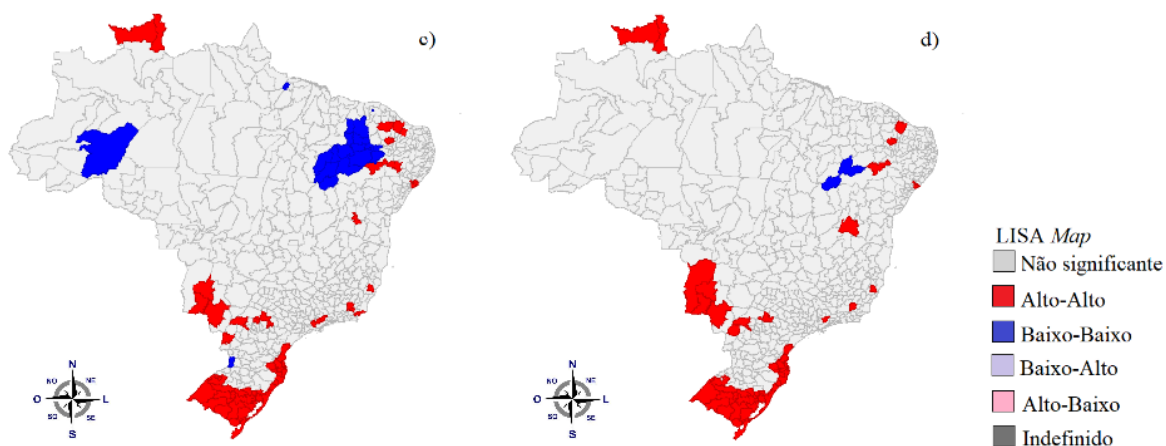


Fonte: Organização do autor (2018).

Foi nesse período (1992) que ocorreu uma grande aceleração inflacionária no país, com a valorização da taxa de câmbio, o que prejudicou a agricultura em geral, reduzindo as receitas. Nesse período instalou-se o regime de flutuação suja, com o estabelecimento da taxa de câmbio pelo mercado, causando uma desvalorização nos anos de 1991 e 1992 e uma posterior valorização no ano de 1993, equilibrando o mercado. Foi no início dos anos 90 que criaram-se os financiamentos privados, como o Certificado do Depósito Agrícola (CDA), a Célula do Produtor Rural, e também a possibilidade de renegociação das dívidas rurais (BACHA; DANELON; FILHO, 2006). No ano de 1992 ocorreu também o *impeachment* do então presidente Fernando Collor de Mello, o que trouxe ainda mais instabilidade política e, conseqüentemente, econômica ao país.

O ano de 1997 teve como característica o aumento nos subsídios oferecidos ao setor agrícola, depois de um longo período de cortes. Nesse ano criou-se o sistema de minibandas cambiais, o que elevou a taxa de câmbio no país, favorecendo a compra de insumos e equipamentos agrícolas. Esse ano também foi marcado por uma grande estiagem, com suas conseqüências se estendendo pelos anos seguintes. Apesar disso, ainda se observa um crescimento no período, conseqüência do aumento da produtividade, mão-de-obra e novas tecnologias disponíveis.

Figura 2. LISA map das microrregiões brasileiras para a produtividade agrícola do arroz nos anos de 2002 e 2007



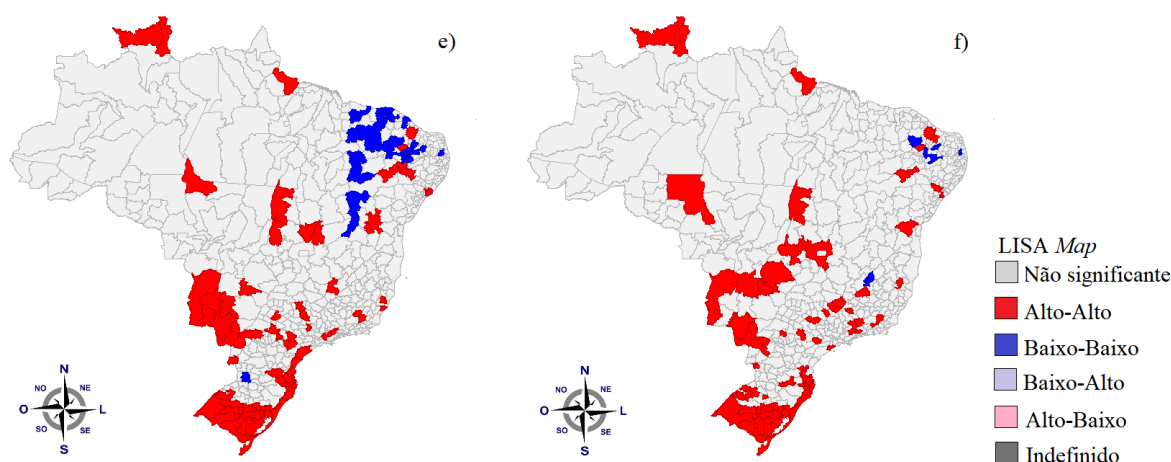
Fonte: Organização do autor (2018).

A Figura 2 apresenta o LISA map para a produtividade agrícola do arroz para os anos de 2002 e 2007. O mapa a) (Figura 2) corresponde ao ano de 2002 e nele pode-se observar sessenta microrregiões

que formam seis *clusters* caracterizados como alto-alto (em vermelho intenso) e dezenove microrregiões que compõem um *cluster* caracterizado como baixo-baixo (em azul intenso), além de quatrocentas e setenta e nove microrregiões não significantes. O mapa b) (Figura 2), corresponde a mesma variável para o ano de 2007, no qual cinquenta e uma microrregiões formam três *clusters* alto-alto, em vermelho intenso, e duas microrregiões estão classificadas como baixa-baixa (azul intenso), além de quinhentas e cinco microrregiões não significativas.

O ano de 2002 foi marcado novamente por uma desvalorização cambial, o que estimulou as exportações no país. Foi também nesse ano que novos programas de financiamento de máquinas agrícolas foram criados. Em 2007 a China consolidou-se como o maior parceiro comercial do Brasil, uma parceria que se iniciou em 1949, pela fundação da República da China (MARCOS et al., 2011).

Figura 3. LISA *map* das microrregiões brasileiras para a produtividade agrícola do arroz nos anos de 2012 e 2017



Fonte: Organização do autor (2018).

Na Figura 3, mapa a), a produtividade agrícola do arroz para o ano de 2012 se distribui em setenta e oito microrregiões identificadas em vermelho intenso, compondo dez *clusters* alto-alto, trinta e quatro microrregiões em azul intenso, caracterizadas como baixo-baixo, compondo três *clusters*, além de quatrocentas e quarenta e seis microrregiões não significantes. O mapa b) (Figura 3) corresponde à mesma variável, para o ano de 2017, último ano em análise na pesquisa. Setenta e oito microrregiões compõem oito *clusters* caracterizados como alto-alto, em vermelho intenso no mapa e sete microrregiões se caracterizam como baixo-baixo, em azul intenso, além de quatrocentas e setenta e três microrregiões que não apresentaram valores significativos. Pode-se perceber que a produtividade agrícola do arroz cresceu ao longo dos anos em análise, se tornando maior em várias regiões vizinhas/contíguas, confirmando assim a presença de transbordamento entre regiões ou efeito “*spillover*” espacial.

O ano de 2012 foi marcado por uma grande quebra de safra, devido a uma grande estiagem, consequência do fenômeno climático “*Al Niña*”. Essa estiagem se estendeu pelos anos seguintes, incluindo o último ano da pesquisa, 2017. Foi nesse período que ocorreu o *impeachment* da presidenta Dilma Rousseff (2016), o que tornou o ano de 2017 bastante instável econômica e politicamente.

Na Figura 1, 2 e 3 observam-se os LISA *maps* caracterizando a produtividade agrícola do arroz para cada ano em análise. Esses mapas de agrupamentos locais corroboram os resultados da Tabela 1, pois neles pode-se observar a formação de *clusters* de alta e baixa produtividade, sendo esses *clusters* uma característica da presença de autocorrelação espacial positiva. Analisando-se o primeiro e o último ano para fins de comparação (

Figura 1, mapa a) e Figura 3, mapa b), observa-se um aumento na produtividade agrícola do arroz entre as microrregiões brasileiras durante o período de análise.

Conclusões

A produtividade agrícola do arroz está distribuída de maneira heterogênea no país, com a dependência espacial presente tanto de maneira global como local, confirmando a importância da utilização da metodologia da Análise Exploratória de Dados Espaciais. Os valores obtidos pela estatística I de Moran possibilitam rejeitar a hipótese nula de aleatoriedade espacial da produtividade agrícola do arroz, o que sugere a formação de *clusters* alto-alto e *clusters* baixo-baixo, indicando que microrregiões com alta produtividade são vizinhas de outras microrregiões com produtividade também alta para a variável arroz, e de maneira análoga, microrregiões que apresentam baixa produtividade se encontram em uma região do mapa com vizinhos apresentando produtividade agrícola do arroz também abaixo da média.

A observação dos mapas de significância LISA *maps* permite a identificação de *clusters* de alta e baixa produtividade. Esses agrupamentos podem ser explicados pelo clima favorável a determinadas culturas em algumas regiões do país, pelos incentivos governamentais, em abundância em algumas regiões, pela convergência da produtividade do arroz, que acaba aumentando a produção em algumas áreas que antes não recebiam cultivo, terras com características específicas, favoráveis a determinadas culturas. Os resultados obtidos possibilitam tomar decisões acerca de investimentos governamentais, levando em consideração os padrões espaciais identificados, ou seja, áreas de maior e menor produtividade, tornando possível o desenvolvimento de políticas públicas de incentivo às regiões com menor produtividade, bem como seus vizinhos, contribuindo assim para o desenvolvimento de regiões com baixa produtividade agrícola.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e também do Laboratório de Análise e Modelagem Estatística – LAME, da Universidade Federal de Santa Maria – UFSM.

Referências

AGEITEC. Agência Embrapa de Informação Tecnológica. Disponível em:

<http://www.agencia.cnptia.embrapa.br/>.

ALMEIDA, E. S. de; PEROBELLI, F. S.; FERREIRA, P. G. C. Existe convergência espacial da produtividade agrícola no Brasil? *Revista de Economia e Sociologia Rural*, v. 46, n. 1, p. 31–52, 2008.

ALMEIDA, E. *Econometria espacial aplicada*. Campinas: Alínea, 2012.

ANSELIN, L. Local Indicators of Spatial Association—LISA. *Geographical Analysis*, v. 27, n. 2, p. 93–115, 1995.

BACHA, C. J. C.; DANELON, L.; FILHO, E. D. B. Evolução da taxa de juros real do crédito rural no Brasil - período de 1985 a 2003. *Teoria e evidência econômica*, v. 14, n. 26, p. 43–69, maio 2006.

EMBRAPA. *Empresa Brasileira de Pesquisa Agropecuária*. Disponível em: <https://www.embrapa.br/>.

IBGE. *Instituto Brasileiro de Geografia e Estatística*. Disponível em: <https://www.ibge.gov.br/>.

MARCOS, C. et al. Determinantes do comércio Brasil-China de Commodities e produtos industriais: uma aplicação VECM. *Economia Aplicada*, v. 15, n. 2, p. 311–335, 2011.

MORAN, P. A. The interpretation of statistical maps. *Journal of the Royal Statistical Society*, v. 10, n. 2, p. 243–251, 1948.

FAO. Organização das Nações Unidas para a alimentação e a agricultura. Disponível em: <http://www.fao.org/brasil/pt/>.

PASCHOALINO, P. A. A. T. et al. Análise espacial da produtividade do feijão nos municípios paranaenses entre 2006 e 2014. *Economia & Região*, v. 5, n. 1, p. 107–123, 2017.

POERSCHKE, R. P.; MORAIS, I. A. C. de. Determinantes da demanda brasileira por importação de arroz: uma abordagem não linear. *Revista de Economia e Sociologia Rural*, v. 52, n. 1, p. 177–194, 2014. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-20032014000100010&lng=pt&tlng=pt.

TEIXEIRA, R. F. A. P.; BERTELLA, M. A. Distribuição espaço-temporal da produtividade média do café em Minas Gerais: 1997-2006. *Análise Econômica*, v. 33, n. 63, p. 275–299, 31 mar. 2015.