

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

Análise espacial para o seguro agrícola: um estudo de caso no Paraná

Tarcísio da Costa Lobato

Tese apresentada para obtenção do título Doutor em
Ciências. Área de concentração: Economia Aplicada

**Piracicaba
2021**

Tarcísio da Costa Lobato
Licenciado em Matemática
Bacharel em Estatística

Análise espacial para o seguro agrícola: um estudo de caso no Paraná
versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **VITOR AUGUSTO OZAKI**

Tese apresentada para obtenção do título de Doutor em
Ciências. Área de concentração: Economia Aplicada

Piracicaba
2021

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Lobato, Tarcísio da Costa

Análise espacial para o seguro agrícola: um estudo de caso no Paraná / Tarcísio da Costa Lobato. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - -Piracicaba, 2021.

102 p.

Tese (Doutorado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Seguro agrícola 2. Soja 3. Milho 4. Correlação espacial 5. STARMA I.
Título

AGRADECIMENTOS

Agradeço ao meu orientador Prof. Dr. Vitor Augusto Ozaki pela paciência, apoio e contribuição na realização deste trabalho.

Agradeço à minha amada esposa, por todo amor, companheirismo, incentivo e também cobrança ao longo dessa caminhada.

Agradeço a todos os professores e funcionários do departamento de Economia da Escola Superior de Agricultura “Luiz de Queiroz” que contribuíram para meu desenvolvimento e crescimento como profissional.

Agradeço ao meu colega de turma do Doutorado, Derick David Quintino, pela amizade e conversas descontraídas.

Agradeço ainda a todos que contribuíram direta ou indiretamente para a realização deste trabalho.

SUMÁRIO

RESUMO.....	5
ABSTRACT	6
LISTA DE FIGURAS.....	7
LISTA DE TABELAS	9
1. INTRODUÇÃO.....	11
Referências.....	14
2. DINÂMICAS ESPACIAIS DA PRODUTIVIDADE DE MILHO E SOJA NO PARANÁ: CONSEQUÊNCIAS PARA O SEGURO AGRÍCOLA	17
2.1. Introdução	17
2.2. Análise espacial e o seguro agrícola	19
2.3. Metodologia	21
2.4. Resultados e discussões	25
2.5. Conclusões	36
Referências.....	38
3. ANÁLISE ESPACIAL DOS SINISTROS DO SEGURO AGRÍCOLA NO PARANÁ	43
3.1. Introdução	43
3.2. O Seguro agrícola e o risco sistêmico	45
3.3. Metodologia	54
3.4. Resultados e discussões	59
3.5. Conclusões	68
Referências.....	69
4. PROPOSTA DO MODELO STARMA PARA CONTROLAR O EFEITO ESPAÇO-TEMPORAL EM DADOS DE PRODUTIVIDADE DE SOJA	73
4.1. Introdução	73
4.2. Metodologia	75
4.3. Resultados e discussões	82
4.4. Conclusões	91
Referências.....	92
ANEXO.....	97

RESUMO

Análise espacial para o seguro agrícola: um estudo de caso no Paraná

A atividade agrícola tem um importante papel para o crescimento econômico do Brasil, com destaque nacional e internacional para a produção de milho e soja, devido a ser o que mais ocupa áreas de lavoura. Nesse contexto, essas atividades são altamente dependentes das condições do clima, e para se protegerem das oscilações climáticas, os produtores podem contratar o seguro agrícola, para transferir os riscos para o mercado segurador. As seguradoras se baseiam no pressuposto de independência entre os eventos, contudo, um evento catastrófico atinge muitos produtores, de modo que a suposição de independência é violada, e os dados de produtividade média dos municípios se apresentam correlacionados espacialmente. Sendo assim, o objetivo principal desta tese é analisar o comportamento das influências espaciais da produtividade de milho e de soja nos municípios do Paraná, para comparar a intensidade da correlação espacial em anos com e sem intempéries climáticas, além de propor o uso de modelos STARMA como alternativa para controle da correlação espacial e espaço-temporal da produtividade de soja provocada pelo risco sistêmico. Para alcançar esse objetivo, utiliza-se a Análise Exploratória de Dados Espaciais (AEDE), correlogramas espaciais e econometria espacial aplicada às produtividades médias municipais de milho, soja e sinistralidade média. Mediante a aplicação da AEDE, os resultados revelaram a existência de influência espacial relativamente alta nas produtividades de milho e de soja, entretanto, apenas para soja existe indícios de que ao comparar espacialmente os anos atingidos por déficit hídrico os municípios possuem maiores similaridades espaciais. Na aplicação dos correlogramas espaciais, os resultados mostram que existem influências espaciais e espaço-temporais ao analisar a produtividade média e sinistros de milho e soja, com maiores distâncias de influência espacial ocorrendo em anos atingidos por efeitos climáticos. No ajuste de modelos STARMA, os modelos ajustados para os municípios do Brasil e para os municípios do Paraná não conseguiram captar os efeitos espaço-temporais, enquanto o modelo com 9 municípios que mais produzem soja no Paraná atendeu o diagnóstico dos resíduos e pode ser utilizado para a correta precificação do risco do seguro agrícola. Portanto, conclui-se que para o seguro agrícola é importante o conhecimento das similaridades espaciais da produtividade de milho e soja, em função dos riscos sistêmicos que possam ocorrer em anos com adversidades climáticas e a aplicação de modelos da classe STARMA para controle da correlação espacial em dados de produtividade.

Palavras-chave: Seguro agrícola, Soja, Milho, Correlação espacial, STARMA

ABSTRACT

Spatial analysis for agricultural insurance: a case study in Paraná

Agricultural activity plays an important role for Brazil's economic growth, with national and international prominence for corn and soybean production due to being the one stumiest in crop areas with national and international prominence for corn and soybean production due to being the one stumiest in crop areas. In this context, these activities are highly dependent on climate conditions and to protect themselves from climate fluctuations, producers may take out agricultural insurance to transfer the risks to the insurance market. Insurers are based on the assumption of independence between events, however, a catastrophic event affects many producers, so that the assumption of independence is violated and the average productivity data of the municipalities are spatially correlated. Thus, the main objective of this thesis is to analyze the behavior of spatial influences of corn and soybean yield in the municipalities of Paraná to compare the intensity of spatial correlation in years with and without weather in addition to proposing the use of STARMA models as an alternative to control the spatial and space-time correlation of soybean yield caused by systemic risk. To achieve this goal, Exploratory Spatial Data Analysis (ESA) is used. Spatial correlograms and spatial econometrics applied to municipal average yields of corn, soybean and average loss. Through the application of the ESA, the results revealed the existence of a relatively high spatial influence on corn and soybean yields. However, only for soybeans there are indications that when spatially comparing the years affected by water deficit, the municipalities have higher spatial similarities. In the application of spatial correlograms, the results show that there are spatial and space-time influences when analyzing the average productivity and corn and soy claims, with greater distances of spatial influence occurring in years affected by climate effects. In the adjustment of STARMA models, the models adjusted for the municipalities of Brazil and for the municipalities of Paraná could not capture the space-time effects, while the model with 9 municipalities that produce soybean sums the most in Paraná met the diagnosis of waste and can be used for the correct pricing of agricultural insurance risk. Therefore, it is concluded that for agricultural insurance it is important to know the spatial similarities of corn and soybean yield, due to systemic risks that may occur in years with climatic adversities and the application of STARMA class models to control spatial correlation in productivity data.

Keywords: Agricultural insurance, Soy, Corn, Spatial correlation, STARMA

LISTA DE FIGURAS

Figura 1. Representação gráfica do diagrama de dispersão de <i>Moran</i>	22
Figura 2. Localização geográfica das mesorregiões do estado do Paraná	24
Figura 3. Produtividade de Milho e de Soja com e sem tendência para o Paraná, no período de 2000 a 2018.	25
Figura 4. Box Map da produtividade de Milho nos municípios do Paraná nos anos de 2008 a 2018.	26
Figura 5. Box Map da produtividade de Soja nos municípios do Paraná nos anos de 2008 a 2018.	27
Figura 6. Box Map do coeficiente de variação da produtividade de Milho (a) e Soja (b) nos municípios do Paraná nos anos de 2000 a 2018.	28
Figura 7. Mapa de clusters da produtividade de Milho nos municípios do Paraná nos anos de 2008, 2009 e 2010.	31
Figura 8. Mapa de clusters da produtividade de Soja nos municípios do Paraná nos anos de 2008, 2009 e 2010.	32
Figura 9. Diagrama de dispersão de Moran e Mapa de cluster do coeficiente de variação para produtividade de Milho (a) e Soja (b) no Paraná, no período de 2008 a 2018.....	33
Figura 10. Distribuição da estatística espaço-temporal de Moran nos lags espaciais para a produtividade de milho e soja, no período de 2008 a 2018.	34
Figura 11. Importância segurada da produção do milho da primeira e segunda safra e o valor da subvenção total no Paraná, nos anos de 2007 a 2018.	50
Figura 12. Valor das indenizações pagas aos produtores de milho da produção do milho segunda safra no Paraná, nos anos de 2007 a 2018.	51
Figura 13. Comparativo entre o total pago pelos prêmios e suas indenizações para produção de milho segunda safra no Paraná, nos anos de 2007 a 2018.....	51
Figura 14. Prêmio total, indenizações pagas (a) e importância segurada (b) para produção de soja no Paraná, nos anos de 2006 a 2018.	53
Figura 15. Decisão do Processo de Regressão Espacial.....	57
Figura 16. Correlogramas espaciais da produtividade do milho da segunda safra do Paraná, nos anos de 2013 a 2018.....	60
Figura 17. Correlogramas espaciais da produtividade da soja no Paraná, nos anos de 2013 a 2018.	61

Figura 18. Correlogramas espaciais da sinistralidade média do milho da segunda safra do Paraná, nos anos de 2013 a 2018.	61
Figura 19. Correlogramas espaciais da sinistralidade média da soja no Paraná, nos anos de 2013 a 2018.	62
Figura 20. Gráfico da função de autocorrelação espaço-temporal.	83
Figura 21. Gráfico da função de autocorrelação espaço-temporal (a) e função de autocorrelação parcial espaço-temporal (b) para primeira diferença na série de dados para os 721 municípios do Brasil.	84
Figura 22. Gráfico do histograma e normalidade dos resíduos.	85
Figura 23. Gráfico da função de autocorrelação espaço-temporal para os resíduos do modelo ajustado.	85
Figura 24. Gráfico da função de autocorrelação espaço-temporal.	86
Figura 25. Gráfico da função de autocorrelação espaço-temporal (a) e função de autocorrelação parcial espaço-temporal (b) para primeira diferença na série de dados para os 242 municípios do Paraná.	87
Figura 26. Gráfico do histograma e normalidade dos resíduos.	88
Figura 27. Gráfico da função de autocorrelação espaço-temporal para os resíduos do modelo ajustado.	88
Figura 28. Gráfico da função de autocorrelação espaço-temporal.	89
Figura 29. Gráfico da função de autocorrelação espaço-temporal (a) e função de autocorrelação parcial espaço-temporal (b) para primeira diferença na série de dados para os 9 municípios do Paraná.	89
Figura 30. Gráfico do histograma e normalidade dos resíduos.	90
Figura 31. Gráfico da função de autocorrelação espaço-temporal para os resíduos do modelo ajustado.	91

LISTA DE TABELAS

Tabela 1. Estatística I Moran Global para a cultura de milho nos anos de 2008 a 2018.....	29
Tabela 2. Análise espacial bivariada da produtividade de Milho e Soja, utilizando como referência os anos de 2009 e 2012 com intempéries climáticas	35
Tabela 3. Causas dos sinistros acionados para o milho primeira safra no Paraná nos anos de 2007 a 2018	48
Tabela 4. Causas dos sinistros acionados para o milho segunda safra no Paraná nos anos de 2007 a 2018	49
Tabela 5. Estatística descritiva para sinistralidade média da produtividade do milho segunda safra, Paraná, no período de 2013 a 2018.....	52
Tabela 6. Causas dos sinistros acionados para a soja no Paraná nos anos de 2007 a 2018.....	52
Tabela 7. Estatística descritiva para sinistralidade média da produtividade da soja no Paraná, nos anos de 2013 a 2018.....	54
Tabela 8. Estimativa, em km, da influência espacial para produtividade e sinistralidade do milho e da soja no Paraná, no período de 2013 a 2018.	63
Tabela 9. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial em relação às sinistralidades médias do milho segunda safra de 2018.	64
Tabela 10. Modelo de regressão espacial aplicado para analisar a correlação espacial e espaço-temporal em relação às sinistralidades médias do milho segunda safra de 2018.....	65
Tabela 11. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial das sinistralidades médias do milho em relação a sua produtividade anual	65
Tabela 12. Modelo de regressão espacial aplicado para analisar a correlação espacial das sinistralidades média do milho em relação a sua produtividade anual.....	66
Tabela 13. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial em relação às sinistralidades médias da soja de 2018	66
Tabela 14. Modelo de regressão espacial aplicado para analisar a correlação espacial e espaço-temporal em relação às sinistralidades médias da soja de 2018.....	67
Tabela 15. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial sinistralidades médias da soja em relação a sua produtividade anual	67
Tabela 16. Modelo de regressão espacial aplicado para analisar a correlação espacial sinistralidades médias da soja em relação a sua produtividade anual.	68
Tabela 17. Comportamento das FAC e FACP espaço-temporal dos modelos STAR, STMA e STARMA.	81

Tabela 18. Resultado do modelo STARIMA (3 ₁ , 1, 3).....	84
Tabela 19. Resultado do modelo STARIMA (19 ₁ , 1, 14 ₁)	87
Tabela 20. Resultado do modelo STARIMA (14 ₁ , 1, 10 ₁)	90

1. INTRODUÇÃO

As atividades desenvolvidas no campo se apresentam como um importante elemento para o crescimento econômico do Brasil, devido a ser fonte de alimentação, matéria prima e energia. Dentre essas atividades, a agricultura é a grande responsável por esse crescimento, principalmente por causa da produtividade de milho e soja, as quais se destacam no cenário nacional e internacional.

De acordo com as informações do Ministério da Agricultura, Pecuária e Abastecimento (MAPA), por meio das projeções do agronegócio, estima-se que a produção de milho para a safra 2028/2029 atinja a marca de 114,5 milhões de toneladas, com 20,2% de aumento em relação à safra de 2018/2019 e aumento de 33,4% em sua exportação, com estimativa de expansão da área cultivada em 7,2%; entretanto, esta expansão é contida pelo fato de a soja liberar novas terras para seu plantio. Na mesma crescente, a produção de soja pode chegar em 151,87 milhões de toneladas na safra de 2028/2029, onde são esperados 32,9% de crescimento acumulado para o período e uma expansão de 26,6% de sua área projetada em relação à safra 2028/2029 (BRASIL, 2019).

Nesse contexto, a produção de milho e soja possui grande importância em determinadas regiões, principalmente por conta da maior adaptação do clima e solo para plantio, como é o caso do Paraná, o estado é um dos grandes produtores nacionais. Ao considerar sua participação no *ranking* nacional na safra 2018/2019, o estado fica em segundo lugar na produção de milho, alcançando 16,7%, e terceiro em relação à produção de soja, com 14,2% (BRASIL, 2019).

Vale ressaltar que, embora a produção agrícola seja praticada em regiões mais propícias para seu cultivo, os produtores estão sujeitos a diversos riscos associados a esse setor, como, por exemplo, riscos de produção, mercado, financeiro, legal e humano. Sendo assim, pelo fato de os produtores não terem condições de controlar os riscos de produção e de mercado, estes se tornam os que mais impactam a sua renda, uma vez que o risco de mercado ocorre em função da volatilidade dos preços dos produtos agrícolas e de insumos, enquanto o risco de produção está associado ao uso inadequado de tecnologias, incêndios, doenças, pragas e adversidades climáticas (BRISOLARA; OZAKI, 2022; DUARTE *et al*, 2018).

Nesse sentido, o risco de produção por meio da ocorrência de condições edafoclimáticas pode provocar grandes perdas na produção agrícola de uma determinada região, principalmente pela forte dependência da atividade agrícola em relação à natureza,

gerando riscos para a atividade que vem se agravando por causa da instabilidade climática, às mudanças nos regimes de chuva e ao próprio aquecimento global (FERREIRA, 2014).

Salienta-se que o estado do Paraná é muito sensível ao clima, de maneira que está suscetível a ocorrências de grandes estiagens, altas temperaturas, chuvas excessivas e intensas geadas. Conforme o Boletim mensal do Departamento de Economia Rural (Deral) da Secretaria da Agricultura e Abastecimento (2019), no ano de 2018 houve períodos de estiagem, chuvas excessivas e altas temperaturas ao longo do ciclo de desenvolvimento das culturas de milho e soja. Segundo o boletim, a safra de soja teve redução de 14%, entretanto, o milho foi pouco afetado em função da resistência das lavouras com o clima seco.

Essa oscilação da produção agrícola brasileira impacta demasiadamente tanto o agricultor empresarial quanto o agricultor familiar, demandando novos mecanismos para se gerir esses riscos. Nesse caso, o seguro agrícola se apresenta como um dos mecanismos mais importantes para lidar com tais riscos. O seguro é um mecanismo de política agrícola que desempenha importante papel na proteção da renda do produtor rural, atuando na minimização dos riscos de perdas da produção agropecuária, permitindo a recuperação de sua capacidade financeira na possibilidade de sinistros por causas naturais incontroláveis. (SANTOS; SOUSA; ALVARENGA, 2013; ALMEIDA, 2014).

No modelo brasileiro de seguro agrícola para produtividade são cobertas as atividades contra perdas na produção decorrentes de fenômenos meteorológicos (climáticos e pluviométricos). Dessa forma, o seguro agrícola é um mecanismo para a estabilização financeira dos produtores, assim como uma mercadoria para as seguradoras (OZAKI, 2008; RAMOS, 2009).

Contudo, existem alguns desafios que prejudicam a implementação e o pleno funcionamento do seguro, sendo eles: informações assimétricas entre produtor e seguradora, seleção adversa, risco moral e risco sistêmico. Este último ocorre quando um fenômeno climático causa perdas à produção de uma determinada cultura e atinge não somente um produtor, mas uma extensa área de terra com diversos outros produtores, violando a suposição básica da segurabilidade que supõe independência entre os sinistros e resulta em um elevado pagamento de indenizações (AKERLOF, 1970; OZAKI, 2005).

Nesse contexto, a precificação do seguro agrícola se torna muito complicada e OZAKI (2007, p.87) faz as seguintes ponderações:

- i) dificuldades de ordem amostral – neste caso o tamanho das séries históricas de produtividade é relativamente pequeno, impossibilitando a detecção de qualquer tipo de padrão e a aplicação dos testes estatísticos convencionais; ii) problemas de correlação espacial – decorre do fato de que propriedades (municípios) mais próximas apresentam maior dependência espacial em relação a propriedades

(municípios) mais afastadas; iii) correlação serial – quando a produtividade em anos anteriores está correlacionada com a produtividade no ano atual; iv) presença de tendência – a produtividade observada em 1980, por exemplo, não pode ser comparada com a produtividade observada em 2004. Isto porque a incorporação de tecnologia pelos produtores ao longo dos anos proporcionou aumento considerável no rendimento agrícola; e, v) heteroscedasticidade – é a situação em que os dados apresentam variabilidade não constante. Todos estes fatores dificultam sobremaneira a análise dos dados. Ignorá-los podem levar a resultados completamente equivocados (OZAKI, 2007, p. 87).

É comum na literatura o controle dos problemas dos itens iii), iv) e v) sobre correlação serial, presença de tendência e heterocedasticidade, respectivamente. Porém, o problema de correlação espacial (causada pelo risco sistêmico) não possui o tratamento adequado e, como o autor afirma, não se pode ignorá-los. Portanto, esta tese, por meio de seus dois primeiros artigos, pretende testar a hipótese da existência de correlação espacial e espaço-temporal nos dados de produtividade agrícola em anos em que ocorrem intempéries climáticas; e no seu terceiro artigo propõe testar a adequação de modelos STARMA para controlar os efeitos espaço-temporais que precisam ser corrigidos para alcançar antes das seguradoras precificarem o seguro.

O objetivo principal desta tese é analisar o comportamento das influências espaciais da produtividade de milho e de soja nos municípios do Paraná, para comparar a intensidade da correlação espacial em anos com e sem intempéries climáticas, além de propor o uso de modelos STARMA como alternativa para controle da correlação espacial e espaço-temporal da produtividade de soja provocados pelo risco sistêmico. Para alcançar esse objetivo, a tese será composta por três artigos.

O Artigo 1 irá analisar as influências espaciais da produtividade média de milho e de soja, aplicando técnicas de Análise Exploratória de Dados Espaciais para os municípios do Paraná, no período de 2008 a 2018. O Artigo 2 verificará de que forma as mudanças climáticas interferem no seguro agrícola, por meio das influências espaciais ocorridas na produtividade média do milho segunda safra, soja e das sinistralidades médias produtores, aplicando correlogramas espaciais para medir a distância de influência espacial e econometria espacial para aferir os efeitos espaciais e espaço-temporal.

Por último, a proposta do Artigo 3 é ajustar a série de produtividade de soja por meio do modelo Autorregressivo e Média Móvel espaço-temporal (STARMA) em três bases de dados, a primeira contendo os 75% municípios que mais produzem soja no Brasil, a segunda todos os municípios do Paraná com dados disponíveis e por último com os 9 municípios que mais produzem soja no Paraná.

Referências

- ALMEIDA, M. F. Os desafios para o desenvolvimento do seguro rural privado no Brasil – O ponto de vista do Resseguro. In: Buainain, A. M.; Vieira, P. A.; Cury, Q. J. M. (Org.). **Gestão do risco e seguro na agricultura brasileira**. Rio de Janeiro: Funenseg, 2014.
- AKERLOF, G.A. The market for "lemons": quality uncertainty and the market mechanism. **Quartely Journal of Economisc**, v.84, n.3, p.488-500, Aug. 1970.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Projeções do agronegócio: Brasil 2018/2019 a 2028/2029**, projeções de longo prazo. Brasília, DF, 2015. Disponível em: <http://www.agricultura.gov.br/assuntos/politica-agricola/todas-publicacoes-de-politica-agricola/projecoes-do-agronegocio/projecoes-do-agronegocio-2018-2019-2028-2029>>. Acesso em: 19 Fev. 2020.
- BRISOLARA, C. S.; OZAKI, V. A. Uma proposição metodológica para a precificação de seguro de receita agrícola no Brasil. **Revista de Economia e Sociologia Rural**. 60(2), 2020. <https://doi.org/10.1590/1806-9479.2021.235656>
- DUARTE, G. V.; BRAGA, A.; MIQUELLUTI, D. L.; OZAKI, V. A. Modeling of soybean yield using symmetric, asymmetric and bimodal distributions: implications for crop insurance. **Journal of Applied Statistics**. v. 45, 2018.
- FERREIRA, B. S. Análise a respeito do seguro agrícola no Brasil: O ponto de vista dos fornecedores. In: Buainain, A. M.; Vieira, P. A.; Cury, Q. J. M. (Org.). **Gestão do risco e seguro na agricultura brasileira**. Rio de Janeiro: Funenseg, 2014.
- OZAKI, V. A. **Métodos atuariais aplicados à determinação da taxa de prêmio de contratos de seguro agrícola: um estudo de caso**. Tese (Doutorado em Economia Aplicada) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2005. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11132/tde-11072005-160540/publico/VitorOzaki.pdf>. Acesso em 08 abr. 2018.
- _____. O papel do seguro na gestão do risco agrícola e os empecilhos para o seu desenvolvimento. **Rev. Bras. Risco Seguro** 2(4): 75-92, 2007.
- _____. Análise espacial da produtividade agrícola no Estado do Paraná: implicações para o seguro agrícola. **Revista de Economia e Sociologia Rural**, v.46, n.3, p.869-886, 2008.
- RAMOS, Rejane Cecília. O seguro rural no Brasil: origem, evolução e proposições para aperfeiçoamento. **Revista Informações Econômicas**, SP, v.39, n.3, mar. 2009.

Disponível em: <http://www.iea.sp.gov.br/ftpiea/publicacoes/IE/2009/tec1-0309.pdf>.
Acesso em 10 jan.2020.

SANTOS, G. R dos; SOUSA, A. G. de; ALVARENGA, G. Seguro agrícola no Brasil e o desenvolvimento do programa de subvenção ao prêmio. **Texto para Discussão** – IPEA, 2013. Disponível em;
https://www.ipea.gov.br/agencia/images/stories/PDFs/TDs/td_1910.pdf. Acesso em 06 jan. 2020.

2. DINÂMICAS ESPACIAIS DA PRODUTIVIDADE DE MILHO E SOJA NO PARANÁ: CONSEQUÊNCIAS PARA O SEGURO AGRÍCOLA

Resumo

O objetivo deste trabalho é analisar a influência espacial e espaço-temporal da produtividade de milho e de soja nos municípios do Paraná, mensurando a similaridade espacial em anos atingidos por efeitos climáticos para apontar possíveis implicações para o seguro agrícola. Para alcançar esse objetivo, utiliza-se a Análise Exploratória de Dados Espaciais aplicada às produtividades médias municipais de milho e soja, nos anos de 2008 a 2018. Os resultados revelaram a existência de influência espacial relativamente alta nas produtividades de milho e de soja, com a formação de *clusters* Alto-Alto e Baixo-Baixo em várias regiões ao longo do tempo, em que se observa um efeito espaço-temporal com similaridade mais acentuada na produtividade do milho do que na de soja. Entretanto, apenas para soja existe indícios de que ao comparar espacialmente os anos atingidos por déficit hídrico, os municípios possuem maiores similaridades espaciais, isto é, as perdas da produtividade dos municípios em anos atingidos por secas são semelhantes espacialmente. Portanto, conclui-se que para o seguro agrícola é importante o conhecimento das similaridades espaciais da produtividade de milho e soja em função dos riscos sistêmicos que possam ocorrer em anos com adversidades climáticas.

Palavras-chave: Seguro agrícola, Influência espaço-temporal, Soja, Milho, Paraná.

Abstract

The objective of this paper is to analyze the spatial and space-time influence of corn and soybean yield in the municipalities of Paraná, measuring spatial similarity in years affected by climate effects to point out possible implications for agricultural insurance. To achieve this goal, exploratory spatial data analysis applied to average corn and soybean yields in the years 2008 to 2018 is used. The results revealed the existence of high spatial influence in corn and soybean yields, with the formation of High-High and Low-Low clusters in various regions over time, in which a space-time effect with a more marked similarity in corn yield than in soybean yield is observed. However, only for soybeans there are indications that when spatially comparing the years affected by water deficit, the municipalities have greater spatial similarities, that is, the productivity losses of municipalities in drought-stricken years are similar spatially. Therefore, it is concluded that for agricultural insurance it is important to know the spatial similarities of corn and soybean yield, due to systemic risks that may occur in years with climatic adversities.

Keywords: Agricultural insurance. Space-time influence. Soy. Corn. Paraná.

2.1. Introdução

Nas últimas décadas, a aplicação de novas tecnologias tem gerado mudanças na estrutura produtiva do milho e da soja, principalmente em regiões que possuem diversos riscos relacionados a sua produção, como por exemplo, os ocorridos por efeitos climáticos,

pragas, doenças e variações nos preços. Apesar dos avanços tecnológicos, as perdas ocasionadas por eventos climáticos ainda são relativamente elevadas (ARIAS *et al.*, 2015).

Nesse contexto, os produtores podem contratar o seguro agrícola para transferir as consequências dos riscos para o mercado segurador. Nesse esquema de proteção, o produtor paga um prêmio para garantir parte do recurso investido na safra, caso a sua produção fique abaixo do estabelecido em contrato. Contudo, a seguradora que atua nesse segmento está exposta a eventos catastróficos, por exemplo, a seca, que pode atingir centenas de propriedades em um curto espaço de tempo. Esse tipo de risco é denominado risco sistêmico e acarreta perdas consideráveis de produção, provocando um alto número de sinistros e um elevado pagamento de indenizações (OZAKI, 2007; OZAKI, 2008; FAVRO, 2014).

Nesse sentido, nota-se que as regiões propícias ao risco sistêmico apresentam similaridades espaciais que influenciam a produtividade do milho e da soja. Neste estudo pretende-se verificar a existência do risco sistêmico, sua influência espacial e seu impacto para o seguro agrícola. A existência desse risco pode afetar consideravelmente os resultados das carteiras das companhias seguradoras, em particular, afetar a precificação, subscrição e a forma de dispersão de risco adotada pelo mercado (OZAKI, 2008; EMBRAPA, 2016).

Dessa forma, para mensurar os efeitos espaciais, a análise exploratória de dados espaciais pode ser empregada para efetuar esse diagnóstico, por meio de estatísticas de autocorrelação espacial, em que se verifica o quanto os municípios estão relacionados com seus vizinhos, isto é, seu grau de similaridade espacial ou influência espacial (ANSELIN, 2000).

Na literatura existem trabalhos que detectaram dinâmica espacial decorrente de similaridades dos municípios vizinhos em torno das regiões produtoras de milho e de soja (VIEIRA; PARRÉ, 2008; FAVRO, 2014; FELEMA, 2016; VIDIGAL *et al.*, 2018). Entretanto, não abordam quais diferenças nas dinâmicas espaciais ocorrem em anos acometidos por intempéries climáticas, e como isso pode influenciar o mercado de seguro agrícola. Portanto, o objetivo principal deste trabalho é analisar as dinâmicas do comportamento espacial e espaço-temporal da produtividade municipal de milho e soja no estado do Paraná nos anos de 2008 e 2018.

Este trabalho está dividido em seções, além desta introdução, como primeira seção, a segunda contém uma discussão acerca da relação da análise espacial com o seguro agrícola; a terceira apresenta a área de estudo com os métodos de análise espacial empregados; em seguida, apresenta-se os resultados e discussões e, por fim, as considerações finais.

2.2. Análise espacial e o seguro agrícola

A Análise Espacial surgiu em meados da década de 1970, com o surgimento dos Sistemas de Informações Geográficas - SIG¹. Sua aplicação se tornou viável em diversas áreas do conhecimento, dando origem a subáreas da Análise Espacial, que possuem diferentes abordagens, como, por exemplo, a estatística espacial, econometria espacial e geoestatística. Independentemente de qual for a abordagem, a Análise Espacial busca estudar a influência do espaço no desempenho de fenômenos naturais ou sociais, utilizando um conjunto de técnicas matemáticas e estatísticas para alcançar esse objetivo (LLOYD, 2007; D'ANDREA, 2018).

A Análise Exploratória de Dados Espaciais (AEDE) se diferencia das técnicas estatísticas clássicas no sentido de não seguir a premissa de aleatoriedade da disposição dos dados que serão analisados, na qual se espera a existência de relação entre as unidades espaciais. Essa ferramenta é designada para o levantamento de informações espacialmente localizadas com o intuito de verificar a associação espacial e heterogeneidade espacial na base de dados, identificando padrões na relação de influência espacial (clusters espaciais), instabilidade espacial e observações atípicas (outliers) (BAILEY; GATTREL, 1995; ANSELIN, 2000; PEROBELLI; FARIA; FERREIRA, 2009).

Nesse contexto, os estudos são realizados para analisar a interação e influência espacial entre as variáveis de interesse. No Brasil, um dos ramos mais investigados pela AEDE é sua aplicação na produção de grãos. Na literatura, existem diversos trabalhos que verificaram a influência espacial na produtividade de grãos, os quais encontraram resultados que sustentam a hipótese de que existe um efeito espacial decorrente de similaridades dos municípios vizinhos em torno das regiões produtoras (PEROBELLI *et al.*, 2007; VIEIRA; PARRÉ, 2008; VIDIGAL *et al.*, 2011; DINIZ *et al.*, 2012; FAVRO, 2014; TEIXEIRA; BERTELLA, 2015; FELEMA, 2016; VIDIGAL *et al.*, 2018).

Diante desse cenário, a atividade agrícola está sujeita a diversos riscos exógenos à gestão do empreendimento rural, advindas de intempéries climáticas, pragas e doenças que possam atingir a produção, o que pode levar ao impacto de múltiplos produtores por extensas áreas, causando perdas que extrapolem as fronteiras da fazenda, município ou região (LOPES *et al.*, 2017).

¹ Um Sistema de Informação Geográfica (SIG) é formado por um acervo de programas computacionais, que compreende pessoas, dados e equipamentos para a manipulação de dados espacialmente referenciados em um sistema de coordenadas conhecido.

Os riscos mencionados são conhecidos como riscos sistêmicos, sendo ligados diretamente à correlação espacial nos dados, pois quando um fenômeno climático atinge uma região, os produtores rurais que estejam nessa área sofrem perdas em conjunto. Por isso que, no contexto do mercado de seguro, esse risco é um dos grandes problemas que o ramo das seguradoras privadas precisa enfrentar, visto que essa situação viola a existência de independência entre as unidades seguradas, elevando o risco individual para um nível agregado (MIRANDA; GLAUBER, 1997; OZAKI, 2007; OZAKI, 2008; WOODARD *et al.*, 2012).

O produtor, ao se proteger por meio do seguro agrícola, garante uma indenização quando seu rendimento observado for inferior ao nível garantido. Para isso, paga-se um prêmio na contratação do seguro e seguir as normas compreendidas no contrato (OZAKI e DIAS, 2009).

O problema de informações assimétricas é de que um dos agentes econômicos detém mais informações do que o outro sobre o bem ou serviço contratado. Nesse caso, as firmas fixam seus preços considerando o que os consumidores irão inferir sobre seu produto, no entanto, isso impede a eficácia da competição de preços, provocando um equilíbrio fora da interseção das curvas de oferta e demanda (GUIMARÃES; NOGUEIRA, 2009).

Em relação ao seguro agrícola, as informações assimétricas se manifestam na presença da seleção adversa e risco moral. Na primeira, cada produtor possui uma quantidade elevada de informação sobre seus riscos em relação aos demais que atuam no mercado de seguro, em que conhecem suas probabilidades de perdas, possibilitando que apenas os produtores que atuam nas regiões e de atividades de maiores riscos contratem o seguro, porém, as seguradoras não conseguem distinguir os clientes de baixo e alto risco, e logo precificam o seguro com um preço médio para todos que estejam no mesmo município (McCARTY, 1941; AKERLOF, 1970; GOODWIN, 1993; QUIGGIN *et al.*, 1994; COBLE; KNIGHT, 2002).

Desse modo, isso significa que as seguradoras cobram o mesmo valor tanto para os que são de alto risco quanto para os de baixo risco, provocando uma evasão de possíveis clientes que são de baixo risco, em virtude do alto preço adotado para pagamento do prêmio do seguro, “beneficiando” os de alto risco com um subsídio que fará com que comprem mais cobertura do que os de baixo risco, o que implica que as seguradoras fiquem apenas com um conjunto de clientes de alto risco, podendo levar a prejuízos no pagamento de indenizações acima dos previstos (AKERLOF; 1970; OZAKI, 2005; MOTA, 2019).

No risco moral, após os agentes econômicos (contratante ou contratado) firmarem um serviço, uma das duas partes alteram seu comportamento pela incapacidade do outro o

monitorar provocando um aumento na probabilidade de um sinistro. No caso do seguro agrícola, as seguradoras não possuem o controle sobre os fatores de produção de seus clientes, o que pode levar um produtor a maximizar sua utilidade esperada, empregando uma quantidade menor de insumo. Essa atitude eleva o risco de perda, o que implica no aumento da probabilidade do recebimento de indenizações (AKERLOF; 1970; GOODWIN, 1993; OZAKI, 2005; WENNER; ARIAS, 2003; MOTA, 2019).

Nesse contexto, o estudo das relações de influência espacial da produtividade de milho e de soja são de extrema importância para que as seguradoras identifiquem a dinâmica espacial entre os municípios e seus vizinhos, para poder diversificar sua atuação entre as regiões que apontem diferentes tipos de riscos, para amenizar suas perdas, considerando não apenas a produtividade de um município, mas todo um *cluster* espacial na tomada da precificação do seguro.

2.3. Metodologia

2.3.1 Análise Exploratória de Dados Espaciais - AEDE

A utilização eficiente da AEDE necessita do uso de variáveis intensivas ou espacialmente densas. O uso de valores absolutos não é indicado e isso pode gerar correlações espaciais entre variáveis de escala, ocasionando em correlações espaciais espúrias. Nesse sentido, a análise pode ser executada medindo a autocorrelação espacial global e local, proporcionando inferências com base em análises criteriosas e racionais. Em virtude desse alerta, esta pesquisa utilizará os dados de produtividade média para milho e soja ao invés da produção (ANSELIN, 1995; ALMEIDA, 2012).

No que se refere às ferramentas da AEDE para construção dos resultados, esta pesquisa utilizará o cálculo da estatística I de Moran Global e Indicadores Locais de Associação Espacial (LISA) que medem o grau de autocorrelação espacial entre os municípios e seus vizinhos. A obtenção dessa métrica é obtida utilizando uma matriz de proximidade espacial, na qual serão testadas as matrizes de contiguidade Torre e Rainha, enquanto a matriz de distância será por meio da distância Euclidiana com KNN vizinhos (MORAN, 1948; ALMEIDA, 2008; ARAÚJO *et al.*, 2014; ANSELIN; REY, 2014; FORTIN; DALE, 2014).

Uma forma de representar o I de Moran é por meio do gráfico de dispersão da Figura 1, a qual apresenta o diagrama de dispersão de Moran dividido em quatro quadrantes, com uma reta de regressão passando através da origem, sendo a inclinação dada pela estatística I,

que determina seu grau de ajustamento. Cada quadrante sinaliza um tipo de associação espacial (TEIXEIRA *et al*, 2010).




Figura 1. Representação gráfica do diagrama de dispersão de Moran

Fonte: Druck *et al.* (2004).

Os quadrantes do diagrama de dispersão de Moran permitem classificar as associações espaciais distribuídas em quatro padrões que dependem do quadrante em que seus vizinhos estão presentes. Caso fique no primeiro, é denominado como Alto-Alto (AA), representando valores de regiões que ficam acima da média e que também possuem regiões vizinhas que ficam acima da média dos valores de z e Wz , respectivamente. O segundo quadrante apresenta regiões com baixos valores, mas com vizinhos acima da média, sendo denominado de Baixo-Alto (BA). No terceiro quadrante é composto de regiões com valores baixos que também possuem vizinhos com valores baixos, denominados de Baixo-Baixo (BB). As regiões com valores acima da média com vizinhos com valores baixos, denominados de Alto-Baixo (AB) estão presente no quarto quadrante (ANSELIN, 1995).

A representação gráfica da associação local espacial é denominada de Moran Map. A função desse mapa é apresentar um panorama visual das regiões de estudo que possuem correlação local significativamente divergente das demais. A função desse mapa é indicar as associações locais significantes a 5% (em cores) e as não significativas (sem cores), classificadas de acordo com a associação discutida dos quatro grupos nos quadrantes do diagrama de dispersão de Moran (KREMPI, 2004).

Para a análise espacial bivariada, a Análise Exploratória de Dados Espaços-Temporais (ESTDA) utiliza as mesmas técnicas vistas anteriormente, uma vez que será considerada uma variável observada em dois instantes de tempo diferentes. Nesse caso, tem-se para análise de dependência espacial a estatística I de Moran espaço-temporal, o diagrama de dispersão de Moran espaço-temporal e o gráfico de linha I de Moran (LOPEZ, 2004).

O gráfico da linha I de Moran é composto pelos seus coeficientes dispostos no eixo vertical em relação as suas defasagens no tempo no eixo horizontal. Esse artifício possibilita analisar que os coeficientes significativos do *I* de Moran próximos do momento atual (*lag* 0) apresenta um processo de difusão espacial rápido. Por outro lado, valores significativos distantes do *lag* atual apontam uma difusão espacial mais lenta, portanto, esse gráfico proporciona a visualização da dependência temporal em um período (LOPEZ, 2004).

2.3.2. Ajuste da tendência

Diante do avanço tecnológico empregado para o aumento da produtividade de milho e de soja ao longo do tempo, isso pode gerar uma tendência na série dos dados de produtividade média das culturas. Para que esse efeito não interfira nas análises espaciais, torna-se necessário o ajuste da série para retirar essa tendência.

A tendência presente nas séries será retirada aplicando a abordagem utilizada por Duarte (2018) que consiste em estimar um modelo linear da produtividade em função do tempo, dado por:

$$y_t = \alpha + \beta T + \gamma T^2 + e_t, \quad e_t \sim N(\mu, \sigma) \quad (1)$$

Onde y_t é o vetor de produtividade; T é o vetor de tempo e α , β , e γ os parâmetros da regressão. Os dados ajustados sem a tendência serão obtidos a partir dos resíduos da regressão e a estimativa da última observação da produtividade, calculado por:

$$\bar{y}_t = \hat{y}_t \left(1 + \frac{\hat{e}_t}{\hat{y}_t}\right) \quad (2)$$

2.3.3. Descrição dos dados

Os dados referentes às produtividades médias anuais de milho e soja dos 399 municípios são provenientes do Sistema de Recuperação Automática (Sidra) e os *shapefiles* do Instituto Paranaense de Desenvolvimento Econômico e Social (IPARDES). A Figura 1 mostra a distribuição espacial dos municípios com suas respectivas mesorregiões.



Figura 2. Localização geográfica das mesorregiões do estado do Paraná.
Fonte: IPARDES (2019).

Como o intuito da pesquisa é comparar as similaridades espaciais da produtividade de milho e soja em anos que ocorreram intempéries climáticas, optou-se por utilizar dados mais recentes, em função da perda do efeito espaço-temporal ao longo do tempo, isto é, quanto maior for o *lag* entre os anos comparados, menor será a similaridades espaço-temporal (QUEIROZ *et al.*, 2018).

Nesse sentido, selecionou-se o período de 2008 a 2018 para realizar as análises, devido a compreender os anos de 2009, 2012 e 2016, nos quais ocorreram intempéries climáticas que afetaram a produção de milho e soja no estado (PARANÁ, 2009; EMBRAPA 2016). Os dados faltantes foram imputados aplicando a média aritmética da produtividade nos anos vizinhos e, posteriormente, a tendência retirada conforme abordagem realizada por Duarte *et al.* (2018). Para imputação dos dados e retirada da tendência foi utilizado o período de 2000 a 2018, apenas para aumentar o intervalo do tempo para melhorar a estimação da tendência.

2.4. Resultados e discussões

Nesta seção são apresentados os resultados da análise de autocorrelação por índices de Moran univariado e bivariado, além de analisar sua similaridade ao longo do tempo. No primeiro momento, é realizada a análise univariada da produtividade de milho e soja, analisando a influência espacial nos anos de 2008 a 2018, e da medição dos riscos medidos pelo coeficiente de variação no período de 2000 a 2018. Em seguida, a análise bivariada é construída para relacionar os espaços e tempo, com o intuito de verificar a influência espaço-temporal nos períodos de estudo.

A retirada da tendência dos dados de produtividade de soja e milho é apresentada na Figura 3. Verifica-se que existe uma queda da produtividade média de milho e de soja em 2009, 2012 e 2016, uma vez que foram atingidos por intempéries climáticas. O tratamento da análise exploratória de dados espaciais foi realizado com o uso do software livre *Geodata AnalySys* (GeoDa).




Figura 3. Produtividade de Milho e de Soja com e sem tendência para o Paraná, no período de 2000 a 2018.
Fonte: Elaboração própria.

Para início da análise, precisa-se entender a dinâmica espacial da produtividade de milho e soja no decorrer do tempo. A Figura 4 apresenta o Box Map da produtividade anual de milho nos anos de 2008 a 2018. Essa distribuição espacial divide os municípios em função dos quartis da produtividade.

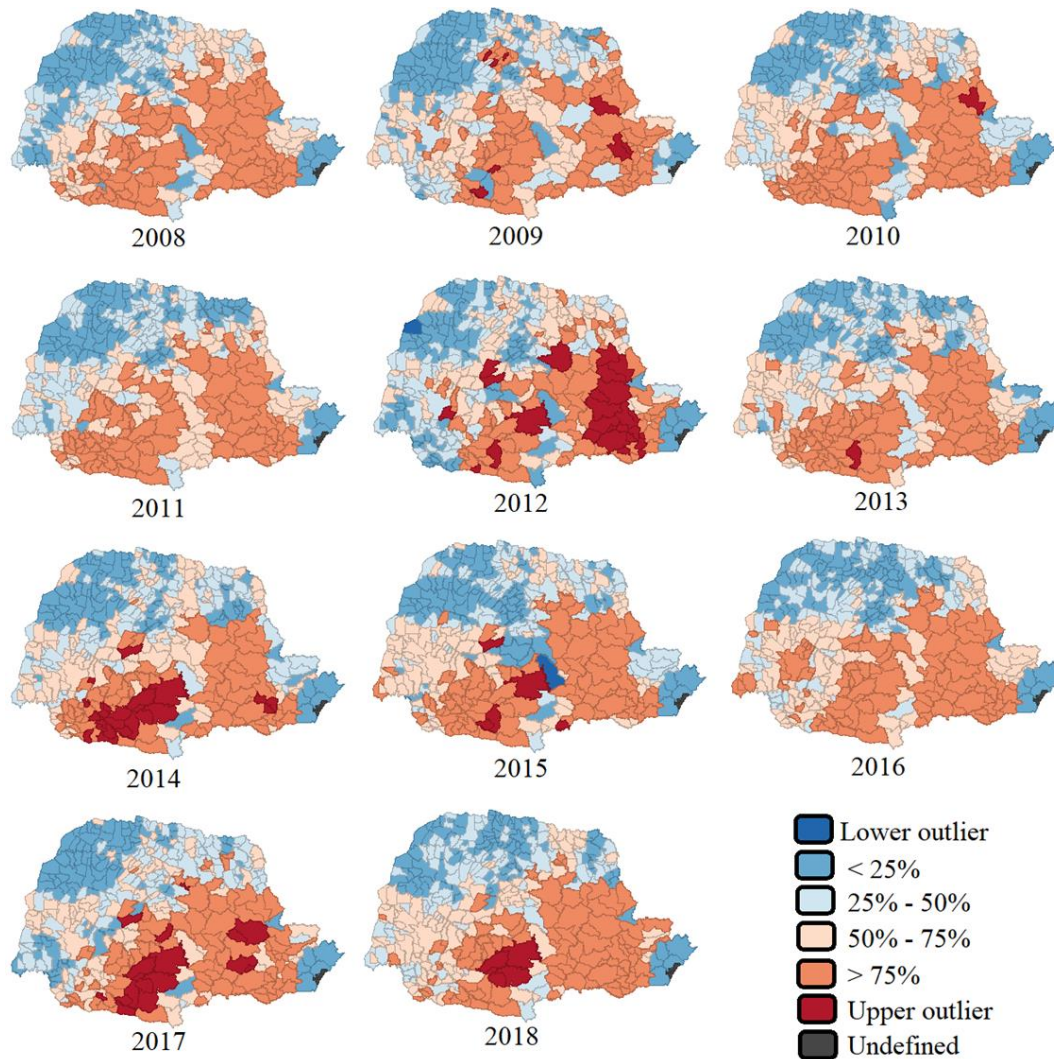


Figura 4. Box Map da produtividade de Milho nos municípios do Paraná nos anos de 2008 a 2018.

Fonte: Elaboração própria a partir do software GeoDa.

A distribuição espacial dos quartis nos municípios com maiores produtividades (quarto quartil) ao longo do tempo está concentrada nas mesorregiões Centro-Oriental, Centro-Sul, Sudoeste e parte da Metropolitana e Sudeste. Todavia, os municípios com produtividades do primeiro e segundo quartil estão nas mesorregiões Noroeste, Norte Central e Norte Pioneiro, sendo essas duas últimas com presença de municípios no terceiro quartil em alguns anos. Sobre a presença de *outliers* superiores, destacam-se os anos de 2012, 2014 e 2017, com expressivo número de municípios no Centro-Oriental e Centro-Sul. Em relação à produtividade de milho nos anos 2009 e 2016, que sofreram com intempéries climáticas afetando a produtividade do estado do Paraná, verifica-se poucas alterações nas dinâmicas espaciais da produtividade nesses anos.

A Figura 5 retrata a produtividade média anual da cultura da soja. Destacam-se no terceiro e quarto quartis as mesorregiões Centro-Oriental, Centro-Sul e Oeste, com parte do Sudeste e Sudoeste. No primeiro e segundo quartis se concentram os municípios do Noroeste e parte do Norte Central e Norte Pioneiro. Ao longo do tempo não são detectados muitos *outliers* superiores, com exceção ao surgimento em Norte Pioneiro em 2010 e 2018 e Oeste em 2003 e 2015. No entanto, *outliers* inferiores não estão presentes apenas nos anos 2009, 2014 e 2016. Nos anos 2009 e 2012, em que a produtividade de soja foi mais afetada por intempéries climáticas, tem-se que o Oeste foi a mesorregião mais impactada, com muitos municípios presentes no primeiro e segundo quartis.

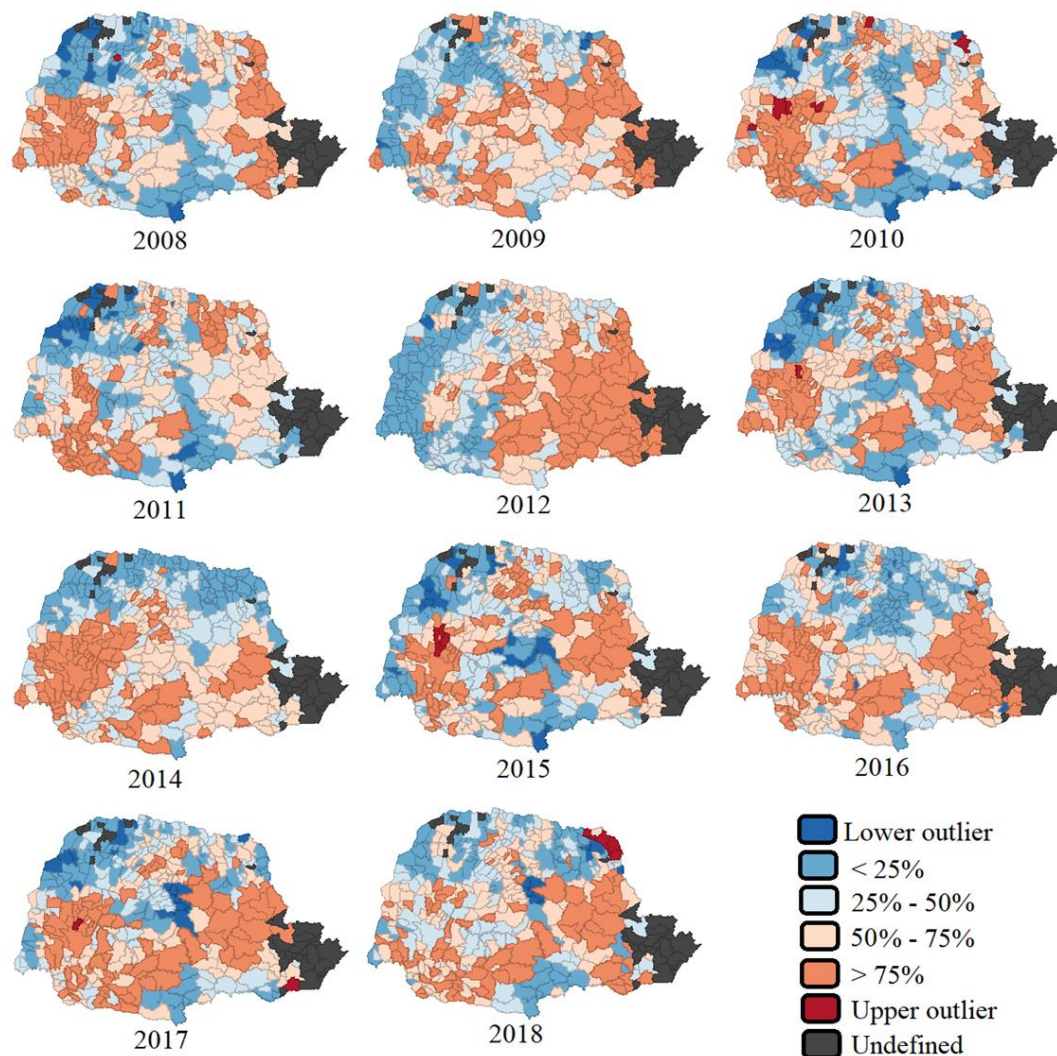


Figura 5. Box Map da produtividade de Soja nos municípios do Paraná nos anos de 2008 a 2018.
Fonte: Elaboração própria a partir do software GeoDa.

No que se refere aos riscos associados à produtividade média de milho e soja, a Figura 6 mostra os resultados dos coeficientes de variação obtidos para cada município no período de 2000 a 2018. Verifica-se que tanto na cultura do milho como na da soja, a distribuição espacial dos riscos possui poucas diferenças, sendo detectado menores riscos ao produzir as culturas no Centro-Oriental, Centro-Sul, Sudeste e parte do Oeste, além da mesorregião Metropolitana, mas nesse último caso, apenas para o milho.

Esses resultados se justificam pelo fato dessas mesorregiões apresentarem condições favoráveis ao cultivo desses grãos, com Centro-Oriental e Centro-Sul localizadas em uma região com elevada altitude, temperatura do ar mais amena e textura do solo média. A mesorregião Sudeste é a que possui menores temperaturas do ar e níveis medianos de chuva e altitude (EMBRAPA, 2016).

Por outro lado, os maiores riscos para milho e soja estão concentrados em Noroeste, Norte Central, Norte Pioneiro, Sudoeste e parte do Oeste. Esses riscos decorrem do Noroeste, Norte Central e Norte Pioneiro apresentarem baixo volume de chuvas, altitude e alta temperatura do ar o que causa muita instabilidade em sua produtividade. No Sudeste e parte do Oeste são muito dependentes dos volumes de Chuvas, portanto, ao se deparar com secas, essas regiões são as mais afetadas em sua produção (EMBRAPA, 2016).

Esses resultados preliminares das produtividades podem indicar a presença de influência espacial entre as regiões do estado do Paraná. É possível realizar essa afirmação por meio da análise da estatística I de Moran global. Os testes foram realizados utilizando as matrizes de contiguidade mais utilizadas na literatura, como a forma da Rainha e Torre, além de se utilizar os pesos de Kernel com matriz de distância Euclidiana com KNN de oito vizinhos mais próximos. Valores de I de Moran significativos e positivos evidenciam que as regiões com baixa e alta produtividade influenciam as regiões circunvizinhas (SCRUCCA, 2005; QUEIROZ *et al.*, 2018).

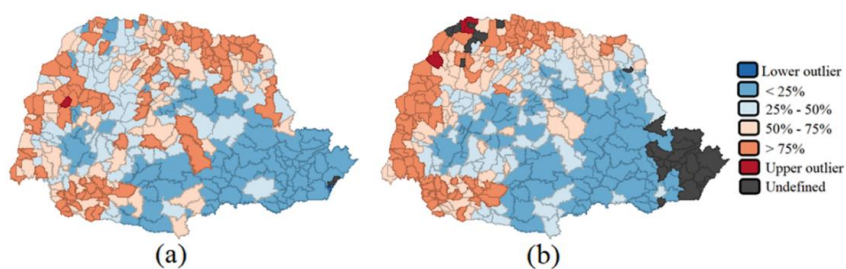


Figura 6. Box Map do coeficiente de variação da produtividade de Milho (a) e Soja (b) nos municípios do Paraná nos anos de 2000 a 2018.

Fonte: Elaboração própria a partir do software GeoDa.

Os resultados do I de Moran para medir a autocorrelação espacial para a produtividade do milho e soja são apresentados na Tabela 1. Na comparação entre as matrizes de contiguidade, todos os I de Moran foram significativos a 1% de significância e 999 permutações. As configurações de Rainha e Torre foram as que obtiveram os menores valores para o I de Moran em todos os anos, exceto os anos de 2008, 2016 e 2017 para o milho e 2009 e 2018 para a soja, em que as três configurações das matrizes foram iguais. A matriz que possui maiores valores para a autocorrelação espacial do milho e da soja e que será utilizada nesta pesquisa foi a configuração com pesos de Kernel, utilizando KNN com 8 vizinhos.

Os resultados do I de Moran para a produtividade de milho e soja revelam forte autocorrelação espacial em todos os anos. Para o caso do milho, o menor valor medido foi no ano de 2009 e o maior em 2016, enquanto na soja o menor valor foi em 2018 e maior em 2014. No comparativo entre as culturas, constata-se que a soja possui menor média para o I de Moran (0,56) seguido de maior variabilidade obtido pelo coeficiente de variação (18,65%). Esse resultado sugere maior instabilidade espacial para a produtividade de soja em relação ao milho, corroborando com os resultados encontrados por Felema *et al* (2016).

Tabela 1. Estatística I Moran Global para a cultura de milho nos anos de 2008 a 2018.

Ano	Milho			Soja		
	Rainha	Torre	KNN	Rainha	Torre	KNN
2008	0.70	0.70	0.70	0.57	0.57	0.59
2009	0.57	0.57	0.61	0.57	0.57	0.57
2010	0.67	0.70	0.72	0.41	0.41	0.47
2011	0.74	0.74	0.75	0.50	0.51	0.54
2012	0.63	0.63	0.64	0.69	0.69	0.70
2013	0.72	0.72	0.73	0.55	0.55	0.58
2014	0.72	0.72	0.74	0.73	0.73	0.76
2015	0.64	0.64	0.65	0.51	0.51	0.53
2016	0.75	0.75	0.75	0.50	0.50	0.55
2017	0.67	0.67	0.67	0.52	0.52	0.55
2018	0.73	0.73	0.74	0.36	0.36	0.36
Média	0.69	0.69	0.70	0.54	0.54	0.56
C.V. (%)	8.08	8.03	7.09	19.89	19.80	18.65

Fonte: Elaboração própria.

É necessária a aplicação dos indicadores locais de associação espacial (LISA) devido à estatística I de Moran global camuflar o padrão de associação local, comprometendo a análise (ALMEIDA, 2012). De acordo com as categorias adotadas AA, BB, AB e BA Os mapas dos *clusters* LISA para a produtividade de milho e soja foram construídos com nível de 5% de significância para os I de Moran local.

Na Figura 7, a cultura do milho evidencia a formação de *clusters* para os anos em análise, prevalecendo um padrão de associação espacial em sua produtividade, assim como já havia sido confirmado nos resultados anteriores. Pode-se constatar em todos os anos de estudo que os municípios classificados como AA se concentram nas mesorregiões Sudoeste, Centro-Sul e Centro-Oriental, em que municípios com alta produtividade possuem municípios vizinhos com alta produtividade de milho, na qual essas mesorregiões se destacam pela produção da agroindústria com altos níveis de modernização agrícola (PAVAN, 2013; PIONEIRO, 2007).

Uma ressalva para esse acontecimento fica para o Sudeste, que faz a divisa entre o Centro-Oriental e Centro-Sul; nota-se que na maioria dos anos boa parte de seus municípios não houve significância estatística, sendo que o município de Prudentópolis atua como um divisor com baixa produtividade entre os dois *clusters* AA nos anos de 2011, 2012, 2013, 2014, 2016 e 2017, classificado como BA.

A respeito dos *clusters* BB, constata-se que o Noroeste concentra em todos os anos municípios com baixa produtividade, circunvizinhado com municípios com baixa produtividade, assim como acontece em Norte Central, com exceção do ano 2009, que teve poucos municípios classificados como BB e alguns em AA. Esses acontecimentos ocorrem devido a essas mesorregiões não possuírem um solo adequado para o plantio, estarem situadas em uma região com baixa altitude e níveis de chuvas (IPARDES, 2004; EMBRAPA, 2016).

Em Norte Pioneiro os municípios não apresentaram significância estatística nos anos de 2010 e 2015, com poucos casos em 2009, 2012 e 2017. Nos anos de intempéries, infere-se que a mesorregião mais afetada foi o Sudoeste, que apresentou municípios classificados como BB no ano de 2009 e 2012, revelando que esses municípios tiveram baixa produtividade em relação aos demais municípios e foram circunvizinhados por municípios com baixa produtividade; como é uma região que depende dos volumes de chuvas nos meses de floração, essa é uma mesorregião com grande potencial de risco sistêmico para o seguro agrícola, caso ocorra uma forte seca.

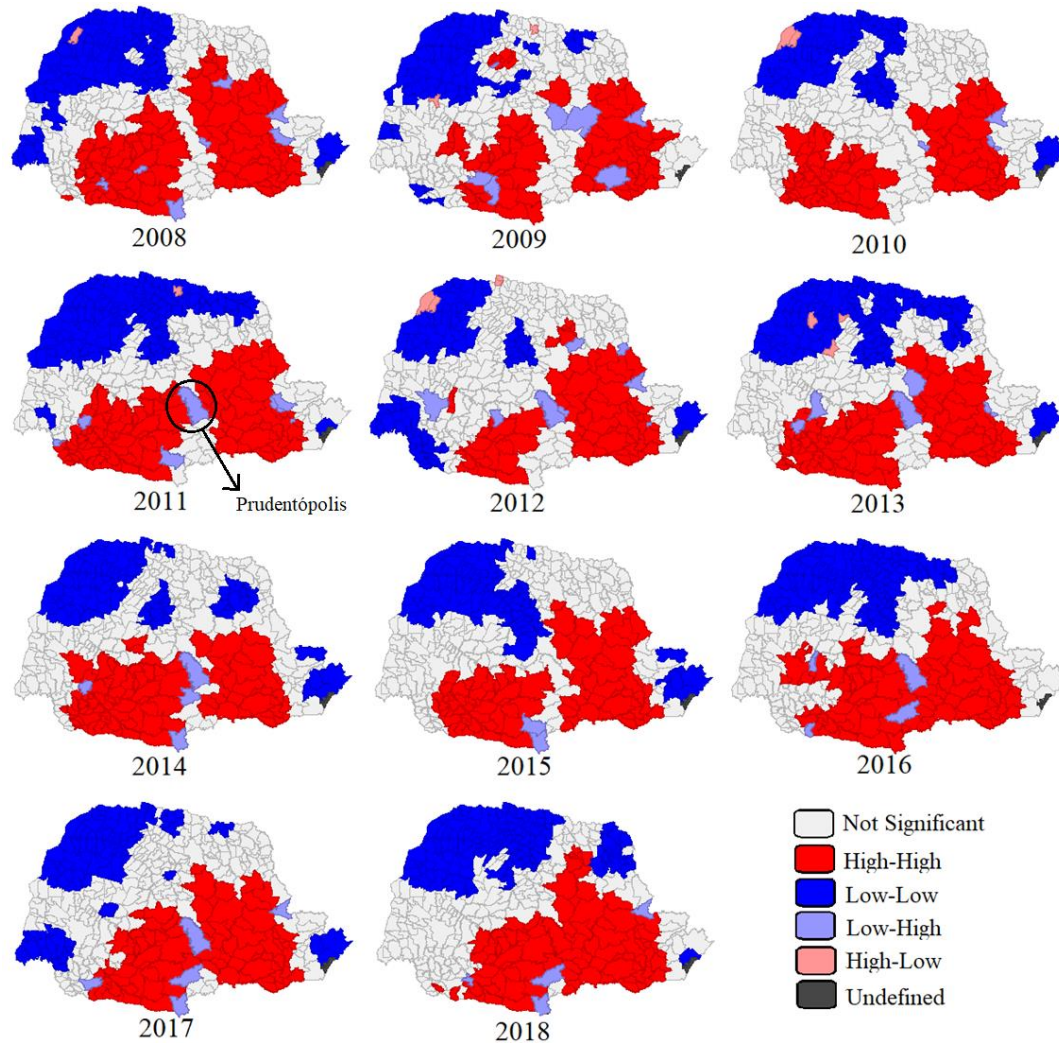


Figura 7. Mapa de clusters da produtividade de Milho nos municípios do Paraná nos anos de 2008, 2009 e 2010. **Fonte:** Elaboração própria a partir do software GeoDa.

A Figura 8 mostra os resultados para soja e apresenta a formação dos *clusters* com um padrão de associação espacial mais disperso pelo estado do Paraná, isto é, em alguns anos é mais espacialmente heterogêneo do que o milho, o que já era de se esperar pelos valores de I de Moran da Tabela 1.

Os municípios classificados nos *clusters* AA estão localizados, em sua maioria, nas mesorregiões Oeste e Centro-Oriental por serem dois grandes polos de cultivo da soja. Isso ocorre devido a elas serem equipadas com boa estrutura produtiva, o que proporciona uma boa dinâmica para o agronegócio da região (PARANÁ, 2011). Nos *clusters* BB novamente a mesorregião Noroeste concentra os municípios com baixa produtividade, com vizinhos também com baixa produtividade. No entanto, os *clusters* AA e BB surgem em pequenas quantidades e distantes um dos outros, refletindo em menores valores para o I de Moran comparado ao milho.

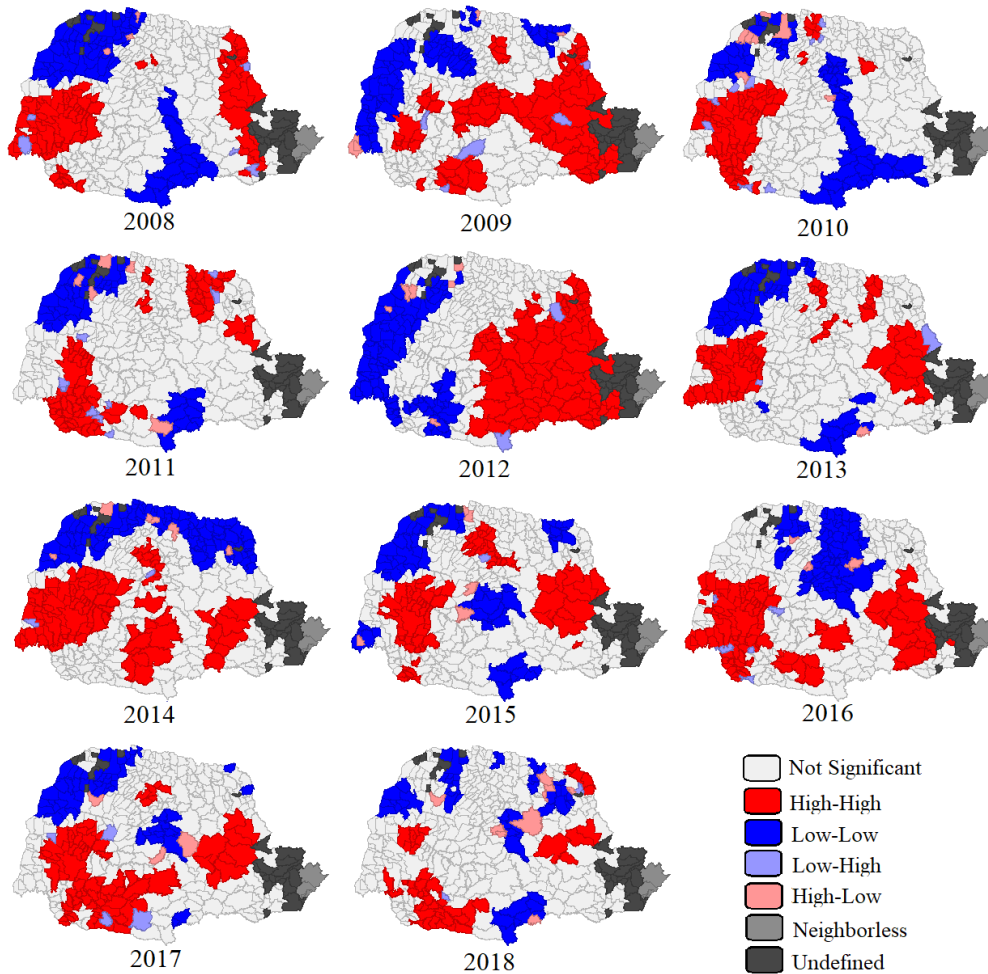


Figura 8. Mapa de clusters da produtividade de Soja nos municípios do Paraná nos anos de 2008, 2009 e 2010.
Fonte: Elaboração própria a partir do software GeoDa.

No ano de 2009, com déficit hídrico, parte do Oeste se dividiu em *clusters* BB e AA, que por sua vez os municípios na fronteira do estado sofreram mais com a seca, semelhante ao ocorrido com a seca de 2012, porém nesse ano houve a formação de um imenso *cluster* AA, abrangendo as mesorregiões Centro-Oriental, Sudeste e parte do Centro-Sul e Norte Pioneiro. A explicação para esses acontecimentos é devido a essas regiões não dependerem dos grandes volumes de chuvas para o plantio da soja, por possuírem bom solo, temperatura média do ar e altitude para seu cultivo, por outro lado, parte do Oeste, Sudoeste e alguns municípios do Centro-Sul foram classificados como BB (EMBRAPA, 2016).

Diante das análises realizadas nos mapas de *clusters* anteriores, torna-se necessário analisar os riscos associados à produtividade de milho e de soja, portanto, a Figura 9 mostra os resultados do coeficiente de variação obtidos no período de 2008 a 2018, contendo o diagrama de dispersão de Moran e os Mapas de clusters LISA.

O valor do I de Moran para os riscos da produtividade do milho foi de aproximadamente 0,57, apresentando no Mapa de *clusters* LISA uma formação *clusters* AA

dispersos no estado do Paraná, indicando formação mais concentrada de AA na mesorregião Sudoeste e alguns municípios no Oeste, norte Central e Norte Pioneiro. Esse resultado implica que municípios com alto risco de perdas de produtividade estão circunvizinhados com municípios com alto risco.

Para a mesorregião do Noroeste, verifica-se que não foram formados *clusters*, em função de existirem municípios com diferentes níveis de risco, não possuindo homogeneidade espacial. Os *clusters* BB se formaram no Centro-Oriental, Metropolitana e em parte do Sudeste e Centro-Sul, apontando áreas onde os riscos são menores, ou seja, com maior estabilidade na produtividade de Milho.

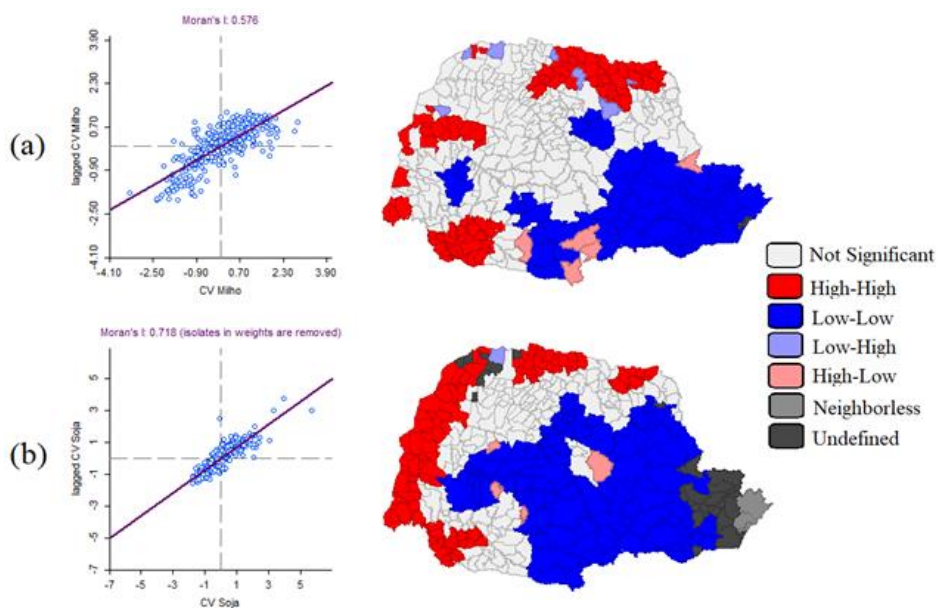


Figura 9. Diagrama de dispersão de Moran e Mapa de cluster do coeficiente de variação para produtividade de Milho (a) e Soja (b) no Paraná, no período de 2008 a 2018.

Fonte: Elaboração própria a partir do software GeoDa.

No que se refere aos riscos na produtividade de soja, o diagrama de dispersão mostra pontos bem ajustados à reta com pouca dispersão e I de Moran de aproximadamente 0,72, o que representa alto grau de influência espacial entre os municípios, desenvolvendo a formação de três *clusters* AA e um super *clusters* BB.

Na classificação AA com maiores riscos, o maior *cluster* percorre toda a fronteira do estado, partindo do Noroeste, Oeste e até o Sudoeste, provavelmente o segundo cluster formado no Norte Central ficou separado pela ausência de dados nos municípios da divisa com o Noroeste. O terceiro *cluster* foi formado com poucos municípios do Norte Pioneiro. Como já mencionado, essas regiões não possuem condições climáticas, de solo e altitude para o cultivo de Soja. O *cluster* BB abrange uma enorme área do estado, cobrindo as mesorregiões Centro-oriental, Sudeste, Centro-Sul e parte do Oeste, Centro-ocidental e Norte

Central. Este *cluster* indica que municípios com baixo risco de produtividade possuem municípios vizinhos com baixa risco na produtividade de soja.

Nos resultados de análise espacial bivariada, utiliza-se o coeficiente tradicional de Moran para inferir simultaneamente sobre a correlação espacial e espaço-temporal. Esta análise é realizada para verificar se existe correlação espacial entre a produtividade de milho ou soja em seus municípios vizinhos em um período diferente.

A Figura 10 apresenta a função de autocorrelação espaço-temporal de Moran para a produtividade de milho e Soja no período de 2008 a 2018. Todas as estatísticas I de Moran foram significativas a 1% a partir de simulações com 999 permutações.




Figura 10. Distribuição da estatística espaço-temporal de Moran nos lags espaciais para a produtividade de milho e soja, no período de 2008 a 2018.

Nota: No eixo horizontal 18/18 apresenta o I de Moran do ano de 2018; 18/17 é o I de Moran bivariado de 2018 com o ano de 2017; Assim como 18/10 é o I de Moran bivariado do ano de 2018 com o de 2010.

Fonte: Elaboração própria a partir do software GeoDa.

São nítidas as evidências para a similaridade espaço-temporal para a produtividade de milho indicado por altos valores para a estatística I de Moran, mesmo com o aumento dos *lags*, com uma linha de tendência decrescente cortando de forma central a série, apontando regularidade com o passar do tempo. Ainda apresenta valores no entorno de 0,60 após 10 anos, mostrando que a influência dos valores da produtividade de 2008, em determinada localização sobre sua vizinhança, persistem por um longo tempo, ou seja, a comparação espaço-temporal revela consistência dos municípios pertencentes aos *clusters* AA e BB, sugerindo que ao longo do tempo os municípios com alta e baixa produtividade de milho continuam circunvizinhos espacialmente com seus similares.

De forma análoga, a função de autocorrelação espaço-temporal de Moran para a produtividade de soja apresenta resultados das estatísticas I de Moran significativos a 1% com

999 permutações, exceto para a comparação da produtividade no ano de 2018 com 2012 (18/12) que obteve um *p-valor* acima de 10% de significância.

Esta correlação espacial não significativa mostra o quão diferente foram as dinâmicas espaciais da produtividade de soja na comparação dos dois anos, que por sua vez apontam que a produção de soja nos municípios no ano de 2018 não compartilha similaridades espaciais com os municípios vizinhos de 2012. A justificativa para esta ocorrência é devida à existência de uma seca em 2012, que provocou grandes perdas na produtividade de soja. Por consequência, gera incertezas para as seguradoras sobre a estabilidade espacial dos municípios produtores de soja no Paraná em anos atingidos por efeitos climáticos.

Essas análises bivariadas para produtividade da soja informam as seguradoras sobre os riscos sistêmicos de uma seca, reforçando que em anos com adversidades climáticas, o comportamento espacial na produtividade dos municípios pode se modificar e formar *clusters* espaciais que não compartilham similaridades em anos que não ocorreram intempéries climáticas, fortalecendo a importância para as seguradoras em diversificar os riscos ao atribuir diferentes precificações em função da região do município.

Com o intuito de realizar comparações espaço-temporais dois a dois entre anos atingidos por secas e anos com mais estabilidade climática, a Tabela 2 apresenta os resultados da análise espacial bivariada para a produtividade de milho e soja. Foi utilizado os anos de 2009 e 2012 como referência para anos que sofreram secas, logo serão a nossa referência na análise com os demais anos.

Tabela 2. Análise espacial bivariada da produtividade de Milho e Soja, utilizando como referência os anos de 2009 e 2012 com intempéries climáticas

Referência 2009			Referência 2012		
Ano	Milho	Soja	Ano	Milho	Soja
2008	0.53	0.24	2008	0.58	0.14
2010	0.50	0.05	2009	0.53	0.45
2011	0.52	0.17	2010	0.54	-0.07
2012	0.52	0.42	2011	0.52	0.15
2013	0.50	0.17	2013	0.53	0.19
2014	0.49	0.22	2014	0.48	<0.01
2015	0.46	0.18	2015	0.51	0.15
2016	0.53	0.07	2016	0.56	-0.06
2017	0.52	0.18	2017	0.53	0.08
2018	0.53	0.13	2018	0.54	-0.01

Fonte: Elaboração própria.

Considerando como referência tanto o ano de 2009 quanto o ano de 2012, a correlação espaço-temporal para a produtividade do milho aponta certa estabilidade espacial de um ano

com seca para com os demais, os resultados do I de Moran não possuem grandes diferenças numéricas e sugerem homogeneidade espacial independente se o ano sofreu ou não com uma seca.

Em compensação, ao se analisar a produtividade de soja nos anos de referência para intempéries climáticas, a correlação espaço-temporal de 2009x2012 e 2012x2009 indicam valores de I de Moran muito superiores aos demais anos, a primeira comparação indica que a produtividade dos municípios em 2009 se assemelha espacialmente com a produtividade dos municípios vizinhos em 2012, com valor de 0,42. De forma análoga, no comparativo 2012x2009, apresenta influência espaço-temporal na produtividade dos municípios de 2012 com os municípios vizinhos em 2009, com valor de 0,45. Os demais anos possuíram baixa correlação espaço-temporal, inclusive na segunda comparação se obteve valores negativos e significativos nos anos de 2010 e 2016.

Os resultados obtidos evidenciam que em anos com secas o comportamento espaço-temporal da produtividade de soja possui similaridades espaciais com os municípios e seus vizinhos, de modo que essa dinâmica espacial não ocorre em anos sem grandes déficits hídricos. Contudo, em comparação com os demais anos, existe uma dissimilaridade espacial. Esse resultado é importante para as seguradoras agrícolas se anteciparem em relação aos riscos sistêmicos causados pelas secas na produtividade de soja, adequando a precificação do prêmio em consequência do grande número de sinistros que irão acionar o pagamento de indenizações, assim como não prejudicar com altas taxas de prêmio regiões que não apresentarem elevado risco.

2.5. Conclusões

A aplicação de técnicas da AEDE em dados de produtividade média anual de milho e soja pode indicar como uma região propícia ou não para o cultivo dessas culturas influencia espacialmente outra região vizinha em sua produtividade.

A indicação de *clusters* espaciais com baixo coeficiente de variação mostram as regiões onde os principais municípios atuam e seu nível de influência espacial com seus municípios vizinhos, podendo ser visto pela seguradora como uma região que incide menores riscos associados as suas perdas. Por outro lado, *clusters* com municípios com alto coeficiente de variação podem indicar regiões onde existem maiores riscos de sinistros. A conclusão espacial univariada do estudo é que as fronteiras das mesorregiões Norte Central, Noroeste, Oeste e Sudoeste são as que apresentam maiores riscos para o cultivo de milho e soja.

A análise espacial bivariada comparou as similaridades dos anos que sofreram seca com os demais anos. Para a produtividade de milho não foram detectadas diferenças espaço-temporais, porém, na produtividade de soja houve indícios de que no acontecimento de uma seca a produtividade dos municípios compartilham influências espaciais. Em contrapartida, conclui-se que existe heterogeneidade espacial entre municípios no ano com seca contra anos sem seca.

Os resultados deste estudo permitem as seguradoras agrícolas informações sobre os riscos das produtividades de milho e de soja nas mesorregiões e municípios do estado. Ademais, fornece indicativos de similaridades espaciais em anos de secas que proporcionam a seguradora mitigar os riscos por meio de uma precificação justa em regiões, dependendo do seu grau de risco sistêmico.

Salienta-se que esta pesquisa possuiu certas limitações em sua execução. A utilização da produtividade média anual do milho ao invés da análise do milho primeira safra e segunda safra pode misturar os efeitos espaciais típicos de cada uma. No entanto, ainda existem poucos dados municipais da produtividade do milho segunda safra, e isso inviabilizaria a realização da metodologia empregada. No que tange à base de dados, obtém-se o problema de agregação pelo fato das produtividades serem dispostas por município e os produtores com plantações em regiões de fronteiras podem possuir maior similaridade espacial (solo e clima) em municípios vizinhos ao serem comparados aos produtores próximos do centroide de seu município. Portanto, esta análise espacial seria mais bem explorada se os dados de produtividade fossem desagregados por produtores com sua informação geográfica, assim, as seguradoras poderiam se utilizar melhor dos resultados deste trabalho e precificar o seguro agrícola sem ter por base as informações agregados por municípios fornecidos pelo IBGE.

Para trabalhos futuros, mediante dados mais consolidados dos municípios para produtividade do milho segunda safra, sugere-se analisar os efeitos espaciais e espaço-temporal dessa cultura. Ademais, obter os arcos de distância de influência espacial para produtividade de milho e de soja, bem como utilizar dados dos sinistros do seguro agrícola em decorrência de adversidades climáticas econometria para investigar as influências espaciais e espaço-temporal por meio da econometria espacial.

Referências

- AKERLOF, G.A. The market for "lemons": quality uncertainty and the market mechanism. **Quartely Journal of Economisc**, v.84, n.3, p.488-500, Aug. 1970.
- ALMEIDA, E. S.; 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, jan./mar. 2008.
- ALMEIDA, E. S. **Econometria Espacial Aplicada**. Campinas: Alínea, 2012.
- ANSELIN, L. Local indicators of spatial association – LISA. **Geographical Analysis**, v. 27, n. 2, p. 93-115, Apr. 1995.
- _____. **Exploring Spatial Data with GeoDa: a workbook**. Urbana-Champaign: University of Illinois, 2005.
- ANSELIN, L., COHEN, J., GORR, W., TITA, G. Spatial analyses of crime. In: NATIONAL INSTITUTE OF JUSTICE (U.S.). **Criminal justice 2000**. Washington, DC, 2000. v. 4, p. 213-262. Disponível em: <<https://www.ncjrs.gov/App/publications/Abstract.aspx?id=185541>>. Acesso em: abr. 2013.
- ANSELIN, L.; REY, S. J. 2014. **Econometria espacial moderna na prática, um guia para Geoda, Geodaspace e Pysal** . Chicago, IL: GeoDa Press.
- ARAÚJO, E. C. de; URIBE-OPAZO, M. A.; JOHANN, J. A. **Modelo de regressão espacial para estimativa da produtividade da soja associada a variáveis agrometeorológicas na região oeste do estado do Paraná**. *Eng. Agríc.* [online]. 2014, vol.34, n.2, pp.286-299.
- ARIAS, D.; MENDES, P.; ABEL, P. Revisão Rápida e Integrada da Gestão de Riscos Agropecuários no Brasil: Caminhos para uma Visão Integrada. **Banco Mundial**, Brasília, DF, 2015.
- BAILEY, T.C., GATRELL, A.C. *Interactive Spatial Data Analysis*, Prentice Hall. 1995.
- DINIZ, S. S., CÂMARA, M. R. G., MASSAMBANI, M. O., ANHESINI, J. A. R., SESSO-FILHO, U. A. Análise espacial da produtividade da laranja dos municípios do estado de São Paulo: 2002-2010. In: 50ª Sociedade Brasileira de Economia, Administração e Sociologia Rural – SOBER, **Anais**,... Vitória, 22 a 25 de julho de 2012.
- DRUCK, S.; CARVALHO, M.S.; CÂMARA, G.; MONTEIRO, A.V.M. (eds.) **Análise Espacial de Dados Geográficos**. Brasília, EMBRAPA, 2004 (ISBN: 85-7383-260-6).

- DUARTE, G. V.; BRAGA, A.; MIQUELLUTI, D. L.; OZAKI, V. A. Modeling of soybean yield using symmetric, asymmetric and bimodal distributions: implications for crop insurance. **Journal of Applied Statistics**. v. 45, 2018.
- COBLE, K.H.; KNIGHT, T.O. Crop insurance as a tool for price and yield risk management. In JUST, RE, POPE, R.D. **A comprehensive assessment of the role of risk in U.S. agriculture**. Boston: Kluwer Academic Publisher, 586p., 2002.
- EMBRAPA. Variabilidade espacial e temporal da produção de soja no Paraná e definição de ambientes de produção [recurso eletrônico]: / Julio Cezar Franchini...[et al.] – Londrina: **Embrapa Soja**, 2016.
- FAVRO, J. Efeitos espaciais da produtividade do milho no Paraná nos anos de 2002 e 2012. *In: Encontro de Produção Científica e Tecnológica - IX EPCT, Anais...* Campo Mourão, 27 a 31 de Outubro de 2014.
- FELEMA, J., MEDEIROS, E. R., FERREIRA, C. R., CAMARA, M. R. G., NASCIMENTO, S. P. Um estudo da produtividade do feijão, do milho e da soja na agricultura paranaense, nos anos de 2000 e 2010: uma análise espacial. **Ensaio FEE**, Porto Alegre, v. 36, n. 4, p. 817-842, mar. 2016.
- GOODWIN, B.K. An empirical analysis of the demand for multiple peril crop insurance. **American Journal of Agricultural Economics**, v.75, p.425-434, May. 1993.
- GUIMARÃES, M. F.; NOGUEIRA, J. M. A experiência norte-americana com o seguro agrícola: loções ao Brasil?. **Rev. Econ. Sociol. Rural**. Vol. 47, n. 01, p. 27-58, 2009.
- INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONOMICO E SOCIAL (IPARDES). **Leituras Regionais**: mesorregião geográfica noroeste paranaense. Curitiba: IPARDES; BRDE, 2004. Disponível em: <www.ipardes.gov.br>. Acesso em: 7 Mar. 2019.
- INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONOMICO E SOCIAL (IPARDES). **[Site institucional]**. 2019. Disponível em: <http://www.ipardes.gov.br/pdf/mapas/base_fisica/mesorregioes_geograficas_base_2010.jp>. Acesso em: 7 Mar. 2019.
- KREMPI, A. P. Explorando recursos de estatística espacial para análise da acessibilidade da cidade de Bauru. 2004. 80 f. Dissertação (Mestrado em Engenharia Civil) - Escola de Engenharia de São Carlos, Universidade de São Paulo USP, São Carlos, 2004.
- LLOYD, C. D. **Local Models for Spatial Analysis**. 2. ed. New York: CRC Press, 2007.

- LOPES, P. F.; CHAIN, C. P.; MENEZES, T. P.; PRADO, J. W.; CARVALHO, F. M. Gestão de riscos e dependência espacial em seguros agrícolas: uma análise da produtividade da soja. **Revista Interciência**, Vol. 42 n° 8, ago, 2017.
- LOPEZ, F. A.; CHASCO, C. **Space-Time Lags: Specification Strategy in Spatial Regression Models**. First Seminar of Spatial Econometrics JEAN PAELINCK. 2004. Disponível em: <<https://econwpa.ub.uni-muenchen.de/econwp/em/papers/0411/0411005.pdf>>
- MIRANDA, M. J.; GLAUBER, J. W. Systemic risk, reinsurance, and the failure of crop insurance markets. **American Journal of Agricultural Economics**, v. 79, n. 1, p. 206-215, fev 1997.
- McCARTY, D.E. Wheat yield insurance. **Journal of Farm Economics**, v.23, p.664- 667, 1941.
- MORAN, P. A. The Interpretation of Statistical Maps. **Journal of the Royal Statistic Society**, v. 10, p. 243–251, 1948.
- MOTA, A. L. **Previsão de prêmio e a ocorrência de sinistros no mercado de seguro agrícola brasileiro**. 97 f. Dissertação (Mestrado em Economia Aplicada) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2019.
- OZAKI, V. A. **Métodos atuariais aplicados à determinação da taxa de prêmio de contratos de seguro agrícola: um estudo de caso**. Tese (Doutorado em Economia Aplicada) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2005. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11132/tde-11072005-160540/publico/VitorOzaki.pdf>. Acesso em 08 abr. 2018.
- _____. O papel do seguro na gestão do risco agrícola e os empecilhos para o seu desenvolvimento. **Rev. Bras. Risco Seguro** 2(4): 75-92, 2007.
- _____. Análise espacial da produtividade agrícola no Estado do Paraná: implicações para o seguro agrícola. **Rev. Econ. Sociol. Rural** 46: 869-886, 2008.
- OZAKI, V.A.; DIAS, C.T.S. Análise e quantificação do risco para a gestão eficiente do portfólio agrícola das seguradoras. **Rev. Econ. Sociol. Rural**. 47: 549-567, 2009.
- PARANÁ. Secretaria da Agricultura e do Abastecimento. **Soja**. 2009. Disponível em: <http://www.agricultura.pr.gov.br/sites/default/arquivos_restritos/files/qas/1998/soja_29jun2009.pdf>. Acesso em: 10 nov. 2020.
- PARANÁ. Secretária de Estado da Agricultura e do Abastecimento (SEAB). **Valor bruto da produção rural paranaense**. Curitiba, 2011. Disponível em:

- <http://www.agricultura.pr.gov.br/arquivos/File/deral/vbp_2010.pdf>. Acesso em: 8 Mar. 2018.
- PAVAN, L. S. **Os determinantes da produtividade agrícola dos municípios paranaenses: uma análise de dados espaciais**. 2013. 115 f. Dissertação (Mestrado em Economia) — Curso de Teoria Econômica, Universidade Estadual de Maringá, Maringá, 2013.
- PEROBELLI, F. S. *et al.* Análise espacial da produtividade do setor agrícola brasileiro: 1991-2003. *Nova Economia*, v. 17, n. 1, p. 65-95, 2007.
- PEROBELLI, F. S.; FARIA, W. R.; FERREIRA, P. G. C. Análise da convergência espacial do PIB *per capita* no estado de Minas Gerais. *Revista Brasileira de Estudos Regionais e Urbanos*, v. 1, n. 1, p. 85-113, 2009.
- PIONEIRO, M. A. **Distribuição Espacial da Agropecuária do Estado do Paraná: um estudo da função de produção**. 2007. 126 f. Dissertação (Mestrado em Economia) — Curso de Teoria Econômica, Universidade Estadual de Maringá, Maringá, 2007.
- QUEIROZ, A. M., BARBOSA, C. J., VIEIRA, E. R., CARVALHO, C. R. R. Clusters espaciais no setor sucroalcooleiro em Goiás: existem territórios canavieiros?. *In: 56ª Sociedade Brasileira de Economia, Administração e Sociologia Rural –SOBER, Anais...* Porto Alegre, 29 de julho a 1 de agosto de 2018. Disponível em: <<http://icongresso.itarget.com.br/tra/arquivos/ser.8/1/8740.pdf>>. Acesso em 15 Fev. 2019.
- QUIGGIN, J.; KARAGIANNIS, G.; STANTON, J. Crop insurance and crop production an empirical study of moral hazard and adverse selection. *In: HUETH D.L; FURTAN, W.H. Economics of agricultural crop insurance: theory and evidence*. Boston Kluwer Academic Publishers, 380p, 1994.
- SCRUCCA, L. Clustering multivariate Spatial Data based on Local Measures of Spatial Autocorrelation: An application to the labour market of Umbria. *Università degli Studi di Perugia, Italy*, 2005. Disponível: <<http://www.ec.unipg.it/DEFS/uploads/spatcluster.pdf>>. Acesso em: 14 Mar. 2019.
- TEIXEIRA, R. F. A. P., BERTELLA, M. A.. Distribuição espaço-temporal da produtividade média do café em Minas Gerais: 1997-2006. **Análise Econômica**, Porto Alegre, ano 33, n. 63, p. 275-299, mar. 2015.
- VIDIGAL, V. G., GOMES, M. F. M., VIDIGAL, C. B. R., SILVEIRA, G. F. Análise espacial da produtividade da cana-de-açúcar em Minas Gerais, 1990 a 2007. **Revista de Economia e Administração**, v.10, n.2, 241-261p, abr./jun. 2011.

VIDIGAL, V. G., VIDIGAL, C. B. R., PARRÉ, J. L. Distribuição espacial da produtividade da soja no Rio Grande do Sul: um estudo exploratório. **Acta Scientiarum. Human and Social Sciences**, v. 40(2), 2018.

VIEIRA, D. T.; PARRÉ, J. L. Um estudo exploratório sobre os efeitos espaciais na produtividade do milho no estado de Santa Catarina. <https://www.researchgate.net/publication/267809127>. 2008.

WENNER, M., ARIAS D.; Agricultural Insurance in Latin America: Where are we?. **Banco Interamericano de Desenvolvimento**. Washington. EUA. Estudo de Caso. 2003.

WOODARD, J.D.; SCHNITKEY, G.D.; SHERRICK, B.J.; LOZANO-GRACIA, N.; ANSELIN, L. A spatial econometric analysis of loss experience in the US crop insurance program. **J. Risk Insur.** 79: 261-286, 2012.

3. ANÁLISE ESPACIAL DOS SINISTROS DO SEGURO AGRÍCOLA NO PARANÁ

Resumo

Este estudo tem como objetivo analisar os efeitos espaciais e espaço-temporal dos dados de produtividade média e sinistros do milho segunda safra e da soja em relação as intempéries climáticas. A fonte de dados sobre sinistralidades foi obtida no Atlas do Seguro Rural, elaborado pelo Ministério da Agricultura, Pecuária e do Abastecimento (MAPA) e os dados da produtividade média das culturas foram extraídos de sítio do Departamento de Economia Rural (DERAL) da Secretaria da Agricultura e Abastecimento (SEAB) do Paraná. Para alcançar esses objetivos, aplicam-se correlogramas espaciais para medir o arco de distância de influência espacial e modelos de econometria espacial para mensurar os efeitos espaciais e espaço-temporal dos sinistros e produtividade média nos municípios do Paraná, no período de 2013 a 2018. Os resultados mostram que existem influências espaciais e espaço-temporais ao analisar a produtividade média e sinistros de milho e soja, com maiores distâncias de influência espacial ocorrendo em anos atingidos por efeitos climáticos.

Palavras-chave: Seguro agrícola, Indenizações pagas, Correlograma especial, Econometria espacial.

Abstract

This paper aims to analyze the spatial and space-time effects of the average and sinister productivity data of second crop corn and soybean in relation to climate weather. The source of data on accidents was obtained in the Atlas of Rural Insurance, prepared by the Ministry of Agriculture, Livestock and Supply (MAPA) and the data on average crop productivity were extracted from the website of the Department of Rural Economy (DERAL) of the Secretariat of Agriculture and Supply (SEAB) of Paraná. To achieve these objectives, spatial correlograms are applied to measure the spatial influence distance arc and spatial econometry models to measure the spatial and space-time effects of claims and average productivity in the municipalities of Paraná, from 2013 to 2018. The results of this study show that there are spatial and space-time influences when analyzing the average and sinister productivity of corn and soybean, with greater distances of spatial influence occurring in years affected by climatic effects.

Keywords: Agricultural insurance, Indemnification paid, Spatial correlogram, Spatial econometrics.

3.1. Introdução

No Brasil, os eventos climáticos extremos são cada vez mais recorrentes e provocam significativas perdas econômicas (GUIMARÃES; IGARI, 2019). Nesse contexto, as atividades agrícolas são altamente dependentes das condições do clima, de maneira que a

quantidade de chuvas, a temperatura e outros elementos climáticos interferem diretamente na produção agrícola.

De acordo com o estudo realizado por EMBRAPA (2016) que analisou a variabilidade climática do Paraná para o cultivo de soja, fica evidente que o estado é suscetível a várias intempéries climáticas que afetam diretamente a produção agropecuária, que durante o ano sofre com grandes estiagens, altas temperaturas, chuvas excessivas e intensas geadas. Nesse contexto é fundamental que os agentes econômicos adotem medidas para preservar a eficiência operacional e o crescimento da produção agropecuária, incorporando à gestão de riscos decorrentes dos eventos climáticos em seus processos de planejamento. Assim, a preocupação da ocorrência desses eventos impulsiona os produtores a buscarem soluções para mitigar as consequências desses riscos na atividade agrícola (OZAKI; DIAS, 2009; IBGE, 2018; SEAB, 2019).

Nessa perspectiva, um dos meios de contornar os riscos é a contratação do seguro agrícola, que se apresenta como uma boa alternativa para o produtor transferir as consequências dos riscos dessa atividade para as seguradoras, que por sua vez, dado o interesse crescente da demanda, aumenta a oferta de produtos, proporcionando mais opções de coberturas.

Um ponto importante a se destacar é a presença do risco sistêmico ou generalizado, que dificulta sobremaneira a massificação do seguro. Esse tipo de risco caracteriza-se pela possibilidade de o risco sistêmico afetar milhares de produtores em uma vasta extensão territorial. Esse fenômeno viola um dos princípios básicos do mercado de seguros, ou seja, a existência de unidades seguradas homogêneas e independentes. Nesse caso, uma das estratégias das seguradoras é diversificar as operações em diferentes regiões geográficas, com o intuito de pulverizar o risco retido. Portanto, podem-se compensar resultados positivos em umas regiões em que outras ocorram sinistros, aliado com a oferta do seguro em municípios de alto risco apenas se houver subvenção governamental, incentivando as seguradoras em aceitar o elevado risco. Nos outros municípios aplica-se o esquema de diversificação (OZAKI *et al.*, 2007; OZAKI; DIAS, 2009).

O problema de diversificar geograficamente a atuação do seguro pode ser analisado em estudos que verifiquem a relação de influência espacial da produtividade das culturas e dos sinistros acionados pelos produtores por causa de intempérie climática. Entretanto, a literatura carece de pesquisas científicas que aplicam métodos espaciais para gerar tais resultados, em que foram encontrados para o Paraná apenas os trabalhos de Ozaki (2008) e

Lopes *et al.* (2017), os quais propuseram obter as distâncias de influência espacial que a produtividade de milho e/ou soja exercem nos municípios do estado.

Esses estudos estão defasados em relação às séries históricas adotadas e não se preocuparam em analisar quais as diferenças das influências espaciais possam vir a ocorrer em anos com efeitos climáticos. Portanto, esta pesquisa pretende preencher esta lacuna na literatura. Ademais, possui o diferencial de aplicar modelos de econometria espacial para detectar como os sinistros se relacionam com as produtividades médias de milho e soja em relação aos efeitos espaciais e espaço-temporal.

Diante desse cenário, este estudo tem como objetivo principal analisar as influências espaciais e espaço-temporal da produtividade do milho segunda safra, soja e as sinistralidades médias perante os efeitos das intempéries climáticas nos municípios do Paraná, no período de 2013 a 2018. Ao analisar como objetivos específicos, pretende-se: i) Inspeccionar as indenizações pagas e sinistros provocados por perdas na produtividade média do milho e soja em decorrência de adversidades climáticas; ii) Construir correlogramas para medir a distância de influência espacial e; ii) Estimar modelos de econometria espacial para investigar as influências espaciais e espaço-temporais da produtividade e sinistralidade média do milho e soja.

O artigo está estruturado da seguinte forma: a seção 2 discute as consequências do risco sistêmico para o seguro agrícola, a seção 3 mostra a metodologia adotada por meio de correlogramas e econometria espacial, a seção 4 apresenta os resultados e discussão e na última seção estão as considerações finais.

3.2. O Seguro agrícola e o risco sistêmico

As atividades agropecuárias possuem riscos de produção extremamente maiores do que as demais atividades econômicas. De maneira que seu êxito econômico não depende exclusivamente do comportamento dos preços, da alocação eficiente dos fatores de produção e do uso adequado da tecnologia, mas também das condições climáticas e de suas inesperadas oscilações (RAMOS, 2009).

Vale ressaltar que segundo o *International Water Management Institute* – IWMI (2014) os eventos climáticos tendem a ficar mais extremos com o tempo, causando inúmeros prejuízos financeiros no mundo inteiro, em razão do aumento de inundações e secas. Atualmente, é notório o aumento da variabilidade climática que causa muitos transtornos para

um planejamento eficaz, que reduza os riscos sociais e econômicos, o que leva à interrupção da produção agrícola e destruição de infraestrutura.

Nesse contexto, conforme a Confederação da *Agricultura e Pecuária do Brasil* – CNA (2015), parte das regiões de maiores produções agropecuárias no Brasil são afetadas por eventos climáticos, o que gera perdas significativas nas lavouras e, conseqüentemente, na rentabilidade dos produtores rurais. O setor agrícola não só do Brasil, mas de todo o mundo, está sujeito aos efeitos dos agentes climáticos, sejam positivos ou negativos (FORNAZIER *et al.*, 2012).

Desse modo, o seguro agrícola é considerado um dos mais importantes instrumentos para o desenvolvimento deste setor, proporcionando proteção ao produtor rural contra efeitos climáticos e do mercado, sendo fundamental para a estabilidade da renda, geração de emprego e para o desenvolvimento tecnológico (BURGO, 2015). Assim, as empresas que atuam no ramo do seguro agrícola possuem considerável importância para mitigar as conseqüências dos riscos associados à produção agrícola. Na ocorrência de sinistro causado por eventos climáticos cobertos pelo seguro, garante-se o pagamento da indenização em relação ao nível de cobertura do contrato, servindo como uma espécie de renda garantida ao produtor (OZAKI, 2007; OZAKI; DIAS, 2009).

Salienta-se que para o funcionamento adequado do mercado de seguro é necessário que algumas condições sejam satisfeitas, as denominadas “condições de segurabilidade”, sendo elas: i) a perda esperada deve ser mensurável e estimável; ii) as circunstâncias de uma perda devem ser bem definidas, devendo ser não intencionais e acidentais; iii) deve haver um grande número de unidades expostas, homogêneas e independentes; iv) o prêmio deve ser economicamente viável; e, v) não haja perda catastrófica (BOOTH *et al.*, 1999; HART *et al.*, 1996; SKEES; BARNETT, 1999).

Contudo, historicamente a implementação do seguro nos países não apresentaram bons resultados, que além dos problemas tradicionais (risco moral e a seleção adversa), as causas de insucesso são ampliadas em virtude do risco sistêmico, isto é, o fato de que quando um evento causador do sinistro ocorre, este não afeta apenas um produtor, mas muitos produtores em uma vasta extensão espacial (OZAKI; SHIROTA, 2005). Logo, alguns eventos catastróficos atingem uma expansão territorial extensa, provocando perdas para vários produtores e pelo fato de os segurados não serem distribuídos de forma independente no espaço, na qual exercem influência espacial em um certo raio de distância. Portanto, esse evento implica no acionamento de muitos sinistros, levando a um elevado valor no pagamento das indenizações, o que impacta diretamente as seguradoras (LOPES *et al.*, 2017).

Dessa forma, encontra-se na literatura estudos que estimam a distância máxima de influência espacial de culturas agrícolas entre as regiões de análise. Tais estudos são essenciais para que as empresas seguradoras considerem as influências espaciais de fenômenos climáticos nos cálculos das indenizações.

Em seu estudo, Goodwin (2001) avaliou a extensão da correlação espacial da produção de milho nos EUA, no período de 1980 a 1990. Com base nos resultados, verificou que a correlação espacial se reduz mais rapidamente com o aumento da distância. Sendo que em anos regulares (isto é, sem a incidência de qualquer evento climático danoso), o valor se estabiliza em 0,10, quando a distância entre as áreas analisadas é de aproximadamente 322 km. Por outro lado, nos anos em que há incidência de eventos climáticos extremos, a correlação espacial se reduz de forma mais lenta, atingindo o valor de 0,10 apenas quando a distância entre as áreas é de aproximadamente 644 km.

Wang e Zhang (2003) analisaram a estrutura de dependência espacial da produção de trigo, soja e milho nos EUA para o período de 1972 a 1997, com intuito de verificar a eficácia de agrupamento de riscos. Empregaram a análise dos correlogramas espaciais e verificaram que a dependência positiva para a produção das três culturas desaparece rapidamente, conforme a distância aumenta, uma vez que a distância máxima estimada para a correlação não-negativa foi de aproximadamente 917 km. Conforme os resultados, os autores concluíram que o agrupamento de riscos pode ser eficaz para as três culturas, desde que os níveis de cobertura sejam pelo menos um desvio padrão abaixo dos rendimentos médios, sugerindo uma alta possibilidade de um mercado viável de seguro agrícola privado nos EUA.

O estudo desenvolvido por Ozaki (2008) analisou espacialmente os dados de produtividade das culturas de soja e milho no Paraná, no período de 1990 a 2002. O objetivo do estudo era verificar a extensão da dependência espacial (em Km) dessas culturas e suas implicações para o seguro agrícola por meio do emprego de semi-variogramas. Os resultados mostraram que, de fato, a dependência espacial desses dados existe, tornando-se praticamente nulas as distâncias relativamente longas e podendo ser captada em todos os anos para ambas as culturas. Portanto, a distância máxima estimada para a correlação não-negativa do milho e da soja foram em média de 132,4 km e 164,6 km, respectivamente.

Lopes *et al.* (2017) analisaram a estrutura de dependência espacial da produtividade média municipal da soja no estado do Paraná, no período de 1990 a 2013. Para tanto, utilizaram o correlograma espacial de Moran. Os resultados evidenciaram uma forte autocorrelação espacial nos anos analisados, com distância de influência espacial deixando de ser significativa a 89,37km em 1990 para 121,87km. Os autores concluíram que é

recomendável que as seguradoras utilizem mais de um método de análise de correlação espacial para validarem suas estimativas durante a definição de estratégias de gestão dos riscos da distribuição geográfica da carteira de clientes.

Considerando os resultados encontrados nesses estudos, é importante analisar quais os impactos que os eventos climáticos possam gerar no seguro agrícola no estado do Paraná, analisando os registros dos sinistros acionados em função de perdas na produção de milho e soja oriundos de adversidades climáticas.

3.2.2. As consequências das intempéries climáticas sobre o seguro agrícola

Como já discutido anteriormente, um evento catastrófico atinge uma porção significativa de produtores na região afetada, causando prejuízos acima do esperado para as seguradoras. Assim, de acordo com os dados divulgados por MAPA (2019) é possível analisar a quantidade de sinistros, importância segurada, prêmio total, indenizações pagas e sinistralidade média para a produção da primeira e segunda safra do milho e da produção de soja no estado do Paraná, nos anos de 2007 a 2018.

A Tabela 3 mostra o levantamento da quantidade de sinistros ocorridos na produção do milho primeira safra. Diante das informações apresentadas, verifica-se que o maior número de acionamentos do seguro é causado pela seca, anotando 1351 casos de 2007 a 2018. No entanto, existiram apenas quatro casos de sinistros provocados por Inundação/Tromba d'água. O ano de 2008 foi o que mais houve o acionamento do seguro, sendo a seca a causa do sinistro mais recorrente, com 1020 casos registrados nesse ano. Em contrapartida, a partir de 2013 o número de casos de sinistros reduziu consideravelmente, chegando a não ter nenhum sinistro acionado no ano de 2017.

Tabela 3. Causas dos sinistros acionados para o milho primeira safra no Paraná nos anos de 2007 a 2018

Causa do sinistro	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	Total
Chuva excessiva	-	2	12	3	1	-	-	1	1	-	-	1	21
Geadas	-	-	-	-	-	15	-	-	2	-	-	-	17
Granizo	5	13	4	4	18	3	-	7	2	-	-	1	57
Inundação/Tromba d'água	-	-	-	-	1	-	1	2	-	-	-	-	4
Seca	4	1020	10	2	250	8	32	10	-	-	-	15	1351
Variação de preço	-	-	-	-	-	-	-	-	-	20	-	-	20
Ventos Fortes/Frios	-	1	7	-	1	5	-	-	2	-	-	-	16
Total	9	1036	33	9	271	31	33	20	7	20	0	17	1486

Fonte: Elaboração própria a partir dos dados do MAPA (2019).

O cenário se altera quando são analisados a quantidade de sinistros causados por intempéries climáticas na produção do milho segunda safra (Ver Tabela 4). Nesse caso, o número de sinistros motivados pela seca alcança a marca de 5422 registros no período de 2007 a 2018, com grande ocorrência de sinistros registrados nos anos de 2016 e 2018, provenientes da geada e pela forte seca, respectivamente. Com exceção dos sinistros causados no ano de 2009, o início do período analisado mostra poucos casos de sinistros, isso advém das baixas quantias da importância segurada em 2007 e 2008 (Ver Figura 11).

Tabela 4. Causas dos sinistros acionados para o milho segunda safra no Paraná nos anos de 2007 a 2018

Causa do sinistro	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	Total
Chuva excessiva	-	-	20	-	7	8	44	24	41	27	116	19	306
Demais causas	-	-	2	-	1	6	3	1	-	-	-	-	13
Geada	6	126	261	175	401	177	164	1	3	1454	53	4	2825
Granizo	-	7	5	2	3	28	22	14	12	75	3		171
Inundação/Tromba d'água	-	-	-	-	-	-	2	-	-	2	4	7	15
Raio	-	-	-	-	-	-	-	-	-	-	-	5	5
Seca	-	-	675	7	1	30	65	21	39	797	132	3655	5422
Varição excessiva de temperatura	-	-	-	-	-	-	1	-	-	1	-	1	3
Ventos Fortes/Frios	-	1	9	4	11	13	31	106	104	115	94	159	647
Total	6	134	972	188	424	262	332	167	199	2471	402	3850	9407

Fonte: Elaboração própria a partir dos dados do MAPA (2019).

Os sinistros implicam em grande perda da produção e parte do valor da produção esperada para o ano é protegida pelo seguro agrícola. O valor dessa produção é dado pela importância segurada (valores nominais R\$) e a comparação entre a primeira e segunda safra do milho com a subvenção total (valores nominais R\$) disponibilizada é apresentada na Figura 11. Verifica-se que de 2007 a 2011 os valores da importância segurada do milho primeira safra eram maiores que da segunda safra, porém, a partir desse período houve uma mudança no comportamento das séries, onde a importância segurada do milho segunda safra supera o da primeira, exceto em 2014.

A substituição da produção do milho safra pela segunda safra ocorre em função deste último ser cultivado logo após a colheita da soja, com o intuito de produzir cobertura morta para o solo no sistema de plantio direto. Outro ponto a considerar é a crescente demanda por milho no período “entressafra”, o que causou elevação dos preços e aumentou o interesse dos produtores no seu plantio nesse período. Ressalta-se que em conjunto com esse aumento da produção segunda safra houve a diminuição da produção do milho primeira safra. Devido à importância da soja no mercado internacional a produção do milho no verão foi perdendo

espaço para que os produtores cultivem a soja nesse período e o milho na segunda safra (DUARTE *et al*, 2015; MANGILI; ELY, 2016).




Figura 11. Importância segurada da produção do milho da primeira e segunda safra e o valor da subvenção total no Paraná, nos anos de 2007 a 2018.

Fonte: Elaboração própria.

Nesse contexto, a Figura 12 mostra o comparativo entre o valor das indenizações pagas (valores nominais R\$) entre milho primeira safra com o da segunda safra, no período de 2007 a 2018. Desde 2009 os valores de indenizações pagas do milho segunda safra são superiores aos da primeira safra, mesmo o valor da importância segurada do último só ultrapassar a do primeiro a partir de 2011 (Ver Figura 11). Nos anos de 2009, 2016 e 2018 houve saltos no pagamento das indenizações do milho segunda safra (conforme Tabela 4) provenientes do aumento ocorrido no número de registro de sinistros, principalmente ocasionados pelas geadas e secas. Em virtude dos valores das indenizações pagas ao milho primeira safra serem muito inferiores ao da segunda safra, esta pesquisa irá focar na produção média do milho segunda safra.

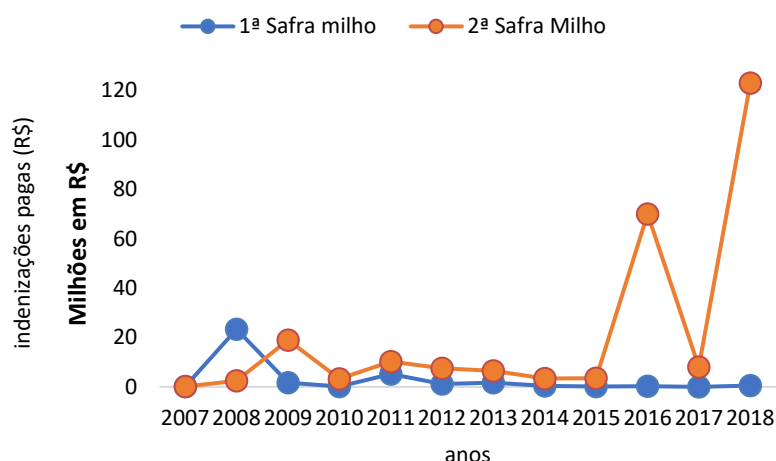


Figura 12. Valor das indenizações pagas aos produtores de milho da produção do milho segunda safra no Paraná, nos anos de 2007 a 2018.

Fonte: Elaboração própria.

A Figura 13 apresenta a soma do total dos prêmios pagos na contratação do seguro (valores nominais R\$) em relação ao total de indenizações pagas dos sinistros do milho segunda safra (valores nominais R\$), no período de 2007 a 2018. Em conformidade com a análise anterior, percebe-se que apenas nos anos de 2009, 2016 e 2018 o valor das indenizações pagas superaram ao do prêmio, no entanto, nos anos de 2012 e 2013 os prêmios pagos superaram em mais de 80% os de indenizações e em 2014, 2015 e 2017 essa relação foi para mais de 90%.

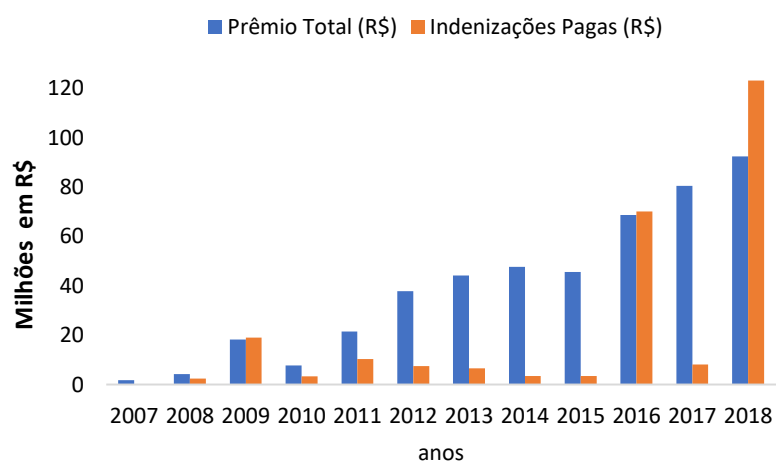


Figura 13. Comparativo entre o total pago pelos prêmios e suas indenizações para produção de milho segunda safra no Paraná, nos anos de 2007 a 2018.

Fonte: Elaboração própria.

A sinistralidade média é a razão entre as indenizações pagas e o total de prêmios, em que valores acima de 1 indicam que as seguradoras pagaram mais indenizações do que

receberam pelos prêmios do seguro. Para analisar a sinistralidade média, optou-se por utilizar os sinistros ocorridos apenas por adversidades climáticas e informações no período de 2013 a 2018, em função de dados mais recentes serem mais abrangentes em quantidade de municípios.

A Tabela 5 apresenta as estatísticas descritivas das sinistralidades médias para a produtividade do milho segunda safra. Os anos de 2016 e 2018 foram os únicos anos que apresentaram média acima de 1, apontando que nesses anos houve maior pagamento de indenizações do que o que foi recebido pelos prêmios do seguro. Ademais, esses anos exibiram a menor variabilidade, visto pelo coeficiente de variação e maior número de ocorrências registrados, reflexo do que foi visto na Figura 13.

Tabela 5. Estatística descritiva para sinistralidade média da produtividade do milho segunda safra, Paraná, no período de 2013 a 2018

Ano	Média	Mínimo	Máximo	Coeficiente de variação (%)	Ocorrências
2013	0.41	0.00	4.57	111.27	188
2014	0.22	0.00	3.54	112.81	196
2015	0.21	0.00	2.06	150.90	201
2016	1.47	0.00	6.54	114.42	230
2017	0.33	0.00	2.09	165.41	244
2018	1.52	0.00	7.14	117.31	266

Fonte: Elaboração própria.

No caso da soja a Tabela 6 mostra que os sinistros são acionados em sua grande maioria pelas secas, chuvas excessivas e granizo, em que correspondem a 15.338, 1.179 e 1.124 dos casos registrados, respectivamente. Os anos com maior número de ocorrências de sinistros foi o de 2011, 2008, 2018 e 2013, grande parte das perdas da produção responsáveis pelas secas.

Tabela 6. Causas dos sinistros acionados para a soja no Paraná nos anos de 2007 a 2018

Causa do sinistro	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	Total
Chuva excessiva	6	17	62	25	26	66	9	66	508	68	207	119	1179
Demais causas	-	-	-	-	-	-	-	-	-	1	-	3	4
Geada	-	-	-	1	1	-	2	-	1	-	-	1	6
Granizo	57	134	98	56	256	74	61	92	29	35	61	171	1124
Incêndio	-	-	1	-	4	1	-	2	-	1	-	-	9
Inundação/Tromba d'água	7	3	30	-	5	1	4	15	27	23	44	31	190
Raio	-	1	-	-	-	-	-	-	-	-	1	6	8
Replanteio	-	-	-	-	-	-	-	-	-	1	-	-	1
Seca	18	3858	72	8	5239	128	1885	544	50	195	49	3292	15338
Varição de preço	-	-	-	-	-	-	-	-	-	-	-	4	4
Varição excessiva de temperatura	-	1	1	1	1	2	4	6	4	-	-	1	21
Ventos Fortes/Frios	-	3	1	1	-	-	6	5	1	-	1	3	21
Total	88	4017	265	92	5532	272	1971	730	620	324	363	3631	17905

Fonte: Elaboração própria.

A Figura 14 indica os valores do prêmio total, indenizações pagas e importância segurada de soja no período de 2006 a 2018, todos em valores nominais. No caso da soja, a importância segurada é crescente ao longo dos anos, com exceção do ano de 2015, na qual houve uma queda significativa de mais de 50% em comparação ao ano anterior. As indenizações pagas superam os prêmios nos anos de 2008, 2011 e 2018, ocasionados em grande parte pelas secas e, em seguida, pelas chuvas de granizo. De forma semelhante ao que acontece com o milho, em vários anos o valor recebido pelo pagamento dos prêmios supera em mais de 80% 90% os valores pagos em indenizações, exceto os anos de 2008, 2011, 2013, 2015.

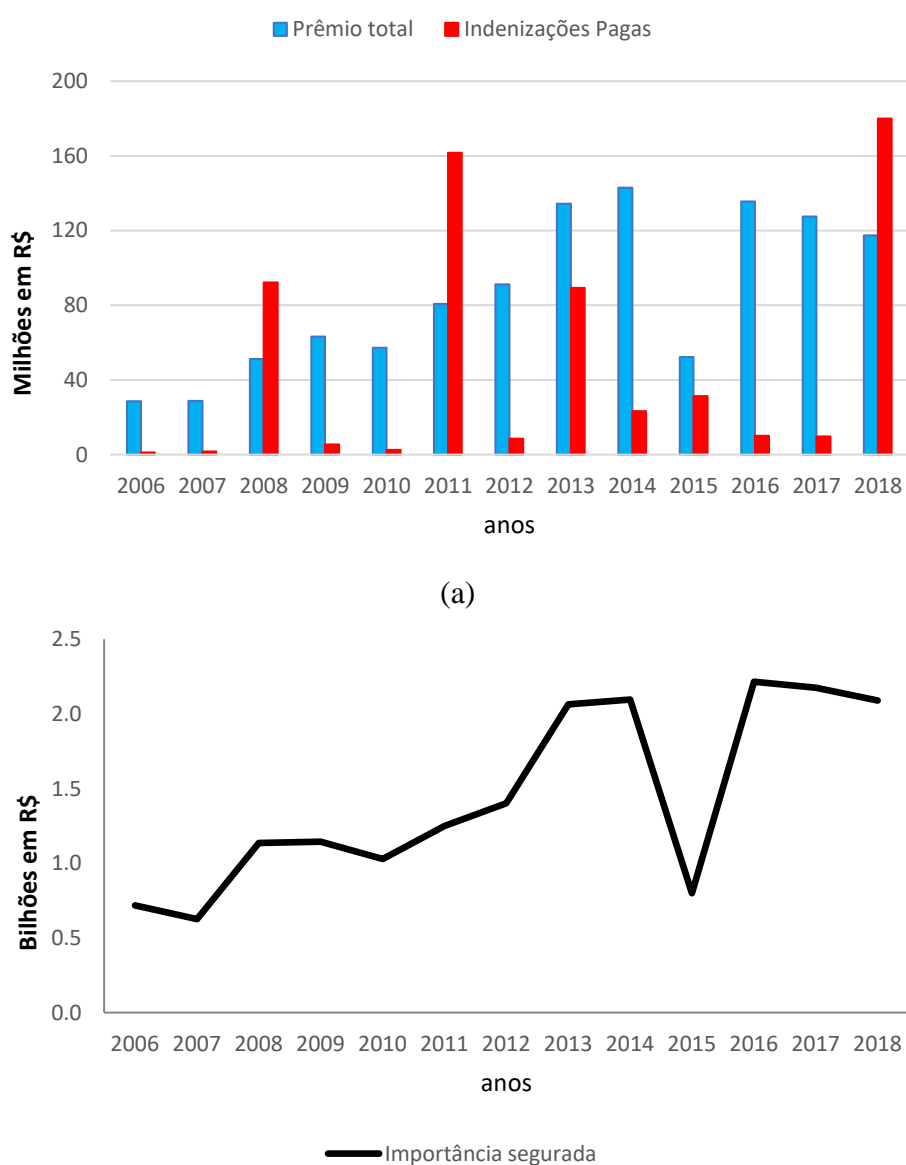


Figura 14. Prêmio total, indenizações pagas (a) e importância segurada (b) para produção de soja no Paraná, nos anos de 2006 a 2018.

Fonte: Elaboração própria.

A Tabela 7 apresenta as estatísticas descritivas para sinistralidade média para soja, em que apenas os anos de 2014, 2016 e 2017 se obteve média abaixo de 1, isto é, apenas nesses anos as seguradoras receberam mais prêmios do que pagaram em indenizações por efeitos climáticos. O ano de 2013 e 2015 possuem as maiores médias e mediana para sinistralidade, o valor máximo alcançado da sinistralidade foi de 13,61 e 11,83, respectivamente, o que significa que na primeira a seguradora pagou mais de 13 vezes em indenização o que foi recebido pelo prêmio do seguro, e na segunda quase 12 vezes.

Tabela 7. Estatística descritiva para sinistralidade média da produtividade da soja no Paraná, nos anos de 2013 a 2018.

Ano	Média	Mínimo	Máximo	Coeficiente de variação (%)	Ocorrências
2013	1.73	0.00	13.61	230.78	372
2014	0.59	0.00	6.39	151.53	378
2015	1.11	0.00	11.83	262.41	332
2016	0.28	0.00	5.52	124.10	369
2017	0.31	0.00	3.47	96.38	373
2018	1.49	0.00	9.28	157.59	367

Fonte: Elaboração própria.

Pode-se inferir que no período escolhido para análise não foi sempre que ocorreram eventos do tipo catastrófico, alguns anos sofreram mais com os efeitos climáticos do que outros, principalmente pela seca, que é a grande responsável pelo acionamento dos sinistros. No entanto, a arrecadação dos valores dos prêmios pelas seguradoras pode estar superestimada, em função da grande diferença percebida entre o valor recebido do prêmio e a proporção repassada em forma de indenizações nos anos em que não houve muitos registros de sinistros, o que já foi constatado em diversos estudos que propõem a precificação do prêmio do seguro (OZAKI, 2005; SANTOS, 2011; SANTOS, 2017).

3.3. Metodologia

Nesta seção serão descritas as ferramentas de estatística espacial utilizadas para obtenção dos resultados. Primeiro será discutido como obter o arco de distância de influência espacial por meio de correlogramas espaciais, em seguida, a descrição de modelos de regressão espacial e os modelos empíricos propostos. Por último será mencionada a fonte de dados adotada nesta pesquisa.

3.3.2. Correlograma Espacial

Um correlograma se trata de gráficos que demonstram como a autocorrelação espacial varia em função da distância entre vizinhos. Nesse sentido, pode-se utilizar um correlograma espacial não paramétrico como uma ferramenta alternativa da autocorrelação espacial global, que não necessita da especificação de uma matriz de pesos espaciais (ODEN, 1984; ANSELIN; REY, 2014).

Nessa perspectiva, o correlograma não-paramétrico é calculado por meio de uma regressão local nas correlações aos pares que se enquadram dentro de um compartimento de distância. Dessa maneira, o I de Moran para cada uma dos k diferentes compartimentos de distância é dado pela equação (3.1).

$$I^{(k)} = \left(\frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij}^{(k)} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2 (\sum_{i \neq j} \sum w_{ij}^{(k)})} \right) \quad (3.1)$$

Com $i = 1, \dots, n$, relativos a cada município.

Em que:

I é índice de Moran para cada um dos compartimentos;

k são os compartimentos de distância;

n é número de municípios;

w_{ij} é a matriz de distância espacial padronizada;

y_i e y_j são os valores observados da produtividade ou sinistros no município i e j ;

\bar{y} é a média da produtividade ou sinistros, observada em todos os municípios analisados.

Conforme Anselin e Rey (2014), o número de compartimentos (k) indica o intervalo de distância de cada compartimento. Esse intervalo é a distância máxima dividida pelo número de posições. Salienta-se que o número de caixas escolhidas está associado ao detalhamento do correlograma, isto é, quando maior for o número de caixas, mais detalhado será o correlograma.

3.3.2. Modelos de Regressão Espacial

Quando se pretende analisar o relacionamento entre duas ou mais variáveis, de modo que o valor de uma delas possa ser estimado pelas demais, utiliza-se modelos de regressão. Na análise de regressão, busca-se um bom ajuste entre os valores preditos pelo modelo e os valores observados da variável dependente. Ademais, as premissas do Melhor Estimador Linear Não-Viesado (MELNV), obtido por meio do método de Mínimos quadrados

Ordinários (MQO) afirma que as observações não são correlacionadas, sendo assim, os resíduos do modelo são independentes e não-correlacionados com a variável dependente, além de apresentarem distribuição normal com média zero e variância constante (CÂMARA *et al*, 2004).

Contudo, caso os dados analisados apresentem dependência espacial, a hipótese de que as observações não são correlacionadas pode não ser verdadeira. Dessa maneira, deve-se investigar os resíduos da regressão em busca de sinais da estrutura espacial; caso seja identificada a presença de dependência espacial, deve-se incorporá-la ao modelo de regressão, visto que a não inclusão dos efeitos espaciais tende a alterar o poder explicativo do modelo, superestimando a significância dos parâmetros e podendo até mesmo induzir a associações espúrias (FOTHERINGHAM; BRUNSDON; ANSELIN, 2002; CÂMARA *et al.*, 2004).

Salienta-se que para diagnosticar a presença de efeitos de dependência espacial, assim como inserir estes efeitos no modelo, é necessário definir, previamente, uma matriz de pesos espaciais conhecida como W . Neste estudo, a matriz será definida utilizando a regra da rainha com os vizinhos estabelecidos de forma similar à regra de movimentação de peças do xadrez (ANSELIN, 2002).

Dessa forma, esse tipo de modelagem captura a estrutura espacial por meio de um único parâmetro que é adicionado ao modelo de regressão tradicional. Sendo assim, neste estudo serão testados o Modelo Espacial Autorregressivo Misto (*Spatial Autorregressive - SAR* ou *Spatial Lag Model*) e o Modelo de Erro Espacial (*Conditional Auto Regressive - CAR* ou *Spatial Error Model-SEM*).

A seleção do modelo de regressão espacial mais adequado é uma questão importante, visto que cada modelo possui suas peculiaridades em estimação e interpretação. Sendo assim, a Figura 15, ilustra a regra de decisão do modelo mais adequado para se utilizar quando se investiga a possível presença de dependência espacial nos dados explorados.

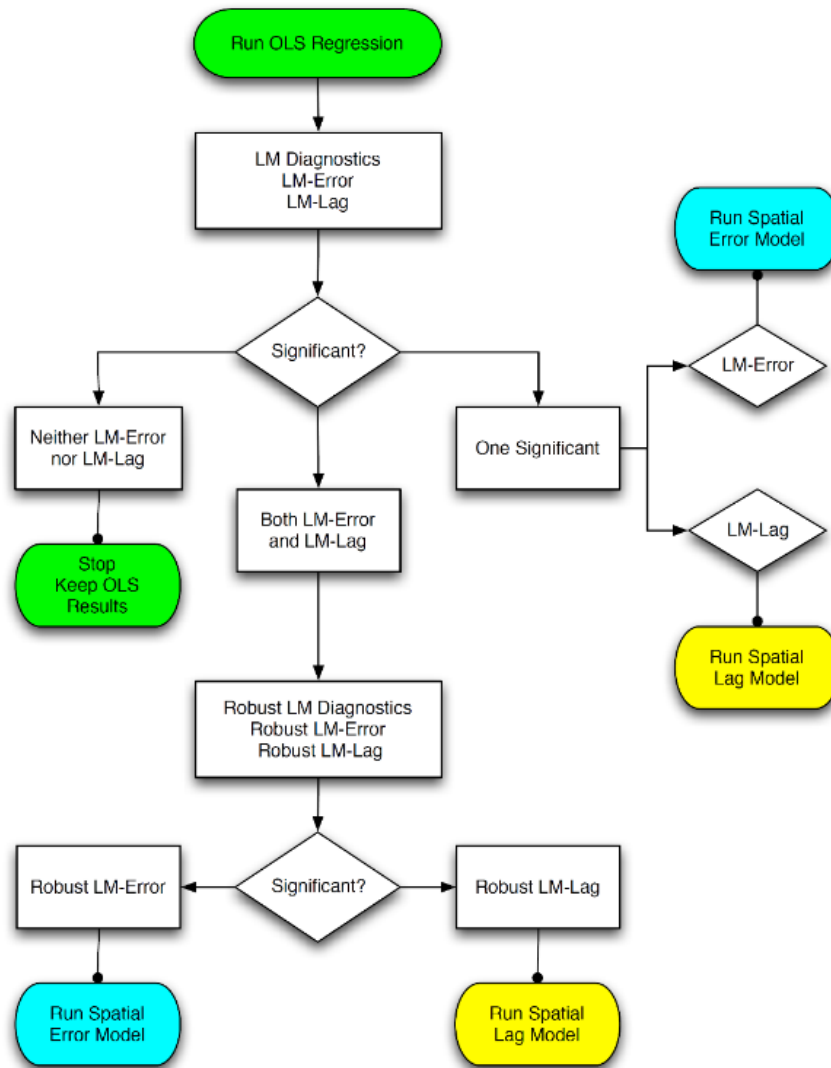


Figura 15. Decisão do Processo de Regressão Espacial.
Fonte: Anselin (2005).

Conforme é possível observar na Figura 15, o primeiro passo no processo decisório da seleção do modelo mais adequado consiste na estimação de um modelo de Mínimos Quadrados Ordinários – MQO, com intuito de se obter os diagnósticos da regressão para a dependência espacial dos resíduos. Após a obtenção dos resíduos, dois testes devem ser realizados para verificar a presença de dependência espacial no modelo. Os testes se referem ao LM - Error e LM – Lag. Caso se verifique a significância do teste LM – Lag, o modelo SAR deve ser selecionado; se o teste LM Error for significativo, o modelo SEM deve ser escolhido. Se nenhum dos dois testes forem significativos, então o MQO pode ser utilizado para estimar os parâmetros do modelo. Contudo, se ambos os testes forem significativos, segue-se para a próxima etapa, que consiste em realizar os testes robustos. Nessa etapa, a escolha do modelo mais adequado será dada pela estatística do teste que forneça o *p-valor*

mais significativo em conjunto com o menor valor para o critério de informação de Akaike (AIC).

3.3.2. Modelo Empírico

Neste estudo, os modelos de econometria espacial serão utilizados com intuito de relacionar as variáveis de sinistros e produtividade média, tanto para a cultura de soja quanto para a de milho. Sendo assim, serão propostos dois modelos para verificar a relação entre tais variáveis.

O primeiro irá estimar uma regressão para medir o efeito espacial e espaço-temporal entre as sinistralidades, ou seja, será verificada a relação entre a variável dependente (sinistralidade) do ano de 2018 com seus anos antecedentes, os anos de 2013 a 2017. Ressalta-se que será estimado um modelo que relaciona a variável dependente com cada um dos anos anteriores. Dessa forma, o modelo a ser estimado MQO, SAR ou SEM, são descritos pelas equações (3.2), (3.3) e (3.4), respectivamente:

$$y_i = \beta_0 + W y_j \beta_1 + y_j \beta_2 + \varepsilon \quad (3.2)$$

$$y_i = \beta_0 + W y_j \beta_1 + y_j \beta_2 + \rho W y_j + \varepsilon \quad (3.3)$$

$$y_i = \beta_0 + W y_j \beta_1 + y_j \beta_2 + \varepsilon, \quad \text{onde } \varepsilon = \lambda W \varepsilon + \xi \quad (3.4)$$

Em que: y representa as sinistralidades médias, com $i = 2018$ e $j = 2013, 2014, \dots, 2017$, sendo $i > j$.

Nesses modelos, o $W y_j$ é a soma das sinistralidades do ano j , com β_1 sendo a magnitude do efeito espaço-temporal dos vizinhos no município. O sinal esperado é que seja positivo, o que significa que os vizinhos do município no ano j ainda compartilham semelhanças espaciais com o município no ano i . O parâmetro β_2 mede o efeito local ou *in-situ*, com expectativa de sinal positivo para indicar que o município no ano j possui comportamento semelhante quando analisado no ano i .

O segundo modelo proposto irá verificar a relação das sinistralidades com a produtividade média das culturas de milho e soja. Sendo assim, para cada ano será estimado um modelo que relacione como variável dependente as sinistralidades e como variável explicativa a produtividade média. Portanto, o modelo a ser estimado MQO, SAR ou SEM, podem ser expressos pelas equações (3.5), (3.6) e (3.7), respectivamente:

$$y_i = \beta_0 + W X_j \beta_1 + X_j \beta_2 + \varepsilon \quad (3.5)$$

$$y_i = \beta_0 + W X_j \beta_1 + X_j \beta_2 + \rho W y_i + \varepsilon \quad (3.6)$$

$$y_i = \beta_0 + WX_j\beta_1 + X_j\beta_2 + \varepsilon, \text{ onde } \varepsilon = \lambda W\varepsilon + \xi \quad (3.7)$$

Onde y representa as sinistralidades médias e X a produtividade média, sendo que $i = 2013, 2014, \dots, 2017$, e $i > j$.

O sinal esperado para o β_1 nesses modelos é que seja negativo, em que os vizinhos de um município que empreguem mais tecnologias para o aumento da produtividade o influenciem espacialmente para que ele também utilize essas técnicas de cultivo, implicando na diminuição das sinistralidades. De forma análoga, o β_2 irá medir a relação inversa entre produtividade e sinistralidades do mesmo município, sendo que o sinal esperado desse parâmetro é negativo, uma vez que se considera que um município que aumente sua produtividade por meio do conhecimento tecno-científico possa lidar melhor com problemas climáticos, minimizando suas perdas e o acionamento do seguro.

3.3.2. Base de dados

Os dados utilizados deste estudo são referentes aos 399 municípios do estado do Paraná, no qual foram analisadas as variáveis de sinistralidade média e produtividade média anual da soja e da segunda safra do milho no período de 2013 a 2018. A escolha desse período é em virtude de possuir uma base de dados mais consolidada para maior parte dos municípios.

As informações a respeito das sinistralidades por apólices foram obtidas no Atlas do Seguro Rural, elaborado pelo Ministério da Agricultura, Pecuária e do Abastecimento (MAPA). Os dados da produtividade média das culturas foram extraídos de sítio do Departamento de Economia Rural (DERAL) da Secretaria da Agricultura e Abastecimento (SEAB) do Paraná. A manipulação das planilhas foi realizada pelo *software Excel* e a aplicação dos métodos espaciais pelo *software* livre *Geodata Analysys* (GeoDa).

3.4. Resultados e discussões

Como visto na seção 3.2.1, as informações sobre importância segurada, indenizações pagas e sinistros para a primeira safra do milho indicam que atualmente essa cultura não possui um volume expressivo nessas variáveis. Portanto, para a construção dos resultados, optou-se pela análise referente apenas ao milho segunda safra.

Para medir o arco da distância da influência espacial da produtividade média do milho segunda safra. A Figura 16 expõe os correlogramas espaciais das safras de 12/13 até

2017/2018. Verifica-se que nos anos das safras 2012/2013, 2013/2014, 2014/2015 e 2016/2017, após certa distância, a correlação espacial é positiva e se estabiliza em torno de zero, enquanto nas safras de 2015/2016 e 2017/2018 essa relação se torna negativa.

Destaca-se que foram nessas duas safras que ocorreram os maiores registros de sinistros, com a safra 2015/2016 sofrendo com as geadas e a safra 2017/2018 com as secas. Este resultado é condizente com a primeira lei da geografia enunciada por Tobler (1970), onde afirma que todas as coisas estão relacionadas com todas as outras, mas as coisas próximas estão mais relacionadas do que as distantes, isto é, regiões mais distantes que não sofreram com os efeitos climáticos se comportaram de maneira distinta das que foram atingidas.




Figura 16. Correlogramas espaciais da produtividade do milho da segunda safra do Paraná, nos anos de 2013 a 2018.

Fonte: Elaboração própria.

O correlograma espacial para a produtividade média de soja é visto na Figura 17. Nos anos de 2013, 2015, 2017 e 2018 a correlação espacial se estabilizou após atingir a correlação nula, no entanto, nos anos de 2014 e 2016 surgem correlações espaciais negativas, sendo compatíveis com a primeira lei da geografia. Nestes anos, apresentam-se as correlações espaciais com maiores valores antes de atingir o arco da distância de influência espacial. Vale ressaltar que houve redução da produção da soja em 2014 e 2016, afetada por eventos climáticos, mesmo não sendo anos com maiores registros de sinistros.

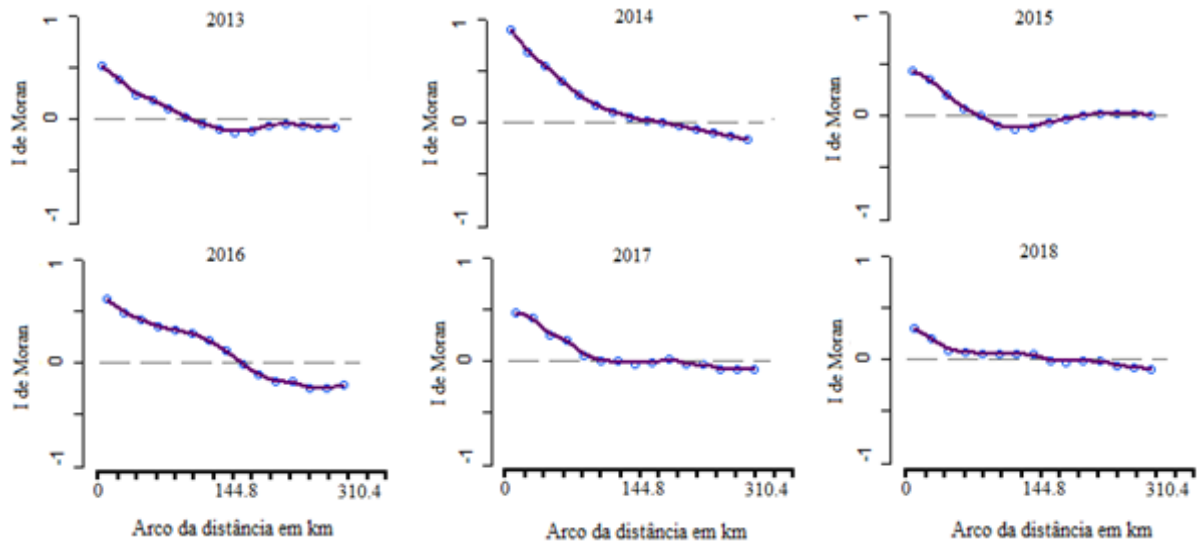


Figura 17. Correlogramas espaciais da produtividade da soja no Paraná, nos anos de 2013 a 2018.

Fonte: Elaboração própria.

O correlograma espacial para a sinistralidade média do milho segunda safra é apresentado na Figura 18. Constata-se que em todos os anos a correlação espacial se estabiliza a partir de uma certa distância, isto é, apresenta uma aleatoriedade espacial após atingir a distância máxima de influência espacial, exceto no ano de 2016 em que, após a perda da influência espacial positiva, apresenta-se de forma negativa e conserva a justificativa apresentada na análise da produtividade.

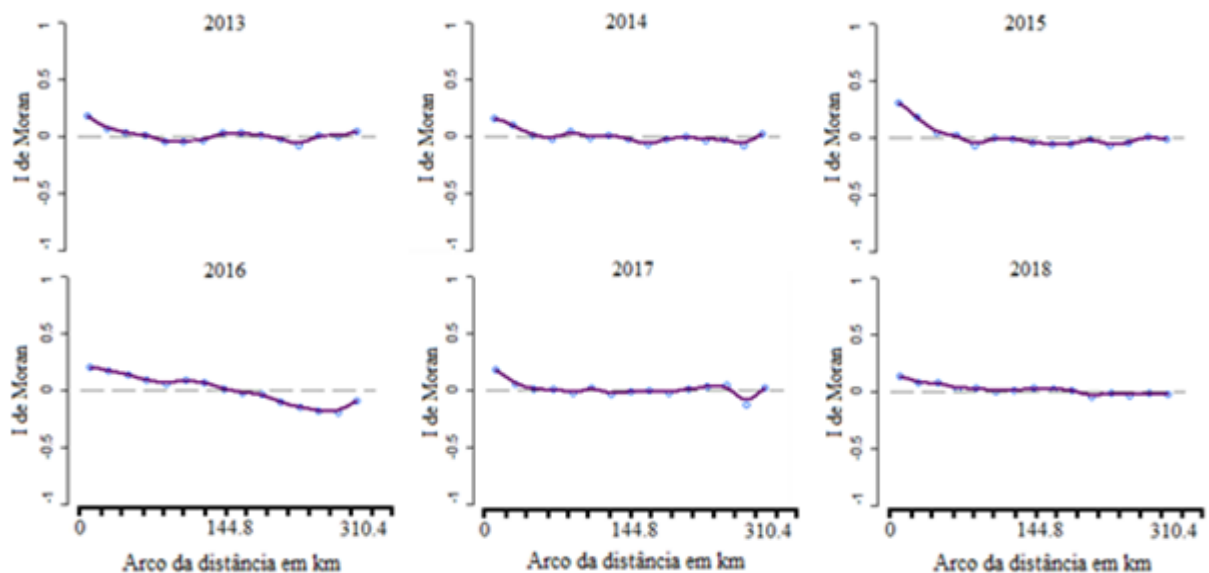


Figura 18. Correlogramas espaciais da sinistralidade média do milho da segunda safra do Paraná, nos anos de 2013 a 2018.

Fonte: Elaboração própria.

A Figura 19 apresenta os correlogramas espaciais para a sinistralidade média de soja. Em todos os anos, assim como ocorreu com o milho, as correlações espaciais se estabilizam

após atingir a distância máxima de influência espacial, enfatizando a existência de aleatoriedade espacial entre os municípios. Contudo, os anos de 2015 e 2018 apresentam correlações espaciais negativas, em que o ano de 2018 foi o que mais registrou ocorrências de sinistros, em sua maioria, provocados pela seca.




Figura 19. Correlogramas espaciais da sinistralidade média da soja no Paraná, nos anos de 2013 a 2018.

Fonte: Elaboração própria.

A Tabela 8 mostra a estimativa de alcance da influência espacial medida pelos correlogramas espaciais de Moran para produtividade e sinistros do milho segunda safra e da soja, no período de 2013 a 2018. Para a cultura do milho, os resultados indicam que na safra de 2015/2016 e 2017/2018 as distâncias de influência espacial obtiveram as maiores distâncias, registrando 152,8 km e 217 km, respectivamente. Considerando todo o período analisado, a distância que ainda exerce influência espacial é, em média, de 131,3 km. Esses resultados corroboram com os de Ozaki (2008) que chegou a uma distância média de 130,4 km para a produtividade de milho, no período de 1990 a 2002.

Em relação a sinistralidade média do milho, os anos com maiores distâncias novamente ocorreram em 2016 (160,8 km) e 2018 (112,4 km). Os efeitos de maiores distâncias ocorrem em anos onde existiram maiores registros de sinistros em decorrência das intempéries climáticas apresentadas na Tabela 4. No total do período, a distância alcançada pela influência espacial é, em média, de 92,2 km, sendo uma distância inferior à obtida na produtividade média do milho. Porém, vale ressaltar que existem muitos municípios com

dados ausentes, o que impossibilita analisar a influência que estes poderiam sofrer, podendo ampliar a medida da distância de influência espacial.

Os resultados para a soja mostram que a distância de influência espacial alcançou menor valor no ano de 2015, com 90,6 km. Contudo, nos anos de 2014, 2016 e 2018 a distância de influência espacial foram maiores, partindo de 169,8 km no ano de 2018 km e atingindo a marca de até 207 km em 2014. A distância média de influência espacial de todo o período de análise foi de 144,2 km. Esses resultados estão em conformidade aos apresentados no estudo de Ozaki (2008) realizados com dados de 1990 a 2002, em que obteve um valor médio da distância de 144,8 km e Lopes *et al.* (2017) de 121,9 km na média com informações dos anos de 2010 a 2013.

Tabela 8. Estimativa, em km, da influência espacial para produtividade e sinistralidade do milho e da soja no Paraná, no período de 2013 a 2018.

Ano	Produtividade		Sinistro	
	Milho	Soja	Milho	Soja
2013	129.4	119.8	72.6	93.10
2014	76.80	207.0	56.1	170.6
2015	119.1	90.60	75.30	177.1
2016	152.8	171.9	160.8	148.5
2017	92.70	106.0	75.80	99.40
2018	217.0	169.8	112.4	231.3
Média	131.3	144.2	92.2	153.3

Fonte: Elaboração própria.

Para a sinistralidade média da soja, destaca-se o ano de 2018, alcançando 231,3 km de distância. Nesse ano houve um grande registro de ocorrência de sinistros pela seca. A segunda maior distância de influência espacial foi o ano de 2015, mesmo não sendo um ano com muitas ocorrências de sinistros, atingiu 177,1 km, devido aos sinistros provocados por fortes chuvas. A média das distâncias no período foi de 153,3 km, nesse caso, superior ao estimado nesta pesquisa e a realizada por Ozaki (2008) em relação à produtividade. Portanto, os sinistros cobrem uma distância de influência espacial maior do que o registrado para a produtividade.

Com a finalidade de verificar qual modelo econométrico espacial é mais indicado para relacionar as sinistralidades médias do milho segunda safra de 2018 com seus anos defasados desde 2013, a Tabela 9 mostra o diagnóstico realizado pelo MQO com as estatísticas para os testes de seleção do modelo. A decisão de escolha entre os modelos foi obtida ao se analisar as estatísticas para o modelo SEM (LM-Error e Robusto LM – Error) e SAR (LM-Lag e

Robusto LM – Lag), quando ambos se mostraram significativos, o modelo escolhido é o que apresenta menor valor de AIC.

Em todos os anos as estatísticas LM foram significativas para os dois modelos, portanto, utilizou-se as estatísticas robustas desses testes, em que no ano de 2016 apenas a estatística R LM – Lag foi significativa a 10%; assim, o modelo escolhido foi o SAR. Nos demais anos, as estatísticas robustas dos dois testes foram significativas, sendo utilizado o menor valor do AIC para escolha dos modelos, na qual o modelo SAR foi apontado pelo AIC para os anos de 2013 e 2017, enquanto o SEM para os anos de 2014 e 2015.

Tabela 9. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial em relação às sinistralidades médias do milho segunda safra de 2018.

Ano	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	LM -Error	LM-Lag	R LM -Error	R LM-Lag	SEM-AIC	SAR-AIC
2013	-0.12*	0.64**	0.08	25.01***	30.50***	10.82***	16.31***	903.5	902.18
2014	-0.26***	0.35**	0.12	48.42***	51.13***	4.96**	7.67***	911.10	911.81
2015	-0.22***	0.40***	0.15**	36.46***	42.37***	4.41**	7.32***	906.98	907.70
2016	-0.14**	0.37***	0.11*	31.95***	33.88***	1.34	3.27*	901.38	902.02
2017	-0.20***	0.61***	0.14**	21.20***	24.84***	4.25**	7.90***	894.93	894.79

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

Para os modelos escolhidos na Tabela 10, os coeficientes estimados e significativos para a influência espacial local e espaço-temporal apresentaram sinal positivo. Para o efeito de influência espacial local ($\hat{\beta}_2$), apenas os anos de 2014 e 2015 se apresentaram significativos a 10% e 5%, respectivamente. Esse efeito aponta que nesses anos os municípios compartilham similaridades espaciais com os municípios de 2018 em relação a sinistralidade média.

Nos anos de 2013, 2015, 2016 e 2017 o coeficiente espaço-temporal ($\hat{\beta}_1$) foi significativo e este resultado revela que existe influência espaço-temporal dos municípios vizinhos desses anos com os municípios em 2018, isto é, ao longo do tempo os municípios vizinhos ainda influenciam espacialmente os municípios em 2018. No caso do modelo para o ano de 2014 esse efeito não se apresenta significativo em comparação com as sinistralidades médias de 2018, devido à pouca ocorrência de registro de sinistros nesse ano, não existem muitos municípios que compartilham semelhanças espaciais no comparativo desses dois anos.

Tabela 10. Modelo de regressão espacial aplicado para analisar a correlação espacial e espaço-temporal em relação às sinistralidades médias do milho segunda safra de 2018.

Modelo	Ano	β_0	β_1	β_2	SEM: $\hat{\lambda}/SAR : \rho$
SAR	2013	-0.08	0.41***	0.06	0.36***
SEM	2014	-0.30	0.22	0.12*	0.43***
SEM	2015	-0.26	0.30**	0.16**	0.41***
SAR	2016	-0.09	0.24***	0.08	0.37***
SAR	2017	-0.14**	0.42***	0.10	0.33***

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

A Tabela 11 mostra os testes para selecionar o melhor modelo espacial que relaciona as sinistralidades médias com a produtividade média do milho segunda safra. Pelas estatísticas dos testes LM, os dois modelos SEM e SAR são significativos, porém não apresentam significância estatística para os testes robustos, exceto para o ano de 2015. Portanto, a escolha do modelo se baseia no menor valor do AIC. Diante dos resultados, as estatísticas AIC para o modelo SEM apresentaram os menores valores em relação ao SAR, logo esse modelo foi escolhido para todos os anos.

Tabela 11. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial das sinistralidades médias do milho em relação a sua produtividade anual

Ano	β_0	β_1	β_2	LM -Error	LM-Lag	R LM -Error	R LM-Lag	SEM-AIC	SAR-AIC
2013	-0.32***	-0.19	0.19**	51.90***	52.38***	0.14	0.62	887.79	889.54
2014	-0.33***	0.005	0.08	52.17***	52.23***	1.44	1.53	890.61	892.62
2015	-0.30***	-0.26**	0.15*	44.43***	46.72***	4.11**	6.41**	870.40	871.25
2016	-0.29***	-0.18	-0.11	31.94***	32.14***	0.03	0.23	857.29	859.03
2017	-0.29***	-0.08	0.1412	48.53***	48.77***	0.25	0.49	857.89	859.80
2018	-0.30***	-0.30***	-0.22***	19.14***	19.16***	0.05	0.07	824.55	826.32

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

Os resultados dos modelos ajustados são apresentados na Tabela 12. No ano de 2013 e 2017 o coeficiente estimado que mede a influência espacial local diferiu do esperado, sendo que foi positiva e significativa a 5% e 10%, respectivamente, indicando que parte dos municípios que tiveram boa produtividade de milho em 2013 e 2017 registraram sinistros e acionaram o seguro em 2018. Nos anos de 2014 e 2015 os coeficientes não foram significativos e isso pode ter ocorrido em função de terem sido os anos com menor registro de sinistros.

No entanto, para o ano de 2016, o efeito espacial local foi negativo e significativo a 10% e no ano de 2018 tanto o efeito espaço-temporal quanto o local foram negativos e

significativos a 1%. Esse resultado indica que para 2016 os municípios que tiveram boa produtividade de milho acionaram menos o seguro em 2018. De forma análoga ocorre em 2018 ao se analisar os sinistros com a produtividade, porém com maior significância para medir este relacionamento, o que fica em acordo com o esperado. Salienta-se que esses anos sofreram com maiores registros de sinistros, em 2016 devido a geadas, e 2018 pela seca, o que refletiu em maior dispersão espacial em relação aos demais anos com menor valor medido para $\hat{\lambda}$.

Tabela 12. Modelo de regressão espacial aplicado para analisar a correlação espacial das sinistralidades média do milho em relação a sua produtividade anual

Modelo	Ano	β_0	β_1	β_2	SEM: $\hat{\lambda}$ /SAR: ρ
SEM	2013	-0.34***	-0.12	0.16**	0.42***
SEM	2014	-0.35***	0.04	0.08	0.43***
SEM	2015	-0.32***	-0.14	0.11	0.41***
SEM	2016	-0.31***	-0.12	-0.15*	0.34***
SEM	2017	-0.32***	-0.005	0.13*	0.40***
SEM	2018	-0.31***	-0.30***	-0.22***	0.29***

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

A Tabela 13 se refere aos resultados dos testes para diagnosticar o modelo espacial mais adequado para relacionar as sinistralidades médias da soja no ano de 2018 com seus anos anteriores. Diante dos resultados dos testes, no ano de 2015, os testes LM foram significativos a 1% para os modelos SEM e SAR, porém não foram significativos nos testes robustos, portanto, o modelo SEM foi o escolhido devido a possuir menor valor para o AIC. Nos demais anos, o modelo escolhido foi o SAR por apresentar significância nos testes LM robusto ou menor valor para o AIC.

Tabela 13. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial em relação às sinistralidades médias da soja de 2018

Ano	β_0	β_1	β_2	LM -Error	LM-Lag	R LM -Error	R LM-Lag	SEM-AIC	SAR-AIC
2013	0.01	0.28***	0.16***	98.07***	100.76***	0.46	3.16*	739.19	739.74
2014	-0.03	0.49***	0.16***	66.90***	77.91***	6.53**	17.54***	741.64	739.12
2015	0.03	0.21**	0.09	112.35***	113.80***	0.32	1.77	747.98	749.56
2016	-0.006	0.43***	0.18***	80.41***	87.42***	2.67	9.68***	741.46	740.75
2017	-0.02	0.49***	0.18***	76.02***	84.22***	2.81*	11.00***	738.77	737.46

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

A Tabela 14 apresenta os coeficientes estimados para os modelos escolhidos nos anos de 2013 a 2017. Para todos os anos o efeito espacial local foi significativo; em relação ao

efeito espaço-temporal, apenas nos anos 2013 e 2015 não apresentaram significância estatística. Os coeficientes para os efeitos espaciais foram positivos, estando em acordo com o esperado. Portanto, todos os anos apresentam similaridades espaciais com 2018, os municípios e seus vizinhos ainda compartilham similaridades espaciais com os municípios em 2018.

Tabela 14. Modelo de regressão espacial aplicado para analisar a correlação espacial e espaço-temporal em relação às sinistralidades médias da soja de 2018

Modelo	Ano	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	SEM: $\hat{\lambda}/SAR : \hat{\rho}$
SAR	2013	-0.01	0.04	0.16***	0.54***
SAR	2014	-0.03	0.19**	0.12***	0.51***
SEM	2015	-0.02	0.11	0.10**	0.56***
SAR	2016	-0.02	0.20**	0.12**	0.51***
SAR	2017	-0.03	0.19**	0.14***	0.51***

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

A Tabela 15 apresenta os testes para verificar o modelo espacial que será adotado nas análises das sinistralidades médias da soja em relação a sua produtividade. De acordo com os testes, o modelo SEM foi indicado para os anos 2013 e 2016, por possuir menor p-valor para o AIC, no entanto, o modelo SAR foi escolhido para os demais anos com base na significância do teste LM robusto ou pelo menor valor de AIC.

Tabela 15. Diagnóstico MQO para verificar o modelo adequado para aplicar a regressão espacial sinistralidades médias da soja em relação a sua produtividade anual

Ano	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	LM -Error	LM-Lag	R LM -Error	R LM-Lag	SEM-AIC	SAR-AIC
2013	0.05	-0.17*	0.07	134.66***	134.12***	0.56	0.02	723.74	725.76
2014	0.04	-0.37***	0.09	103.50***	106.33***	1.27	4.11**	718.50	718.72
2015	0.07	-0.45**	0.15*	123.62***	125.97***	0.0005	2.35	709.91	709.63
2016	-0.04	-0.28***	0.05	119.31***	121.03***	0.17	1.89	717.02	717.90
2017	0.06	-0.25**	-0.09	107.86***	110.16***	0.68	3.00*	714.22	715.23
2018	-0.06	-0.36***	-0.02	107.26***	113.74***	3.07*	9.55***	716.29	715.90

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

Pode-se verificar a estimativa dos modelos escolhidos para os anos em análise por meio da Tabela 16. Diferente do que ocorreu com o milho, ao se construir os modelos para a soja não se encontrou significância estatística para o efeito espaço-temporal, apenas o modelo SAR para o ano de 2015 apresentou significância de 10%, e positivo para o coeficiente estimado da influência espacial local. Porém, a dinâmica espacial existente para soja implica em baixa similaridade espacial ao longo do tempo, mesmo as autocorrelações espaciais

possuindo valores acima de 0,50. Desse modo, para o ano de 2015 os municípios com alta produtividade compartilham uma influência espacial com os sinistros registrados nos municípios em 2018.

Tabela 16. Modelo de regressão espacial aplicado para analisar a correlação espacial sinistralidades médias da soja em relação a sua produtividade anual.

Modelo	Ano	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	SEM: $\hat{\lambda}/SAR: \rho$
SEM	2013	-0.005	-0.12	0.59	0.59***
SAR	2014	-0.003	-0.17	0.04	0.55***
SAR	2015	0.01	-0.31	0.17**	0.58***
SEM	2016	-0.06	-0.15	0.003	0.57***
SAR	2017	0.008	-0.09	-0.06	0.56***
SAR	2018	0.004	-0.16*	-0.01	0.56***

*Significativo a 10%; **Significativo a 5%; ***Significativo a 1%.

Fonte: Elaboração própria.

3.5. Conclusões

Este estudo teve como principal objetivo analisar os efeitos espacial e espaço-temporal dos dados de produtividade média e sinistros do seguro agrícola do milho segunda safra e de soja em relação aos efeitos das intempéries climáticas. Os métodos adotados para esse propósito foram correlogramas espaciais para medir a distância de influência espacial e econometria espacial para analisar os efeitos espaciais e espaço-temporal das sinistralidades médias e produtividade média nos municípios do Paraná, no período de 2013 a 2018.

Os resultados deste estudo mostram que ao analisar a produtividade média e sinistros de milho e soja, as maiores distâncias de influência espacial ocorreram em anos atingidos por efeitos climáticos. Contudo, a soja alcança um arco de distância maior de influência espacial do que o milho, principalmente em relação à sinistralidade média. Portanto, o milho apresenta municípios e seus vizinhos com maiores similaridades espaciais, mas a soja atinge uma distância de influência espacial superior ao milho. Estas análises sinalizam para as seguradoras que existe possibilidade de risco sistêmico para as duas culturas.

Nesse sentido, conclui-se que não há independência espacial entre as unidades seguradas, havendo homogeneidade espacial nos dados analisados. Ademais, com o elevado grau de risco sistêmico e a existência de correlação espacial, quando os municípios são atingidos por uma intempérie climática, isso pode gerar perdas espacialmente dependentes, que por sua vez, geram um risco de inadimplência das seguradoras que não estejam cobertas pelo Fundo de Estabilidade do Seguro Rural (FESR) para coberturas de riscos catastróficos.

Portanto, torna-se crucial que as seguradoras estejam parcialmente ou totalmente cobertas contra esses tipos de eventos em conjunto com a diversificação geográfica e setorial.

Algumas limitações desta pesquisa podem explicar as diferenças encontradas entre o milho e soja. A primeira é a distância de influência espacial do milho, que pode ter sido subestimada em razão de possuir dados ausentes para alguns municípios, o que pode ter restringido esse alcance. Outro fator é que as medidas de distâncias obtidas pelos correlogramas espaciais são obtidas pelos centroides dos municípios e não consideram os diferentes relevos existentes no Paraná, em que o milho é afetado por fortes geadas, que são influenciados pela altitude onde estão localizados os municípios. Por último, devido ao seguro agrícola não abranger todos os produtores de milho e soja, não é possível mensurar os efeitos espaciais que não foram registrados em forma de sinistros pelas seguradoras, o que faz perder as informações espaciais de parte da produção não segurada.

Para trabalhos futuros é indicado realizar esta análise incluindo alguma variável climática. Ademais, empregar técnicas que captem as distâncias de influência espacial, considerando os relevos dos municípios e outros modelos de econometria espacial para medir a influência espaço-temporal. Em relação à violação de independência e homogeneidade das unidades seguradas em função da influência espacial, sugere-se a utilização de modelos Autorregressivos e de Médias Móveis Espaço-Temporais (STARMA) para estimar a produtividade média, para que esses efeitos espaciais sejam incorporados na precificação.

Referências

- ANSELIN, L. **Spatial Econometrics: Methods and Models**, Dordrecht, Kluwer Academic Publishers. 1988.
- ANSELIN, L. Under the hood issues in the specification and interpretation of spatial regression models. **Agricultural Economics**, v. 27, n. 3, p. 247–267, 2002.
- ANSELIN, L.; REY, S. J. **Modern Spatial Econometrics in Practice: A Guide to GeoDa, GeoDaSpace and PySAL**, 2014.
- BOOTH, P.; CHADBURN, R.; COOPER, D.; HABERMAN, S.; JAMES, D. **Modern actuarial theory and practice**. London: Chapman & Hall/CRC, 1999. 716p.
- BURGO, Marcelo Nery. **Caracterização espacial de riscos na agricultura e implicações para o desenvolvimento de instrumentos para seu gerenciamento**. Mestrado (Dissertação) – Escola Superior de Agricultura Luiz de Queiroz – ESALQ, Piracicaba,

2005. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11132/tde-09052005-140315/publico/marcelo.pdf>.

CÂMARA, G., CARVALHO, M. S., CRUZ, O. G., CORREIA, V. Análise espacial de áreas. *In: DRUCK, S.; CARVALHO, M.S.; CÂMARA, G.; MONTEIRO, A.V.M. (eds.). Análise Espacial de Dados Geográficos*. Brasília, EMBRAPA, 2004. Disponível em: <http://www.dpi.inpe.br/gilberto/livro/analise>. Acesso em 22 jan. 2020.

CONFEDERAÇÃO DA AGRICULTURA E PECUÁRIA DO BRASIL - CNA. **Guia de seguros rurais e ProAgro**. 2015. Disponível em: http://www.cnabrazil.org.br/sites/default/files/sites/default/files/uploads/cartilha_seguro_rural_.pdf. Acesso em: 7 dez. 2019.

DUARTE, J. O; GARCIA, J. C; MIRANDA, R. A. Cultivo do milho. **Embrapa Milho e Sorgo**. Sistema de Produção 1. Versão eletrônica, 9ª edição. ISSN 1679-012X, Nov. 2015. Disponível em: <https://bit.ly/392GaOY>. Acesso em: 22 Mar 2020.

EMBRAPA. Variabilidade espacial e temporal da produção de soja no Paraná e definição de ambientes de produção [recurso eletrônico]: / Julio Cezar Franchini...[et al.] – Londrina: **Embrapa Soja**, 2016.

FORNAZIER, A.; SOUZA, P. M.; PONCIANO, N. J. A importância do seguro rural na redução de riscos da agropecuária. **Revista de Estudos Sociais**. v. 14, n. 28, p. 39 - 52, 2012. Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/res/article/download/1829/1372/0>. Acesso em: 2 dez. 2019.

GUIMARÃES, T. C.; IGARI, A. T. Mudança do clima e seus impactos no seguro agrícola no Brasil. *Rev. Agro. Amb.*, v. 12, n.4, p. 1583-1604, out./dez. 2019.

GOODWIN, B.K., Problems with Market insurance in agriculture. **American Journal of Agricultural Economics**. vol. 83, edição 3, p. 643-649, 2001. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/0002-9092.00184>. Acesso em: 2 dez. 2019.

HART, D.G.; BUCHANAN, R.A.; HOWE, B.A. The actuarial practice of general insurance. 5.ed. Sydney: **The Institute of Actuaries of Australia**, 1996. 592p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Valor Adicionado da Agropecuária**. Disponível em: <http://www.sidra.ibge.gov.br/tabela5938>. 2018.

INTERNATIONAL WATER MANAGEMENT INSTITUTE – IWMI. **Strategy 2014 – 2018: solution for a water secure world**. 2014. Disponível em:

- <http://www.iwmi.cgiar.org/About_IWMI/PDF/iwmi-strategy-2014-2018.pdf>. Acesso em: 2 dez. 2019.
- LOPES, P. F.; CHAIN, C. P.; MENEZES, T. P.; PRADO, J. W.; CARVALHO, F. M. Gestão de riscos e dependência espacial em seguros agrícolas: Uma análise da produtividade da soja. **Interciência: Revista de Ciência e Tecnologia das Américas**, Caracas, v. 42, n. 8, p.503-518, jun. 2017. Disponível em: <https://www.interciencia.net/wp-content/uploads/2017/08/503.pdf>. Acesso em: 10 jan. 2020.
- MANGILI, F. B., ELY, D. F. Análise da Relação da Produção do Milho Segunda Safra com o Balanço Hídrico Sequencial em Londrina (PR). **Geografia (Londrina)**. v. 25. n. 1. p.65-85, jan/jun, 2016.
- MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO - MAPA. Dados de indenizações – 2006 a 2018. 2019. Disponível em: <http://www.agricultura.gov.br/assuntos/riscosseguro/seguro-rural/relatorios-estatisticos>. Acesso em: 10 jan. 2020.
- ODEN, N. L. Assessing the Significance of a Spatial Correlogram. **Revista: Geographica Anazysis**, New York, v. 16, n. 1, jan. 1984. Disponível em: <https://onlinelibrary.wiley.com/doi/epdf/10.1111/j.1538-4632.1984.tb00796>. Acesso em: 10 jan. 2020.
- OZAKI, V. A. **Métodos atuariais aplicados à determinação da taxa de prêmio de contratos de seguro agrícola: um estudo de caso**. Tese (Doutorado em Economia Aplicada) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2005. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11132/tde-11072005-160540/publico/VitorOzaki.pdf>. Acesso em 08 abr. 2018.
- _____. O papel do seguro na gestão do risco agrícola e os empecilhos para o seu desenvolvimento. **Rev. Bras. Risco Seguro** 2(4): 75-92, 2007.
- _____. Análise espacial da produtividade agrícola no Estado do Paraná: implicações para o seguro agrícola. **Rev. Econ. Sociol. Rural** 46: 869-886, 2008.
- OZAKI, V.A.; SHIROTA, R. Um estudo da viabilidade de um programa de seguro agrícola baseado em um índice de produtividade regional em Castro (PR). **Revista de Economia e Sociologia Rural**, Rio de Janeiro, v. 43, n.3, p. 485-503, jul./set. 2005.
- OZAKI, V.A.; DIAS, C.T.S. Análise e quantificação do risco para a gestão eficiente do portfólio agrícola das seguradoras. **Rev. Econ. Sociol. Rural**. 47: 549-567, 2009.

- RAMOS, Rejane Cecília. **O seguro rural no brasil: origem, evolução e proposições para aperfeiçoamento.** Informações Econômicas, SP, v.39, n.3, mar. 2009. Disponível em: <http://www.iea.sp.gov.br/ftp/iea/publicacoes/IE/2009/tec1-0309.pdf>.
- SANTOS, C O. **A distribuição Skew-Normal como modelo para a produtividade de milho aplicada ao Seguro agrícola.** 93 f. Dissertação (Mestrado) – Universidade Federal de Lavras, 2011. Disponível em: <http://repositorio.ufla.br/jspui/handle/1/1605>. Acesso em: 08 abr. 2018.
- SANTOS, G.O. **Caracterização da distribuição e análise espacial da produtividade de milho do estado de Sergipe: efeitos para o seguro agrícola.** Trabalho de Conclusão de Curso (Graduação em Ciências Atuariais), Universidade Federal de Sergipe São Cristovão, 2017. Disponível em: https://ri.ufs.br/bitstream/riufs/7171/2/Giovani_Oliveira_Santos.pdf. Acesso em: 08 abr. 2018.
- SECRETARIA DA AGRICULTURA E ABASTECIMENTO – SEAB. **Condições das lavouras -principais culturas.** 2019. Disponível em: http://www.agricultura.pr.gov.br/sites/default/arquivos_restritos/files/qas/6600/plantio_coleitea_22_jan_2019.pdf. 7 dez. 2019.
- SKEES, J.R.; BARNETT, B.J. Conceptual and practical considerations for sharing catastrophic risks. **Review of Agricultural Economics**, v.21, n.2, p.424-441, 1999.
- TOBLER, W. R. A computer movie simulating urban growth in the Detroit region. **Economic Geography**, v. 26, p. 234–240, 1970.
- WALTER, L. WANG, H. H.; ZHANG, H. On the possibility of private crop insurance market: a spatial statistics approach. 2003. **The Journal of Risk and Insurance**, vol. 70, no. 1, 2003, pp. 111–124. 2003.

4. PROPOSTA DO MODELO STARMA PARA CONTROLAR O EFEITO ESPAÇO-TEMPORAL EM DADOS DE PRODUTIVIDADE DE SOJA

Resumo

O seguro agrícola é precificado no pressuposto de independência entre os eventos, contudo, um determinado evento climático pode causar perdas em toda uma extensa área com muitos produtores, de modo que essa suposição de independência é violada e provoca problemas de correlação espacial nos dados de produtividade média dos municípios. O objetivo desta pesquisa é ajustar modelos STARMA a dados de produtividade média de soja, captando a correlação espacial dos dados para serem utilizadas na precificação do seguro agrícola. Os dados da produtividade média de soja foram retirados do Sistema IBGE de Recuperação Automática – SIDRA, compreendendo os anos de 1993 a 2019. Foram propostas três bases de dados distintas, a primeira considera 721 municípios do Brasil que mais produzem soja, o segundo possui 242 municípios do Paraná e o terceiro 9 municípios que mais produzem soja no Paraná. Os resultados indicam que os modelos ajustados para o Brasil e para os municípios do Paraná não conseguiram captar os efeitos espaço-temporais, enquanto o modelo para os 9 municípios do Paraná atendeu o diagnóstico dos resíduos e pode ser utilizado para a correta precificação do risco do seguro agrícola.

Palavras-chave: Correlação espacial. STARMA. Modelo espaço-temporal. Soja.

Abstract

Agricultural insurance is priced on the assumption of independence between events, however, a particular weather event can cause losses across an extensive area with many producers, so that this assumption of independence is violated and causes spatial correlation problems in the average productivity data of the municipalities. The aim of this research is to adjust STARMA models to average soybean yield data, capturing the spatial correlation of the data to be used in the pricing of agricultural insurance. The data of the average soybean yield were taken from the IBGE System of Automatic Recovery - SIDRA, comprising the years 1993 to 2019. Three distinct databases were proposed, the first considers 721 municipalities in Brazil that produce soybeans the most, the second has 242 municipalities in Paraná and the third 9 municipalities that produce soybeans the most in Paraná. The results indicate that the models adjusted for Brazil and for the municipalities of Paraná could not capture the space-time effects, while the model for the 9 municipalities of Paraná met the diagnosis of waste and can be used for the correct pricing of agricultural insurance risk.

Keywords: Spatial correlation, STARMA, Space-time model, Soy.

4.1. Introdução

As atividades agrícolas são muito sensíveis a situações que fogem do controle dos produtores, como, por exemplo, os eventos climáticos que são os principais responsáveis pela queda da produtividade agrícola. Nesse contexto, os produtores elaboraram mecanismos de defesa e atenuação dos riscos.

Dentre estes mecanismos, destaca-se a utilização do seguro agrícola que permite ao produtor se proteger contra perdas, garantindo sua renda caso ocorra algum fenômeno inesperado, especialmente eventos climáticos. Desse modo, o seguro agrícola pode ser entendido como uma das formas mais eficientes de transferir as consequências dos riscos do produtor para outros agentes econômicos (OZAKI, 2005), nesse caso, as seguradoras e resseguradoras.

Para a precificação, as seguradoras se baseiam no pressuposto de independência entre os eventos, contudo, um determinado evento climático ou a ocorrência de doenças e pragas podem causar perdas apenas a um produtor, mas em uma extensa área e a muitos produtores, de modo que a suposição de independência é violada e pela existência de correlação espacial nos dados de produtividade média dos municípios (OZAKI, 2005).

A correlação temporal é uma das singularidades listada por Ozaki (2007) e deve ser considerada na aplicação do método de precificação do seguro agrícola, no intuito de não incorrer em resultados errôneos. Porém, diversos estudos apenas se preocupam em eliminar algumas das singularidades, tais como correlação serial, presença de tendência e heteroscedasticidade. Nesse sentido, alguns estudos utilizam técnicas para captar estas singularidades, tais como os modelos de regressão, passeio aleatório e autorregressivos (AR) (SANTOS, 2011; DUARTE *et al*, 2018).

No entanto, o emprego dessas técnicas não capta os efeitos espaciais, o que pode causar na modelagem das probabilidades resultados não fidedignos. Portanto, é indispensável o emprego de métodos que considerem essas particularidades, uma vez que o uso de técnicas inadequadas e a ausência de informações dificultam uma precificação adequada do risco pelas seguradoras.

Dessa forma, para solucionar o problema de correlação espacial, pode-se utilizar o modelo Autorregressivo e Média Móvel Espaço-Temporal (STARMA). Além de considerar as influências temporais, esse modelo também considera os efeitos espaciais. Salienta-se que o modelo STARMA se trata de uma extensão do modelo Autorregressivo e Média Móvel Vetorial (VARMA), porém considera um termo que captura os efeitos espaciais (JIN, 2017).

A aplicabilidade dos modelos da classe STARMA são encontrados na literatura em muitas áreas, sempre com o propósito de ajustar dados temporais correlacionados espacialmente. Estudos epidemiológicos ajustam modelos STARMA para estimar a propagação temporal e espacial de certa enfermidade, como a febre hemorrágica com síndrome renal, taxa de tuberculose e recentemente da COVID-19, enquanto outros estudos se concentram em ajustar os modelos a dados de tráfegos de veículos, transporte e demanda de

táxis (GARRIDO, 2000; KAMARIANAKIS; PRASTACOS, 2003; CHEN; ZHANG, 2018; ZHAO *et al*, 2018; FREITAS, 2019; SAFIKHANI *et al*, 2020; AWWAD *et al*, 2021).

Na área meteorológica os modelos STARMA desempenham um papel muito importante para estimar dados de poluição, temperatura e precipitação, em que essas últimas são primordiais para analisar os riscos da produtividade agrícola (DALEZIOS; ADAMOWSKI, 1995; MARTINS, 2013; BIZ, 2014; RATHOD *et al*, 2018; SJAHD *et al*, 2020). Contudo, não foram encontrados até o momento na literatura estudos que utilizem os modelos STARMA para estimar a produtividade agrícola para fins de precificação do risco agrícola.

Diante do exposto, esta pesquisa visa preencher esta lacuna na literatura com o objetivo de ajustar modelos STARMA a dados de produtividade média de soja, eliminando a correlação espacial dos dados para serem utilizadas na precificação do seguro agrícola. Para testar o ajuste em função da quantidade de municípios inseridos no modelo, foram elaborados três conjunto de dados. No primeiro, pretende-se ajustar os modelos para os municípios que mais produzem soja no Brasil; em seguida, para todos os municípios do Paraná que possuem dados e, por último, para os maiores produtores do Paraná.

Para esses modelos será utilizado o coeficiente de variação como medida de risco para inferir o grau de proximidade dos municípios na construção dos pesos espaciais ($W_{i,j}$). Dessa maneira, não é necessário que os municípios compartilhem a mesma região geográfica (ALMEIDA, 2012; FREITAS, 2019).

Este artigo está dividido da seguinte forma: o segundo tópico mostra a metodologia, contendo informações sobre a base de dados e a descrição dos modelos STARMA. O terceiro tópico apresenta os resultados e a discussão dos ajustes dos modelos STARMA a dados de produtividade média de soja, finalizando no quarto tópico com as considerações finais.

4.2. Metodologia

4.2.1 Matriz de ponderação espacial

Os modelos espaço-temporais são caracterizados por possuírem elementos que captam os efeitos temporais e espaciais. Esses efeitos são representados pela correlação entre os elementos do conjunto de dados, onde a correlação entre as observações no tempo é chamada de correlação temporal, e quando ocorre com as observações, considerando sua localização, é denominado de correlação espacial. Esta última é o diferencial desses modelos, devido

considerar o grau de associação espacial, conforme as interações entre as observações e seus vizinhos (JIN, 2017; PFEIFER; DEUTSCH, 1980; FREITAS, 2019).

A classe de modelos autorregressivos de médias móveis espaço-temporais (STARMA) considera a matriz de ponderação espacial para detectar da correlação espacial entre as observações, apresentando a variabilidade espacial dos dados. Essa matriz é denotada por \mathbf{W} , onde é constituída de uma matriz quadrada com dimensão $N \times N$ e $N^2 - N$ elementos de covariância, no qual N representa a quantidade de observações no espaço, em que seu objetivo é descrever o grau de associação entre as sub-regiões de interesse, conforme um critério definido para sua obtenção (MONTEIRO *et al.*, 2004; ALMEIDA, 2012).

A matriz \mathbf{W} é composta por N diferentes locais com ordem l , onde cada peso espacial $w_{i,j}$ é o grau de proximidade entre a região i e a região j para todo $i \neq j$. No final da obtenção da matriz é realizada a normalização para que todas as linhas sejam iguais a 1. A Figura 1 apresenta o esquema de proximidade dos pesos espaciais em função da ordem l adotada em sua construção, um vez que quanto maior a ordem menor será a proximidade entre as localidades (FREITAS, 2019).

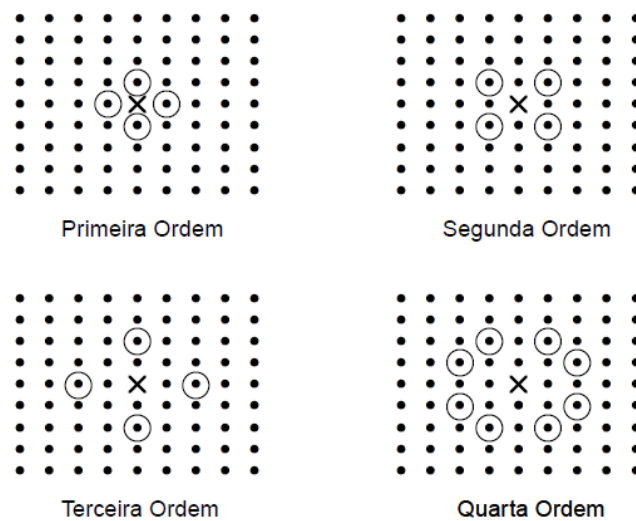


Figura 1. Matriz de ponderação espacial com vizinhança da primeira à quarta ordem.
Fonte: (PFEIFER; DEUTSCH, 1980; BIZ, 2014).

É importante realçar que a construção de uma matriz de vizinhança não é simples e nem singular. A determinação dos pesos $w_{ij}^{(l)}$ fica a critério do pesquisador, devendo selecionar os pesos que representem a distribuição espacial do sistema em estudo (MARTINS; BIZ; OZAKI, 2014).

4.2.2 Critérios geográficos

A elaboração de matrizes de vizinhanças, pautadas em critérios geográficos, consideram as distâncias, dada uma métrica, ou as fronteiras das regiões em estudo. Em relação às matrizes de vizinhança que consideram as fronteiras, antes de sua normalização elas podem ser binárias ou não. Nesse tipo de matriz, supõem-se que as regiões possuem maior nível de proximidade, quanto maior for a extensão de fronteira que compartilham (ALMEIDA, 2012). Ademais, a ponderação de pesos espaciais pode ser realizada de duas maneiras: i) atribui-se pesos espaciais somente analisando se há ou não o compartilhamento de fronteiras em comum por duas áreas; e ii) atribui-se os pesos considerando a extensão da fronteira compartilhada entre as áreas.

A Matriz de Contiguidade é uma das matrizes que consideram as fronteiras mais utilizadas, destacando-se por sua simplicidade. Salienta-se que atribuir pesos espaciais levando em consideração fronteiras possui algumas dificuldades, dentre elas, pode-se destacar a complexidade de medir o comprimento das fronteiras e dos perímetros de cada área. Além disso, em situações em que as áreas possuem tamanhos muito diversificados, a matriz W obtida será desbalanceada, de maneira que as áreas com fronteiras maiores tenderão a apresentar maior número de vizinhos (ALMEIDA, 2012).

No que diz respeito às matrizes de vizinhança baseadas em distâncias, pressupõem-se que duas regiões terão maior interação espacial se forem geograficamente próximas. Para construção da matriz W , foram propostas diversas formas, dentre elas: a) matriz exponencial de distância; b) matriz da distância inversa; e c) matriz de k -vizinhos e sua modificação proposta por Tyszler (2006). Cabe destacar que dentre essas matrizes de vizinhança, talvez a mais adequada seja a matriz exponencial de distância (ALMEIDA, 2012).

Contudo, a atribuição de pesos espaciais para essa matriz depende de um parâmetro de amortecimento, muitas vezes estabelecido por suposição, de forma arbitrária e independentemente do restante das análises. Outra desvantagem é a definir a métrica a ser utilizada, a mais usual é a distância Euclidiana, no entanto, utilizar a Distância do Grande Círculo é o mais adequado para as situações em que as regiões de interesse são geograficamente distantes (ALMEIDA, 2012).

4.2.3 Critérios socioeconômicos

Muitas vezes, mensurar o grau de similaridade entre duas áreas pode ser mais apropriado por meio de variáveis socioeconômicas. Por exemplo, pode-se mensurar o grau de proximidade de duas cidades por meio do índice de desenvolvimento humano, grau de escolaridade, nível de segurança etc. Sendo assim, recomenda-se a utilização de critérios socioeconômicos para a elaboração das matrizes de vizinhança, sendo que, supõem-se que áreas com características similares têm maior proximidade, embora sejam geograficamente distantes, de modo que as interações espaciais podem ser mais bem caracterizadas por critérios socioeconômicos do que geográficos (ALMEIDA, 2012).

Vale destacar que não há na literatura muitas orientações para a construção de matrizes de ponderação espacial socioeconômicas. No entanto, Almeida (2012) elucida que uma das maneiras de se construir uma matriz de pesos espaciais socioeconômica é considerando a similaridade entre as regiões de interesse. A ideia da similaridade é que, quem é mais similar influencia mais do que os mais diferentes. Assim, as distâncias nesse tipo de matriz são dadas por valores, denotando a diferença de similaridade.

Dessa maneira, a ideia de se basear em critérios socioeconômicos para elaborar matrizes de pesos espaciais pode se utilizar da noção de distância inversa. Entretanto, na construção da matriz W , os pesos espaciais $w_{ij}(d_{SE})$, são definidos de acordo com a interação baseada na distância socioeconômica (d_{SE}). Formalmente, tem-se:

$$w_{ij}(d_{SE}) = \frac{1}{|x_i - x_j|^b} \quad (4.1)$$

Em que x é o coeficiente de variação da produtividade de soja dos municípios i e j da região em análise e b é um número positivo par. Utiliza-se o módulo da diferença para garantir que os pesos não sejam negativos.

4.2.4 Modelos STARMA

O modelo STARMA é empregado para retratar dados de séries temporais espacialmente localizados. Conforme Pfeifer e Deutsch (1980a) para se ajustar um modelo da classe STARMA os processos devem ser descritos por observações de única variável aleatória que estão disponíveis em N locais fixos no espaço, sendo que as dependências entre os N locais estão sistematicamente relacionadas.

Destaca-se que, para a utilização deste modelo, supõem-se que a dependência entre as observações de cada região e das regiões vizinhas seja a mesma para todos os locais. Ademais, o modelo é caracterizado pela dependência linear defasada no tempo e no espaço (PFEIFER; DEUTRCH, 1980a; BIZ, 2014).

Para construir um modelo STARMA, define-se um operador de defasagem $L^{(l)}$, ou seja, designa-se uma região vizinha, considerando o peso espacial. Sendo assim, o operador de defasagem espacial de l -ésima é definido como:

$$\begin{aligned} L^{(0)}z_i(t) &= z_i(t), \\ L^{(l)}z_i(t) &= \sum_{j=1}^N w_{ij}^{(l)} z_j(t). \end{aligned} \quad (4.2)$$

Em que: $z_i(t)$ são as observações da variável aleatória $Z_i(t)$ e $w_{ij}^{(l)}$ são os pesos com $\sum_{j=1}^N w_{ij}^{(l)} = 1$, para todo i , e $w_{ij}^{(l)}$ é diferente de zero se os locais i e j forem vizinhos da l -ésima ordem. Sendo $\mathbf{W}^{(l)}$ a matriz que representa os pesos $w_{ij}^{(l)}$, $\mathbf{z}(t)$ um vetor coluna $N \times 1$ de observações $z_i(t)$, $i = 1, 2, \dots, N$ e \mathbf{I}_N uma matriz identidade de dimensão $N \times N$, então:

$$\begin{aligned} L^{(0)}\mathbf{z}(t) &= \mathbf{W}^0\mathbf{z}(t) = \mathbf{I}_N\mathbf{z}(t), \\ L^{(l)}\mathbf{z}(t) &= \mathbf{W}^l\mathbf{z}(t), \text{ para } l > 0. \end{aligned} \quad (4.3)$$

O modelo STARMA é definido como:

$$z_i(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} L^{(l)} z_i(t-k) - \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} L^{(l)} \epsilon_i(t-k) + \epsilon(t) \quad (4.4)$$

Onde: p é a ordem autorregressiva; q a ordem de médias móveis; λ_k a ordem espacial do k -ésimo termo autorregressivo; m_k a ordem espacial do k -ésimo termo de médias móveis; $L^{(l)}$ o operador de defasagem espacial, ϕ_{kl} e θ_{kl} são os parâmetros e $\epsilon_i(t)$ os erros aleatórios que seguem uma distribuição normal com:

$$\begin{aligned} E[\epsilon_i(t)] &= 0 \\ E[e_i(t)e_j(t+s)'] &= \begin{cases} \sigma^2, & i = j, s = 0 \\ 0, & \text{caso contrário} \end{cases} \end{aligned} \quad (4.5)$$

O modelo STARMA pode ser reescrito na forma matricial:

$$\mathbf{z}(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \mathbf{z}(t-k) - \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} \mathbf{W}^{(l)} \boldsymbol{\epsilon}(t-k) + \boldsymbol{\epsilon}(t) \quad (4.6)$$

De modo semelhante aos modelos da classe ARMA, o modelo STARMA se trata da união de dois modelos, um com a parte autorregressiva, denominado modelo espaço-temporal autorregressivo (STAR), onde, $q = 0$ e o modelo é dado por:

$$\mathbf{z}(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \mathbf{z}(t-k) + \boldsymbol{\epsilon}(t) \quad (4.7)$$

E o modelo que se refere somente à parte de médias móveis é denominado modelo espaço-temporal de médias móveis (STMA), em que $p = 0$ e o modelo é descrito por:

$$\mathbf{z}(t) = \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} \mathbf{W}^{(l)} \boldsymbol{\epsilon}(t-k) + \boldsymbol{\epsilon}(t) \quad (4.8)$$

Vale ressaltar que os modelos STARMA supõem processos estacionários, isto é, a média e estrutura de covariância de $\mathbf{z}(t)$ não se alteram com o tempo. Se esta condição não for satisfeita, pode-se utilizar o modelo espaço-temporal autorregressivo de médias móveis, STARIMA (PFEIFER; DEUTSCH, 1980c). Tal modelo se trata de um STARMA no qual foram adicionadas d diferenças, sendo definido por:

$$\nabla^d \mathbf{z}(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \nabla^d \mathbf{z}(t-k) - \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} \mathbf{W}^{(l)} \boldsymbol{\epsilon}(t-k) + \boldsymbol{\epsilon}(t) \quad (4.9)$$

De forma semelhante aos modelos de Box e Jenkins, pode-se obter os da classe STARMA, isto é, por meio do procedimento iterativo de três estágios, sendo eles: *i*) Identificação do modelo; *ii*) estimação dos parâmetros e; *iii*) diagnóstico do modelo (CHEYSSON, 2016).

i) Identificação do modelo: os modelos STARMA podem ser identificados com base na análise das funções de autocorrelação espaço-temporal (FAC espaço-temporal) e função de autocorrelação parcial espaço-temporal (FACP espaço-temporal). Segundo Jin (2017), nos processos STAR a FAC espaço-temporal decai gradativamente tanto para o espaço quanto para o tempo e a FACP espaço-temporal é igual a zero após o *lag* p no tempo e *lag* λ_p no espaço.

No modelo STMA, a FAC espaço-temporal é igual a zero após o q -ésimo *lag* temporal e o m_q -ésimo *lag* espacial e a FACP espaço-temporal diminui gradativamente tanto para o tempo quanto o espaço. Para os modelos STARMA, verifica-se o decaimento gradativo tanto da FAC quanto da FACP espaço-temporal. A Tabela 1 apresenta um resumo do comportamento das FAC e FACP espaço-temporal do modelo STARMA.

Tabela 17. Comportamento das FAC e FACP espaço-temporal dos modelos STAR, STMA e STARMA.

Modelo	FAC espaço-temporal	FACP espaço-temporal
STAR	decai gradativamente	decaimento gradativo após a p -ésima lag temporal e λ_p -ésima lag espacial.
STMA	decaimento gradativo após a q -ésima lag temporal e m_q -ésima lag espacial.	decai gradativamente
STARMA	decai gradativamente	decai gradativamente

Fonte: (PFEIFER; DEUTSCH, 1980b; MARTINS, 2013).

Salienta-se que para selecionar o modelo, considera-se o princípio da parcimônia, ou seja, seleciona-se o modelo com menor número de parâmetros para estimação, utilizando o critério de informação bayesiano (BIC):

$$BIC = NT \ln(\hat{\sigma}^2) + 2b \ln(T) \quad (4.10)$$

Onde: N é o número de regiões; T é o tamanho das séries; $\hat{\sigma}^2$ é a variância residual estimada e b é o número de parâmetros.

ii) *Estimação dos parâmetros:* Após a seleção do modelo, procede-se para estimação dos parâmetros. Segundo Pfeifer e Deutsch (1980b) as estimativas obtidas pelo método da máxima verossimilhança garantem boas propriedades para ϕ e θ . Contudo, obter tais estimativas por esse método é muito difícil, de modo que o modelo STARMA caiu em desuso na década de 80. Sendo que passou a ser utilizado novamente em anos recentes, em virtude de surgirem implementações computacionais do modelo, como por exemplo, a estimação dos parâmetros por meio do pacote Starma do *software R*, desenvolvido por Cheysson (2016), no qual utiliza o Filtro de Kalman para estimar os parâmetros.

Segundo o autor, estimar os parâmetros por meio do Filtro de Kalman, além de proporcionar considerável redução do custo computacional, é eficiente quando aplicado a conjuntos de dados muito grandes. Ademais, conforme Jin (2017), embora seja o mais comum, a suposição de normalidade residual não é necessária.

iii) *Diagnóstico do modelo:* para verificar se o modelo estimado é adequado, ou seja, se o modelo não apresenta correlação residual, deve-se realizar uma análise residual e observar se os resíduos são ruídos brancos, isto é, são independentes com distribuição normal multivariada com média zero e matriz de covariância σI_{NT} . Sendo assim, para testar se os resíduos são independentes, utiliza-se a função '*stcot.test()*' do pacote '*starma*'. Esta função se trata de uma extensão do teste de Box-Pierce, onde é testada a hipótese de não correlação residual (CHEYSSON, 2016). O teste é descrito por:

$$N \sum (T - s) [\hat{\rho}_l(s)]^2 \sim \chi^2(slag; tlag) \quad (4.11)$$

Em que: N é o número de regiões consideradas; T o número de observações ao longo do tempo das N regiões; s a defasagem temporal; $[\hat{\rho}_l(s)]^2$ a função de autocorrelação espaço-temporal para l -ésima ordem de vizinhança e s -ésima defasagem temporal; $slag$ maior ordem de vizinhança; $tlag$ número de defasagem temporal usada para construir o gráfico da função de autocorrelação espaço-temporal (CHEYSSON, 2016).

4.2.5 Base de dados

Os dados da produtividade média de soja foram retirados do Sistema IBGE de Recuperação Automática – SIDRA, compreendendo os anos de 1993 a 2019. Não foram considerados municípios com ausência de dados no período escolhido para o estudo. Foram retiradas as tendências das séries de dados de produtividade média de cada município, conforme realizado no Artigo 1 desta tese e apresentado na rotina do *software R* em anexo.

Para o ajuste do modelo STARMA para os municípios do Brasil, foi realizado um recorte no primeiro quartil da produtividade média de soja para excluir 25% dos municípios que menos produzem, isto é, os municípios selecionados representam os 75% maiores produtores, o que totalizou 721 municípios distribuídos nos estados PR, MG, MA, GO, SP, MS, MT, BA, SC, RS, TO, PI, RO e no DF.

No caso do Paraná o primeiro ajuste considera todos os municípios com dados no período de 1993 a 2019, totalizando 242 municípios. O segundo ajuste considera os municípios com histórico de maior produção e produtividade média de soja no estado, sendo selecionados 9 municípios: Ponta Grossa, Cascavel, Castro, Guarapuava, Pato Branco, Campo Mourão, Toledo, Francisco Beltrão, Tibagi.

4.3. Resultados e discussões

O ajuste dos modelos STARMA foi realizado primeiro para os dados de produtividade média de soja dos municípios do Brasil. Para verificar a existência de correlação espaço-temporal foi aplicado uma extensão do teste Box-Pierce, por meio do pacote *starma* do *software R* (CHEYSSON, 2016). O resultado do teste indicou que a hipótese de não correlação espaço-temporal deve ser rejeitada, ou seja, os dados apresentam correlação espaço-temporal.

Para identificar a ordem espacial e temporal do modelo, utilizou-se dos gráficos da função de autocorrelação espaço-temporal (FAC espaço-temporal) e da função de

autocorrelação parcial espaço-temporal (FACP espaço-temporal), respectivamente. A Figura 2 apresenta os gráficos da FAC espaço-temporal e, ao considerar o *slag* 1, constata-se a existência de correlação espaço-temporal encontrada anteriormente pelo teste Box-Pierce. No entanto, verifica-se na FAC espaço-temporal com *slag* 0 a persistência da correlação temporal significativa em quase todos *lag*, portanto, optou-se por aplicar uma diferença na série de dados para contornar esse problema.




Figura 20. Gráfico da função de autocorrelação espaço-temporal.
Fonte: Elaboração própria.

Considerando a primeira diferença na série de dados, a extensão do teste Box-Pierce manteve o resultado significativo para existência da correlação espaço-temporal. A Figura 22 mostra os gráficos da FAC espaço temporal e da FACP espaço-temporal, onde é possível verificar que a diferença aplicada reduziu a correlação temporal dos dados e de acordo com os resultados do STACF (*lag* 1), verificou-se a existência da correlação espaço-temporal.




Figura 21. Gráfico da função de autocorrelação espaço-temporal (a) e função de autocorrelação parcial espaço-temporal (b) para primeira diferença na série de dados para os 721 municípios do Brasil.

Fonte: Elaboração própria.

A ordem do modelo STARMA mediante os gráficos da FAC espaço-temporal e da FACP espaço-temporal pode ser escolhida pela significância dos *lags* presentes em ambos, considerando tanto o *slag 0* quanto o *slag 1*. Como os gráficos não foram muito sugestivos para a escolha da ordem do modelo, foram testados diversos modelos, considerando a significância dos *lags*, sendo escolhido o modelo que apresentou menor valor para o critério de informação bayesiano (BIC) conjuntamente com o mais parcimonioso.

Nesse caso, o modelo que obteve menor valor para o critério foi a ordem STARIMA (3₁, 1, 3), no qual obteve valor do BIC igual a 53.361,99. A Tabela 2 mostra os resultados do ajuste do modelo, constatou-se que todos os parâmetros estimados foram significativos a 1% de significância.

Tabela 18. Resultado do modelo STARIMA (3₁, 1, 3)

Parâmetro	Estimativa	Erro-padrão	Estatística t	Valor-p
$\phi_{2,0}$	0.13	0.01	13.49	$< 2.2 \times 10^{-16}$
$\phi_{2,1}$	-0.37	0.04	-8.23	$< 2.2 \times 10^{-16}$
$\phi_{3,0}$	0.38	0.02	18.40	$< 2.2 \times 10^{-16}$
$\phi_{3,1}$	-0.17	0.02	-9.04	$< 2.2 \times 10^{-16}$
$\theta_{1,0}$	0.20	0.01	23.23	$< 2.2 \times 10^{-16}$
$\theta_{2,1}$	0.22	0.05	4.52	$< 6.3 \times 10^{-6}$
$\theta_{3,0}$	-0.18	0.02	-8.68	$< 2.2 \times 10^{-16}$

Fonte: Elaboração própria.

O diagnóstico dos resíduos do modelo ajustado foi realizado ao analisar a FAC espaço-temporal dos resíduos, uma vez que se espera o comportamento semelhante ao do ruído branco, ou seja, resíduos independentes seguindo a distribuição normal com média zero e variância constante. A confirmação da análise é feita com o apoio da extensão do teste Box-Pierce para verificar se o modelo captou todos os efeitos espaço-temporais.

O histograma e normalidade dos resíduos podem ser investigados visualmente pela Figura 23. A hipótese da normalidade dos resíduos foi verificada por meio do teste de Kolmogorov-Smirnov, no qual não existem evidências para se não rejeitar a normalidade dos resíduos.




Figura 22. Gráfico do histograma e normalidade dos resíduos.
Fonte: Elaboração própria.

A Figura 24 apresenta a FAC espaço-temporal dos resíduos do modelo ajustado, onde é possível verificar que o modelo não captou todos os efeitos temporais (*slag 0*) e espaço-temporais (*slag 1*), devido a picos significativos da correlação de acordo com o aumento dos *lags*. Este tipo de resultado ocorreu no trabalho de Freitas (2019) que estimou a taxa de incidência de tuberculose e concluiu que isso significa que a série espaço-temporal apresenta memória longa.

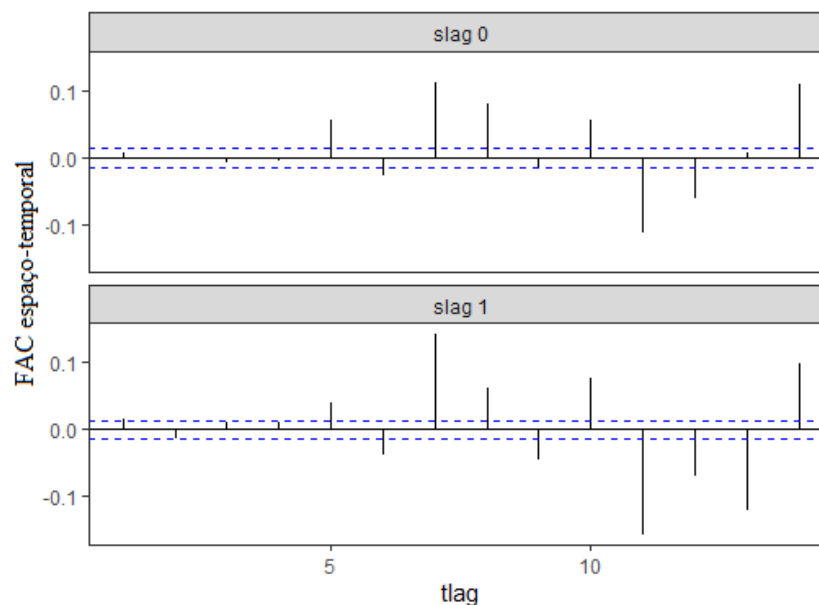


Figura 23. Gráfico da função de autocorrelação espaço-temporal para os resíduos do modelo ajustado.
Fonte: Elaboração própria.

A extensão do teste de Box-Pierce confirmou ao rejeitar a hipótese nula de não correlação espaço-temporal. O resultado do teste indicou que a hipótese de não correlação espaço-temporal deve ser rejeitada. O modelo ajustado apesar de fornecer resíduos normalmente distribuídos, não captou de forma satisfatória os efeitos temporais e espaço-temporais para os 721 municípios distribuídos pelos estados no Brasil. Portanto, o segundo modelo utilizando os 242 municípios do Paraná foi a segunda tentativa de ser ajustar o modelo STARMA para série de dados de produtividade média de soja.

A extensão do teste de Box-Pierce indicou que a produtividade média de soja dos municípios possui correlação espaço-temporal. Ademais, de acordo com a FAC espaço-temporal da Figura 25 a correlação temporal é significativa em todos os *lags*, o que pode indicar que a série não é estacionária, portanto, foi aplicada uma diferença na série de dados da produtividade média dos municípios para eliminar essa não estacionaridade.




Figura 24. Gráfico da função de autocorrelação espaço-temporal.
Fonte: Elaboração própria.

Para a série com uma diferença, a extensão do teste Box-Pierce também não rejeitou a hipótese nula de não correlação espaço-temporal. A Figura 26 apresenta a FAC espaço-temporal e FACP espaço-temporal, novamente, pelo fato da presença de correlações significativas em *lags* distantes, a detecção da ordem do modelo fica difícil de ser realizada. Em função disso foram gerados vários modelos, inserindo ordens com as *lags* significativas apresentadas pelas FAC e FACP espaço-temporais. O modelo escolhido com base no menor valor para o BIC obtido dentre os diversos modelos foi o STARIMA (19₁, 1, 14₁), com BIC igual a 14.779,28.




Figura 25. Gráfico da função de autocorrelação espaço-temporal (a) e função de autocorrelação parcial espaço-temporal (b) para primeira diferença na série de dados para os 242 municípios do Paraná.

Fonte: Elaboração própria.

A Tabela 19 mostra os resultados dos parâmetros estimados para o ajuste do modelo STARIMA $(19_1, 1, 14_1)$ para a série de dados da produtividade média de soja dos 242 municípios do Paraná, no período de 1993 a 2019. Nesse modelo foi necessário inserir altas defasagens para obter o menor valor do critério de informação bayesiano, devido aos altos *lags* significativos nas FAC e FACP espaço-temporal. No entanto, não foram necessários muitos parâmetros estimados sendo o mais parcimonioso com todos os coeficientes significativos a 1% de significância.

Tabela 19. Resultado do modelo STARIMA $(19_1, 1, 14_1)$

Parâmetro	Estimativa	Erro-padrão	Estatística t	Valor-p
$\phi_{19,1}$	0.37	0.06	5.66	$< 1.56 \times 10^{-8}$
$\theta_{1,0}$	-0.75	0.03	-26.95	$< 2.2 \times 10^{-16}$
$\theta_{13,0}$	-0.24	0.03	-8.64	$< 2.2 \times 10^{-16}$
$\theta_{14,1}$	0.78	0.04	20.24	$< 2.2 \times 10^{-16}$

Fonte: Elaboração própria.

Uma vez ajustado o modelo é necessário realizar o diagnóstico dos resíduos utilizando a FAC e FACP espaço-temporal dos resíduos, assim como aplicar a extensão do teste de Box-Pierce e testar a normalidade dos resíduos. O teste de Kolmogorov-Smirnov gerou um p-valor de 0,88, indicando que os resíduos seguem uma distribuição normal, do mesmo modo que pode ser visto pela Figura 27, que apresenta o histograma e a densidade da normal para os resíduos.

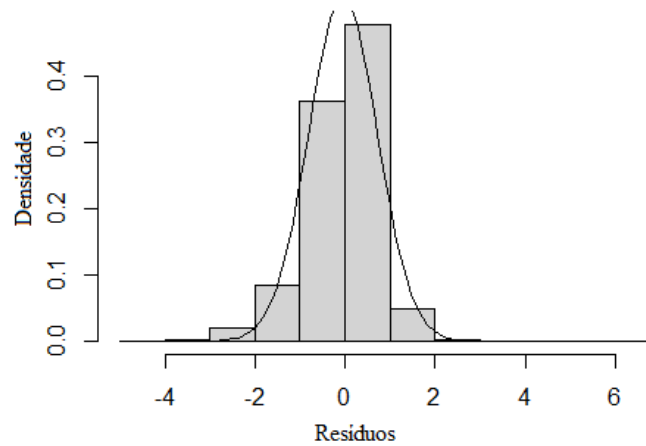


Figura 26. Gráfico do histograma e normalidade dos resíduos.
Fonte: Elaboração própria.

Em relação à FAC e FACP espaço-temporal para os resíduos, de forma similar, o que ocorreu para o ajuste do modelo para os municípios do Brasil, o ajuste para os 242 municípios do Paraná também não consegue capturar os efeitos espaço-temporais, como pode ser visto na Figura 28, que expõe diversas correlações significativas ao longo dos *lags*, fornecendo o mesmo indicativo de um processo de memória longa.




Figura 27. Gráfico da função de autocorrelação espaço-temporal para os resíduos do modelo ajustado.
Fonte: Elaboração própria.

O terceiro e último modelo foi o ajuste do STARMA para série de dados dos 9 municípios que mais produzem soja no Paraná. A extensão do teste de Box-Pierce detectou a correlação espaço-temporal presente na série. De acordo com a FAC espaço-temporal da

Figura 29, torna-se necessária a aplicação de uma diferença nos dados em função das correlações significativa ao longo das *slag* 0.

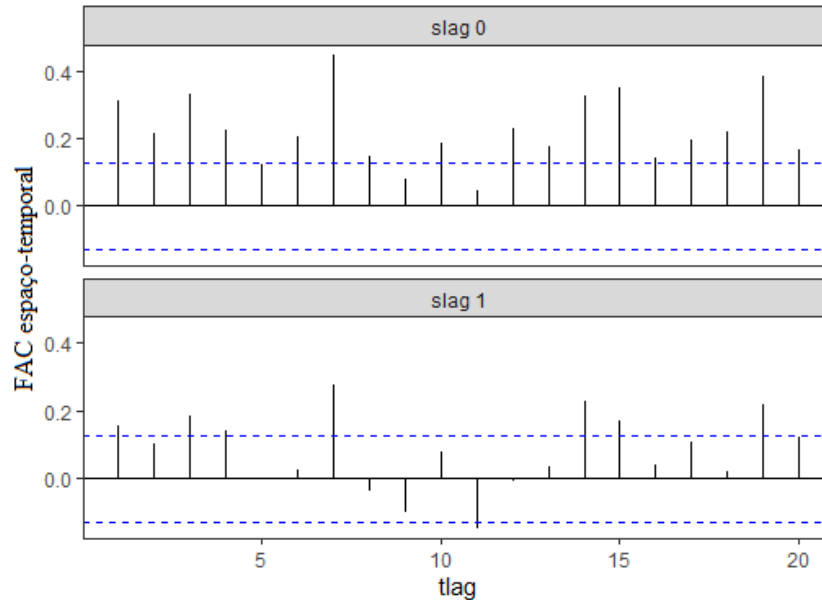


Figura 28. Gráfico da função de autocorrelação espaço-temporal.
Fonte: Elaboração própria.

A série diferenciada também indica presença de correlação espaço-temporal indicada pela extensão do teste Box-Pierce, e a Figura 30 mostra a FAC e FACP espaço temporal para o auxílio da ordem do modelo STARIMA. Assim Como realizado no ajuste dos modelos anteriores, a FAC e FACP espaço-temporal indicam a presença de muitos *lags* com correlações significativas e a escolha da ordem considerou diversas combinações de modelos, embasado nos *lags* significativos em *slag* 0 e *slag* 1.




Figura 29. Gráfico da função de autocorrelação espaço-temporal (a) e função de autocorrelação parcial espaço-temporal (b) para primeira diferença na série de dados para os 9 municípios do Paraná.

Fonte: Elaboração própria.

O modelo escolhido com menor valor para o critério de informação bayesiano (630,1) foi de ordem STARIMA (14₁, 1, 10₁), no qual as estimativas dos parâmetros são apresentadas na Tabela 20. Nesse modelo, todos os coeficientes foram significativos a 5%, e houve a necessidade de não considerar o modelo mais parcimonioso, apenas o que obtivesse o menor valor BIC, por causa do diagnóstico dos resíduos.

Tabela 20. Resultado do modelo STARIMA (14₁, 1, 10₁)

Parâmetro	Estimativa	Erro-padrão	Estatística t	Valor-p
$\phi_{3,0}$	0.26	0.10	2.57	0.01**
$\phi_{11,1}$	-0.80	0.18	-4.51	1.03x10 ⁻⁵ *
$\phi_{12,0}$	0.44	0.13	3.43	7.0x10 ⁻⁴ *
$\phi_{14,1}$	0.48	0.21	2.28	0.02**
$\theta_{1,0}$	-0.46	0.16	-2.82	5.1x10 ⁻³ *
$\theta_{7,0}$	0.33	0.13	2.44	0.01**
$\theta_{9,0}$	-0.30	0.14	-2.22	0.03**
$\theta_{10,1}$	0.75	0.17	4.36	1.96x10 ⁻⁵ *

*Significativo a 1%, **Significativo a 5%.

Fonte: Elaboração própria.

Quanto ao diagnóstico dos resíduos para o modelo ajustado, o teste de normalidade de Kolmogorov-Smirnov obteve um p-valor de 0.96, indicando a presença de normalidade nos resíduos, o que pode ser ilustrado no histograma dos resíduos da Figura 31. Ademais, a FAC espaço-temporal dos resíduos representada na Figura 32 indica poucas defasagens, a que o modelo proposto não captou os efeitos espaço-temporais, no entanto, ao aplicar a extensão do teste Box-Pierce para os resíduos, não se rejeita a hipótese nula com 5% de significância de não correlação espaço-temporal, devido ao p-valor do teste ser igual a 0,059.

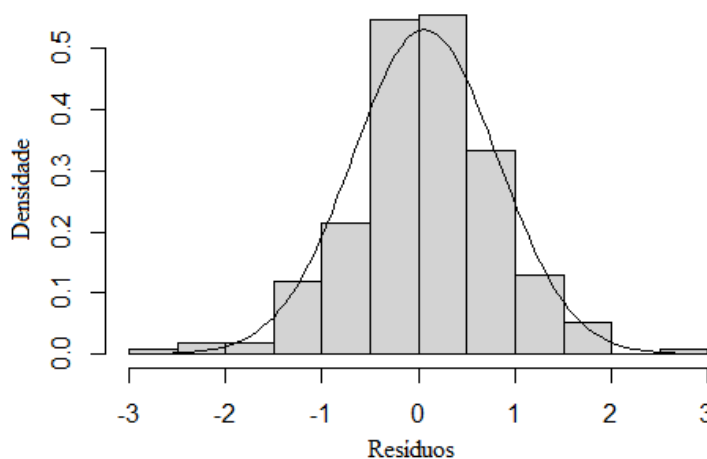


Figura 30. Gráfico do histograma e normalidade dos resíduos.

Fonte: Elaboração própria.

De acordo com o diagnóstico dos resíduos, o modelo ajustado para série da produtividade média de soja para os 9 maiores produtores de soja do Paraná pode ser utilizado para eliminar os efeitos espaço-temporais existentes. Portanto, a classe dos modelos STARMA pode ser empregado para eliminar as singularidades existentes antes do cálculo da precificação do seguro agrícola praticado pelas seguradoras.




Figura 31. Gráfico da função de autocorrelação espaço-temporal para os resíduos do modelo ajustado.
Fonte: Elaboração própria.

4.4. Conclusões

Esta pesquisa se propôs a aplicar as classes de modelos STARMA em dados de produtividade média de soja, testando três séries de dados diferentes. A primeira composta por 721 municípios que mais produzem soja no país, a segunda com 242 municípios do Paraná e, por último, os nove municípios com maior produção de soja no Paraná.

Os modelos ajustados para o Brasil e para os municípios do Paraná não conseguiram captar os efeitos espaço-temporais dos dados, em que os resíduos apresentaram correlações espaço-temporais em *lags* distantes. Isso pode ter ocorrido pelo fato da presença de um processo de memória longa, mesmo problema encontrado por Freitas (2019) ao ajustar com dados epidemiológicos e que foi solucionado por Monroy (2013), em sua tese de doutorado, ao reformular a classe de modelos STARMA para capturar esses efeitos de memória longa, o qual denominou de modelo AFIRMA espaço-temporal ou STARFIRMA.

Outro fator a se considerar é o fato dessas duas bases de dados possuírem muitos municípios, isso impacta na dimensão da matriz W que é $N \times N$ e implica em valores muito pequenos para os w_{ij} após a normalização da linha, gerando muitos efeitos espaciais com

valores próximos um do outro, o que dificulta o ajuste do modelo para captar a quantidade suficiente de efeitos espaços-temporais na extensão do teste Box-Pierce, para se aceitar a hipótese nula de não correlação espaço-temporal.

Esse pode ter sido um dos problemas que o terceiro modelo com os 9 municípios do Paraná não enfrentou, por se tratar de uma base com menos regiões do que comparado com as demais o modelo conseguiu captar os efeitos espaço-temporais da série, sendo recomendado para ser utilizado no tratamento dos dados antes de se realizar a precificação do seguro agrícola, eliminando ao mesmo tempo a correlação temporal e espacial, que é um dos problemas geralmente encontrados no momento da precificação.

Vale destacar que esta pesquisa se utiliza de matrizes de pesos espaciais construídos a partir do coeficiente de variação, o qual mede o risco da produtividade média de soja de cada município. Portanto, pelo fato de não utilizar as distâncias geográficas, os municípios não são obrigados a possuírem vizinhança geográfica. Diante do exposto, este trabalho possui como principal limitação não utilizar diferentes tipos de construção para matrizes de pesos espaciais.

Nesse sentido, é recomendável que trabalhos futuros utilizem outros tipos de matrizes espaciais, incluindo matrizes de contiguidade para analisar o ajuste de modelos STARMA limitados por municípios vizinhos. Ademais, recomenda-se também elaborar uma rotina no *software R* para ajustar o modelo STARFIRMA proposto por Monroy (2013) para captar efeitos espaço-temporais de memória longa presentes neste estudo.

Referências

- ALMEIDA, E. S. **Econometria Espacial Aplicada**. Campinas: Alínea, 2012.
- AWWAD, F.A; MOHAMOUD, M.A; ABONAZEL, M.R. Estimating COVID-19 cases in Makkah region of Saudi Arabia: Space-time ARIMA modeling. **PLOS ONE** 16(4), 2021. <https://doi.org/10.1371/journal.pone.0250149>. Acesso em 2 mai. 2021.
- BIZ, G. Simulação de pesos espaciais para o modelo STARMA e aplicações. Tese (Doutorado em Estatística e Experimentação Agronômica) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2014. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11134/tde-15092014-123217/en.php>. Acesso em 14 fev. 2021.

- CHEN, LI D.; ZHANG G.; ZHANG, X. Localized Space-Time Autoregressive Parameters Estimation for Traffic Flow Prediction in Urban Road Networks. **Applied Sciences**. 2018; 8(2):277. <https://doi.org/10.3390/app8020277>. Acesso em 2 mai, 2021.
- CHEYSSON F. (2016). starma: Modelling Space Time Auto Regressive Moving Average (STARMA). Processes. R package version 1.3. <https://CRAN.R-project.org/package=starma>.
- DUARTE, G. V.; BRAGA, A.; MIQUELLUTI, D. L.; OZAKI, V. A. Modeling of soybean yield using symmetric, asymmetric and bimodal distributions: implications for crop insurance. **Journal of Applied Statistics**. v. 45, 2018.
- FREITAS, M. F. **Matrizes socioeconômicas no ajuste de modelos STARMA aplicados a dados epidemiológicos**. Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2019. Disponível em: <http://repositorio.ufla.br/jspui/handle/1/33636>. Acesso em: 20 fev. 2021.
- GARRIDO, R. A. Spatial interaction between the truck flows through the Mexico–Texas border. **Transportation Research Part A: Policy and Practice**. Volume 34, Issue 1, January 2000, p. 23-33, 2000. [https://doi.org/10.1016/S0965-8564\(98\)00062-7](https://doi.org/10.1016/S0965-8564(98)00062-7)
- JIN, E.Y. **Estruturas de vizinhanças espaciais nos modelos autorregressivos e de médias móveis espaço-temporais STARMA**. Dissertação (Mestrado) Instituto de Matemática e Estatística – Universidade de São Paulo, 2017. Disponível em: <https://www.teses.usp.br/teses/disponiveis/45/45133/tde-24072017-194839/pt-br.php>. Acesso em 15 jan. 2020.
- KAMARIANAKIS, Y; PRASTACOS, P. Forecasting Traffic Flow Conditions in an Urban Network: Comparison of Multivariate and Univariate Approaches. **Transportation Research Record**. 1857(1), 74-84, 2003. doi:10.3141/1857-09. Acesso em 4 mai 2021.
- MARTINS, N. S. **Modelos autorregressivos e de médias móveis espaço-temporais (STARMA) aplicados a dados de temperatura**. Dissertação (Mestrado em Estatística e Experimentação Agronômica) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2013. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/11134/tde-09042013-112557/pt-br.php>. Acesso em 20 fev 2021.

- MARTINS, N. S.; BIZ, G. I. Z.; OZAKI, V.A. Modelo autorregressivo de média móvel espaço-temporal aplicado em dados de temperaturas mínimas médias mensais. *Revista Brasileira de Biometria*, v. 32, n. 1, p. 158-169, 2014. Disponível em: http://jaguar.fcav.unesp.br/RME/fasciculos/v32/v32_n1/A9_Natalia.pdf. Acesso em: 15 mai. 2021.
- MONROY, N. A. J. Modelo ARFIMA Espaço-Temporal em estudos de poluição do ar. Tese (Doutorado em Engenharia Ambiental), Universidade Federal do Espírito Santo, Vitória, 2013. Disponível em: <http://repositorio.ufes.br/handle/10/3919>. Acesso em 25 jun 2021.
- MONTEIRO, A. M. V. *et al.* **Análise espacial de dados geográficos**. Planaltina: Embrapa, 2004.
- NICOLAS R. DALEZIOS & KAZIMIERZ ADAMOWSKI. Spatio-temporal precipitation modelling in rural watersheds. **Hydrological Sciences Journal**, 40:5, 553-568, 1995. DOI: 10.1080/02626669509491444. Acesso em 3 mai 2021.
- OZAKI, V. A. **Métodos atuariais aplicados à determinação da taxa de prêmio de contratos de seguro agrícola: um estudo de caso**. Tese (Doutorado em Economia Aplicada) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2005. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11132/tde-11072005-160540/publico/VitorOzaki.pdf>. Acesso em 08 abr. 2018.
- _____. O papel do seguro na gestão do risco agrícola e os empecilhos para o seu desenvolvimento. **Revista Brasileira de Risco e Seguro** (online), v. 2, p. 75-92, 2007. Disponível em: <http://www.rbrs.com.br/arquivos/RBRS4-5%20Vitor%20Ozaki%20On%20Line.pdf>. Acesso em: 10 jan. 2020.
- OZAKI, V. A; CAMPOS, R. C. Reduzindo a Incerteza no Mercado de Seguros: Uma Abordagem via Informações de Sensoriamento Remoto e Atuária. **Revista Brasileira de Economia**, Rio de Janeiro v. 71 n. 4 / p. 489–514 Out-Dez 2017. Disponível em: <http://www.scielo.br/pdf/rbe/v71n4/0034-7140-rbe-71-04-0489.pdf>. Acesso em 15 jan. 2020.
- PFEIFER, P. E.; DEUTRCH, S. J. A three-stage iterative procedure for space-time modeling phillip. *Technometrics*, v. 22, n. 1, p. 35-47, 1980a. Disponível em: <https://www.jstor.org/stable/1268381?origin=crossref>. Acesso em: 10 mai. 2021.

- PFEIFER, P. E.; DEUTSCH, S. J. Identification and interpretation of first order space-time ARMA models. *Technometrics*, v. 22, n. 3, p. 397-408, 1980b. Disponível em: <https://www.jstor.org/stable/1268325>. Acesso em: 10 mai. 2021.
- PFEIFER, P. E.; DEUTSCH, S. J. A STARIMA model-building procedure with application to description and regional forecasting. *Transactions of the Institute of British Geographers*, p. 330-349, 1980c. Disponível em: <https://www.jstor.org/stable/621846>. Acesso em: 10 mai. 2021.
- SANTOS, C. O. **A distribuição Skew-normal como modelo para a produtividade de milho aplicada ao seguro agrícola**. Dissertação (Mestrado) - Programa de Pós-Graduação em Estatística e Experimentação Agropecuária – Universidade Federal de Lavras, 2011. Disponível em: <http://repositorio.ufla.br/jspui/handle/1/1605>. Acesso em: 08 abr. 2018.
- RATHOD, S.; GURUNG, B.; K.N. SINGH, K. N.; RAY, M. An improved Space-Time Autoregressive Moving Average (STARMA) model for Modelling and Forecasting of Spatio-Temporal time-series data. **Journal of the Indian Society of Agricultural Statistics** 72(3), p. 239–253, 2018.
- SAFIKHANI, A.; KAMGA, C.; MUDIGONDA, S.; FAGHIH, S. S.; MOGHIMI, B. Spatio-temporal modeling of yellow taxi demands in New York City using generalized STAR models. **International Journal of Forecasting**, Volume 36, Issue 3, p. 1138-1148, 2020. <https://doi.org/10.1016/j.ijforecast.2018.10.001>. Acesso em 4 mai. 2021.
- SJAHID, M., SETIAWAN, A., SUHARTONO, RUCHJANA, B. N., & PRASTYO, D. D. Prediction of $p[m.sub.10]$ pollutant in surabaya using generalized space-time autoregressive moving average. **Investigación Operacional**, 41(7). 2020.
- TYSZLER, M. Econometria espacial: discutindo medidas para a matriz de ponderação espacial. Dissertação (mestrado) - Programa de Pós-Graduação em Administração Pública e Governo - Escola de Administração de Empresas de São Paulo da Fundação Getúlio Vargas, 2006. Disponível em: <https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/2451/155051.pdf>. Acesso em: 15 mai. 2021.
- ZHAO, Y; GE, L; ZHOU, Y; SUN, Z; ZHENG, E; WANG, X.; HUANG, Y; CHENG, H.. A new Seasonal Difference Space-Time Autoregressive Integrated Moving Average (SD-STARIMA) model and spatiotemporal trend prediction analysis for Hemorrhagic Fever with Renal Syndrome (HFRS). **PLOS ONE** 13(11), 2018. <https://doi.org/10.1371/journal.pone.0207518>. Acesso em 4 mai. 2021.

ANEXO

```
#####
##### Brasil #####
#####

#Carregando dados
library(readxl)
Soja <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/SojaBrasil.
xlsx")

#Transformando em série temporal
série_temporal<-data.frame(ts(Soja, start=c(1993,1), end=c(2019,1), frequen
cy = 1 ))
ano<- 1993:2019

install.packages('zoo')
library(zoo)
tSoja <- data.frame(zoo(série_temporal, ano))

#Fazendo as regressões
resultados.lm = list()

for(i in 1:721) {
  foo.y = tSoja[,i]
  foo.name = names(tSoja)[i]
  resultados.lm[[i]] = lm(foo.y ~ ano)
}
resultados.lm

#Retirando a tendência
resultados.tend = list()

for (i in 1:721){
  foo.name = names(tSoja)[i]
  res= resultados.lm[[i]]$residuals
  ypred=resultados.lm[[i]]$fitted.values
  ynew= ypred[27]*(1+res/ypred)
  resultados.tend[[i]] = ynew
}
P = data.frame(resultados.tend)

write.table(P, file='SojaBrasilST.csv', sep=';', dec='.', row.names=FALSE)

#Matriz w para Soja
library(readxl)

SojaBrasilRisco <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/
Risco_SojaBrasil.xlsx")
Risco = SojaBrasilRisco$Risco
l=length(Risco)

Sojalist = matrix(list(), nrow=l, ncol=l)
for (i in 1:l){
  for(j in 1:l){
    if (Risco[i]==Risco[j]){
      c=0
    }else{
      c = 1/abs(Risco[i]-Risco[j])
    }
    Sojalist[i,j] = c
  }
}
```

```

}
w = matrix(do.call(rbind, Sojalist), nrow=1, ncol=1)
#Matriz w normalizada
m = matrix(list(), nrow=1, ncol=1)
for (i in 1:1){
  for (j in 1:1){
    soma= w[i,j]/sum(w[i,])
    m[i,j]=soma
  }
}
wnorm = matrix(do.call(rbind, m), nrow=1, ncol=1)

library(readxl)
DifSoja <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/DifSojaB
rasilST.xlsx")
Soja <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/SojaBrasils
T.xlsx")

install.packages('starma')
library(starma)
length(DifSoja)
o0=diag(length(DifSoja))
w1 = list(order0 =o0, order1=wnorm)

d=stcenter(DifSoja, center = TRUE, scale = TRUE)
stcor.test(d, w1, tlag=NULL)

# Identificação do modelo
stacf(d, w1, tlag.max = 20, use.ggplot = TRUE)
stpacf(d, w1, tlag.max = 20, use.ggplot = TRUE)

# Etapa de ajuste do modelo STARIMA (161, 1, 31)

ar<- matrix(0, 16, 2)
ar[15,2]=1
ar[16,2]=1

ma <- matrix(0, 16, 2)
ma[3,1]=1
ma[3,2]=1

# Ajuste do modelo
model=starma(d, w1, ar, ma)
summary(model)
model$bic

#Diagnóstico do modelo
stcor.test(model$residuals, w1, fitdf=4)
stacf(model$residuals, w1)
stpacf(model$residuals, w1)
hist(model$residuals, prob=TRUE)
curve(dnorm(x, mean=mean(model$residuals), sd=sd(model$residuals)), add=TRU
E)
ks.test(model$residuals, mean(model$residuals), sd(model$residuals))

# Etapa de ajuste do modelo STARIMA STARIMA (31, 1, 3)

ar<- matrix(0, 3, 2)
ar[2,1]=1
ar[2,2]=1
ar[3,1]=1
ar[3,2]=1

ma <- matrix(0, 3, 2)
ma[1,1]=1

```

```

ma[2,2]=1
ma[3,1]=1

# Ajuste do modelo
mode2=starma(d, w1, ar, ma)
summary(mode2)
mode2$bic

#Diagnóstico do modelo
stcor.test(mode2$residuals, w1, fitdf=4)
stacf(mode2$residuals, w1)
stpacf(mode2$residuals, w1)
hist(mode2$residuals, prob=TRUE)
curve(dnorm(x, mean=mean(mode2$residuals), sd=sd(mode2$residuals)), add=TRUE)
ks.test(mode2$residuals, mean(mode2$residuals), sd(mode2$residuals))

#####
##### Paraná #####
#####

#Carregando dados
library(readxl)
SojaPR <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/SojaPR.xlsx")

#Transformando em série temporal
série_temporal<-data.frame(ts(SojaPR, start=c(1993,1), end=c(2019,1), frequency = 1 ))
ano<- 1993:2019

install.packages('zoo')
library(zoo)
tSojaPR <- data.frame(zoo(série_temporal, ano))

#Fazendo as regressões
resultados.lm = list()

for(i in 1:242) {
  foo.y = tSojaPR[,i]
  foo.name = names(tSojaPR)[i]
  resultados.lm[[i]] = lm(foo.y ~ ano)
}
resultados.lm

#Retirando a tendência
resultados.tend = list()

for (i in 1:242){
  foo.name = names(tSojaPR)[i]
  res= resultados.lm[[i]]$residuals
  ypred=resultados.lm[[i]]$fitted.values
  ynew= ypred[27]*(1+res/ypred)
  resultados.tend[[i]] = ynew
}
P = data.frame(resultados.tend)
write.table(P, file='SojaPRST.csv', sep=';', dec='.', row.names=FALSE)

#Matriz w para Soja
library(readxl)

SojaPRST <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/RiscoSojaPR.xlsx")
Risco = SojaPRST$Risco
l=length(Risco)

```

```

Sojalist = matrix(list(), nrow=1, ncol=1)
for (i in 1:1){
  for(j in 1:1){
    if (Risco[i]==Risco[j]){
      c=0
    }else{
      c = 1/abs(Risco[i]-Risco[j])
    }
    Sojalist[i,j] = c
  }
}

w = matrix(do.call(rbind, Sojalist), nrow=1, ncol=1)

#Matriz w normalizada

m = matrix(list(), nrow=1, ncol=1)
for (i in 1:1){
  for (j in 1:1){
    soma= w[i,j]/sum(w[i,])
    m[i,j]=soma
  }
}

wnorm = matrix(do.call(rbind, m), nrow=1, ncol=1)

library(readxl)
DifSojaPR <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/DifSojaPRST.xlsx")
SojaPRST <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/SojaPRST.xlsx")

install.packages('starma')
library(starma)
length(DifSojaPR)
o0=diag(length(DifSojaPR))
w1 = list(order0 =o0, order1=wnorm)

d=stcenter(DifSojaPR, center = TRUE, scale = TRUE)
stcor.test(d, w1, tlag=NULL)

# Identificação do modelo
stacf(d, w1, tlag.max = 12, use.ggplot = TRUE)
stpacf(d, w1, tlag.max = 12, use.ggplot = TRUE)

# Etapa de ajuste do modelo STARIMA (191, 1, 141)

ar<- matrix(0, 19, 2)
ar[19,2]=1

ma <- matrix(0, 14, 2)
ma[1,1]=1
ma[13,1]=1
ma[14,2]=1

# Ajuste do modelo
model=starma(d, w1, ar, ma)
summary(model)
model$bic

#Diagnóstico do modelo
stcor.test(model$residuals, w1, fitdf=4)
stacf(model$residuals, w1)
stpacf(model$residuals, w1)
hist(model$residuals, prob=TRUE)
curve(dnorm(x, mean=mean(model$residuals), sd=sd(model$residuals)), add=TRUE)
ks.test(model$residuals, mean(model$residuals), sd(model$residuals))

```

```

# Etapa de ajuste do modelo STARIMA (191, 1, 41)

ar<- matrix(0, 19, 2)
ar[16,1]=1
ar[19,2]=1

ma <- matrix(0, 19, 2)
ma[4,1]=1
ma[4,2]=1

# Ajuste do modelo
model=starma(d, w1, ar, ma)
summary(model)
model$bic

#Diagnóstico do modelo
stcor.test(model$residuals, w1, fitdf=4)
stacf(model$residuals, w1)
stpacf(model$residuals, w1)
hist(model$residuals, prob=TRUE)
curve(dnorm(x, mean=mean(model$residuals), sd=sd(model$residuals)), add=TRUE)
ks.test(model$residuals, mean(model$residuals), sd(model$residuals))

#####
##### Paraná 9 #####
## Municípios produtores #####
#####

#Matriz w para Soja

library(readxl)

SojaPRST <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/RiscoPR
.xlsx")
Risco = SojaPRST$Risco
l=length(Risco)

Sojalist = matrix(list(), nrow=l, ncol=l)
for (i in 1:l){
  for(j in 1:l){
    if (Risco[i]==Risco[j]){
      c=0
    }else{
      c = 1/abs(Risco[i]-Risco[j])
    }
    Sojalist[i,j] = c
  }
}

w = matrix(do.call(rbind, Sojalist), nrow=l, ncol=l)

#Matriz w normalizada

m = matrix(list(), nrow=l, ncol=l)
for (i in 1:l){
  for (j in 1:l){
    soma= w[i,j]/sum(w[i,])
    m[i,j]=soma
  }
}

wnorm = matrix(do.call(rbind, m), nrow=l, ncol=l)

library(readxl)
DifSojaPR <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/DifPR.
xlsx")

```

```
SojaPR <- read_excel("Doutorado/Economia aplicada/Tese/Dados Tese/PR.xlsx")
install.packages('starma')
library(starma)

o0=diag(length(DifSojaPR))
w1 = list(order0 =o0, order1=wnorm)

d=stcenter(DifSojaPR, center = TRUE, scale = TRUE)
stcor.test(d, w1, tlag=NULL)

# Identificação do modelo
stacf(d, w1, tlag.max = 20, use.ggplot = TRUE)
stpacf(d, w1, tlag.max = 19, use.ggplot = TRUE)

# Etapa de ajuste do modelo STARIMA (141, 1, 101)

ar<- matrix(0, 20, 2)
ar[3,1]=1
ar[14,2]=1
ar[11,2]=1
ar[12,1]=1

ma <- matrix(0, 20, 2)
ma[9,1]=1
ma[10,2]=1
ma[1,1]=1
ma[7,1]=1

# Ajuste do modelo
model=starma(d, w1, ar, ma)
summary(model)
model$bic

#Diagnóstico do modelo
stcor.test(model$residuals, w1, fitdf=1)
stacf(model$residuals, w1)
stpacf(model$residuals, w1)
hist(model$residuals, prob=TRUE)
curve(dnorm(x, mean=mean(model$residuals), sd=sd(model$residuals)), add=TRUE)
ks.test(model$residuals, mean(model$residuals), sd(model$residuals))
```