

Um estudo sobre a diversificação espacial de riscos climáticos em seguros agrícolas no Brasil[†]

João Vinícius de França **CARVALHO**¹

jvfcarvalho@usp.br |  ORCID: <https://orcid.org/0000-0002-1076-662X>

Nathalia Costa **FONSECA**¹

nathaliacostafonseca@usp.br |  ORCID: <https://orcid.org/0000-0003-0178-4663>

Daniel Fabri **BAGATINI**¹

dbagatini@alumni.usp.br |  ORCID: <https://orcid.org/0009-0000-8863-5323>

Resumo

A produção agrícola no Brasil representa cerca de 6,9% do PIB e está fortemente exposta a riscos climáticos. Apesar de sua relevância econômica, os efeitos de eventos climáticos adversos sobre os sinistros de seguros agrícolas ainda são pouco conhecidos. Este trabalho avalia os efeitos de variáveis climáticas sobre os sinistros diretos em seguros agrícolas, por meio de modelos de econometria espacial com dados em painel. São utilizados dados oficiais do mercado segurador brasileiro e de medições meteorológicas, mensalmente entre jan/2006 e ago/2023, totalizando 5.460 observações de 26 estados brasileiros. Todos os modelos espaciais estimados apontam consistentemente que as variáveis climáticas estão fortemente associadas aos sinistros. Particularmente, a precipitação não apresenta efeito direto significante, apenas quando afeta simultaneamente múltiplos vizinhos (e.g., enchentes e alagamentos). Já a força do vento e a umidade (indicador principal de secas, se baixa, e de geadas, se elevada e concomitante a baixas temperaturas) são fatores relevantes para explicar os sinistros. Observa-se, também, concentração de prêmios emitidos nas regiões Sul e Sudeste, sugerindo riscos potenciais de concentração geográfica. Os achados podem apoiar (res)seguradoras na diversificação e precificação de portfólios. Também oferecem subsídios a agricultores e formuladores de políticas públicas na mitigação de perdas e alocação de recursos.

Palavras-chave

Seguros agrícolas, Mudanças climáticas, Econometria espacial, Risco sistêmico.

¹ Universidade de São Paulo (USP), Faculdade de Economia, Administração, Contabilidade e Atuária, Departamento de Contabilidade e Atuária (FEA), São Paulo, SP, Brasil.

Recebido: 28/11/2024.

Revisado: 10/07/2025.

Aceito: 05/08/2025.

DOI: <https://doi.org/10.1590/1980-53575546jnd>

A study on the spatial diversification of climate risks in agricultural insurance in Brazil

Abstract

Agricultural production in Brazil accounts for about 6.9% of GDP and is heavily exposed to climate risks. Despite its economic relevance, the effects of adverse climatic events on agricultural insurance claims are not well understood. This paper assesses the effects of climatic variables on direct claims in agricultural insurance, using spatial econometrics models with panel data. Official data from the Brazilian insurance market and meteorological measurements, monthly from Jan/2006 to Aug/2023, are used, totaling 5,460 observations from 26 Brazilian states. All estimated spatial models consistently show that climatic variables are strongly associated with claims. Specifically, precipitation does not have a significant direct effect, only when it simultaneously affects multiple neighboring areas (e.g., floods and inundations). Wind strength and humidity (a key indicator of droughts when low, and frost when high and coupled with low temperatures) are relevant factors for explaining claims. Additionally, there is concentration of premiums issued in the South and Southeast regions, suggesting potential geographical concentration risks. The findings can assist (re)insurers in diversifying and pricing portfolios. They also offer support to farmers and policymakers in mitigating losses and allocating resources more effectively.

Keywords

Agricultural insurance, Climate change, Spatial econometrics, Systemic risk.

JEL Classification

G22, C33, Q54.

1. Introdução

Alterações climáticas provocam mudanças na frequência, duração, intensidade, extensão espacial e sazonalidade de eventos climáticos essenciais para atividades humanas como a agricultura e pecuária, com variações nos padrões de precipitação, temperatura ou umidade do solo (Malhi, Kaur, and Kaushik 2021). Mesmo quando não configuram extremos estatísticos, os efeitos das mudanças climáticas podem gerar impactos severos, sobretudo ao ocorrerem de forma combinada ou ao ultrapassarem limites críticos para as atividades humanas (IPCC 2012; FAO 2023). A agricultura se destaca nesse contexto, tanto por sua alta sensibilidade às condições climáticas, quanto por sua centralidade na segurança alimentar e na estabilidade dos mercados de *commodities* (Brás *et al.* 2021; Monteleone *et al.* 2023).



Evidências empíricas de impactos negativos sobre a produção de culturas agrícolas essenciais, como soja, trigo e milho, têm sido observadas nas últimas cinco décadas (Miranda and Glauber 1997), com efeitos registrados em diferentes regiões do planeta, ainda que derivados de fatores climáticos distintos (Khan and Rashid 2022). Em regiões da África, por exemplo, aumentos de temperatura e pluviometria foram associados a perdas na produção agrícola (Sultan, Defrance, and Iizumi 2019), enquanto que na Austrália os principais impactos decorreram da redução pluviométrica e aumento de temperatura (Hochman, Gobbett, and Horan 2017). Nos últimos 30 anos, estima-se que desastres naturais tenham causado a perda de US\$ 3,8 trilhões na produção agrícola e pecuária, o que representa, em média, uma redução de US\$ 123 bilhões por ano – cerca de 5% do PIB agrícola global anual (FAO 2023). Para comparação, o montante total dessas perdas ao longo das três décadas equivale ao PIB do Brasil em 2022.

Diante desse cenário de instabilidade climática e de seus efeitos sobre a produção de alimentos, os seguros agrícolas despontam como instrumentos relevantes para a estabilização econômica, ao contribuírem para a manutenção da renda dos produtores e estimularem os investimentos no setor (Okhrin, Odening, and Xu 2013). Considerando que cerca de 90% das propriedades responsáveis pela produção de alimentos no mundo são fazendas familiares (Lowder, Sánchez, and Bertini 2019), a estabilização de renda por meio de seguros pode gerar um impacto social positivo.

Apesar dos efeitos positivos que os produtos de seguro podem gerar no setor agrícola, as seguradoras enfrentam riscos próprios, relacionados à dificuldade de diversificação do portfólio, que é necessária para evitar que um grande número de segurados seja afetado concomitantemente por um mesmo evento climático (Ozaki 2007; Mason, Hayes, and Lence 2003; Miranda and Glauber 1997). Esse problema se torna especialmente preocupante quando os impactos climáticos sobre a produção agrícola ocorrem frequentemente, afetando muitas culturas seguradas em uma mesma região. Isso pode tornar a comercialização de seguros agrícolas inviável sem a proteção de um ressegurador capaz de diversificar tais riscos (Phélieppé-Guinvarc'h and Cordier 2006; Okhrin, Odening, and Xu 2013).

Para mitigar esses riscos, a diversificação geográfica se torna uma estratégia importante, tanto para as seguradoras quanto para os produtores (Su, Gabrielle, and Makowski 2021). A diversificação espacial dos riscos climáticos pode garantir maior estabilidade nos resultados financeiros,

reduzindo a exposição a perdas generalizadas. Afinal, como os principais fatores de risco da produção estão ligados a eventos climáticos regionais, distribuir a produção entre diferentes áreas pode funcionar como um *hedge* natural contra variações extremas do clima (Torres et al. 2024; Nguyen-Huy et al. 2019). Estudos mostram que, apesar dos desafios operacionais, a diversificação espacial pode aumentar a resiliência do setor, tornando a produção agrícola menos vulnerável a choques externos e evitando sinistros generalizados para as (res)seguradoras (Dal Pozzo, Zorzi, and Ozaki 2025; G. Martins and Signorini 2025).

Considerando a importância da diversificação do portfólio de seguros agrícolas, diversos estudos realizados em países como Estados Unidos (Sun and Wang 2022) China (Okhrin, Odeneing, and Xu 2013), Austrália (Nguyen-Huy et al. 2019) e Alemanha (Xu et al. 2010) investigam a possibilidade da diversificação espacial dos riscos climáticos, que aumentaria a viabilidade dos produtos de seguro. Em particular, Okhrin et al. (2013) verificaram na China que a diversificação espacial pode reduzir a probabilidade de perdas generalizadas nos portfólios de seguros agrícolas.

O Brasil é um dos maiores produtores agropecuários do mundo, com destaque para suas produções internacionalmente relevantes de cana de açúcar, soja e outras oleaginosas, carnes, café e frutas tropicais¹. Sua grande extensão territorial, tanto latitudinal quanto longitudinal, confere características únicas ao país, bastante distintas de outros grandes produtores agrícolas mundiais (Chang 1977), as quais favorecem estudos sobre a diversificação espacial de riscos climáticos. Ademais, o setor agrícola brasileiro exerce importante papel em sua economia interna, compondo aproximadamente 6,2% do PIB nacional em 2023 (The World Bank 2022). Contudo, não foram encontrados estudos que abordem a diversificação espacial de riscos climáticos para seguros agrícolas no contexto brasileiro, nem pesquisas internacionais recentes que tenham analisado países com essas características.

Esta é a lacuna que se pretende explorar. O objetivo deste trabalho é avaliar os efeitos de variáveis climáticas sobre os sinistros diretos em seguros agrícolas, um segmento suscetível a riscos ambientais sistêmicos. Como instrumento, serão utilizados modelos de econometria espacial para estimar a estrutura de dependência espacial entre os montantes de sinistro agregado e os eventos climáticos em diferentes regiões do Brasil. Embora essa abordagem não represente diretamente a diversificação do portfólio

¹ “Resource Trade”, Chatham House, em vigor em 21 de agosto de 2025, <https://resourcetrade.earth/>

das seguradoras, ela permitirá mapear padrões de risco climático, oferecendo subsídios relevantes para a gestão de riscos em seguros agrícolas.

Yun e Gramig (2022) apontam que, com o fácil acesso a dados climáticos das últimas décadas, o uso de econometria espacial para avaliar efeitos do clima sobre a agricultura têm ganhado espaço na literatura. Nesse cenário, existem evidências de que análises espaciais podem contribuir para o entendimento dos efeitos climáticos sobre a agricultura e fornecer subsídios para auxiliar na tomada de decisões tanto referentes à gestão pública quanto à gestão de carteiras de seguros agrícolas (Goodwin and Piggott 2020; Yun and Gramig 2022).

Os resultados desta pesquisa podem beneficiar diversos agentes econômicos: (i) (re)seguradoras, ao aprimorar a diversificação de portfólios e reduzir riscos sistêmicos; (ii) agricultores, que podem ter à disposição apólices de seguros mais viáveis; (iii) formuladores de políticas públicas podem usar os resultados para mitigar riscos no setor agrícola, para produtores e seguradores, e, finalmente; (iv) instituições financeiras poderão avaliar melhor os impactos climáticos e alocar recursos no agronegócio (e.g., crédito) de forma mais eficiente.

2. Fundamentação Teórica e Literatura Empírica

2.1. Diversificação Espacial: Importância e Técnicas de Medição

A preocupação com os efeitos econômicos e sociais causados por alterações climáticas, principalmente aqueles relacionados à agricultura, reforça o papel dos seguros agrícolas na estabilização econômica após eventos que geram perda de produtividade. Importantes produtos nesse tipo de estabilização econômica, os seguros agrícolas enfrentam problemas específicos em casos de eventos climáticos. É amplamente documentado pela literatura que seguros agrícolas estão sujeitos a elevado risco sistêmico em todo o mundo, i.e., grande quantidade de agentes pode ser atingida por perdas simultaneamente, principalmente quando grandes eventos climáticos estão envolvidos, uma vez que estes podem afetar diversas regiões biogeográficas simultaneamente (Guimarães and Igari 2019; Miranda and Glauber 1997; Okhrin, Odeneing, and Xu 2013; Mason, Hayes, and Lence 2003; Ozaki 2007) que provocaria posteriormente aumento nos prêmios cobrados pelas empresas seguradoras. Os prêmios mais caros fazem com que as carteiras passem a ser compostas prioritariamente por segurados de maior risco, o

que aumentaria ainda mais a recorrência de indenizações a sinistros. Para atender ao objetivo proposto, realizaram-se análises de regressão linear entre sinistros ocorridos em um ano e as contratações no ano seguinte, entre o período de 2003 a 2013, para seis Unidades Federativas do Brasil, sendo elas: Mato Grosso do Sul (MS). Tais eventos impedem que seguradoras consigam diversificar seus riscos pelo mecanismo de *pooling*, uma vez que existe elevado risco de grande parte do portfólio segurado ser atingido quando os eventos ocorrem em grandes regiões (Mason, Hayes, and Lence 2003).

Nesse contexto, Miranda e Glauber (1997) indicam que a criação de um programa de resseguros por área de colheita por meio de contratos a serem comercializados em bolsas de futuros e opções (*area-yield reinsurance contracts*) poderia ser um mecanismo auxiliar na mitigação desses riscos, permitindo que seguradoras se protejam de perdas que afetem um grande número de segurados numa mesma área, e/ou que excedam os limiares aceitáveis.

Entretanto, Mason et al. (2003) apontam que tais contratos não oferecem a proteção necessária para os produtores, pois não são efetivos na proteção de riscos locais que possam afetar a produção. Ademais, enquanto as divisões regionais utilizadas pelos autores (divisas estaduais e municipais) podem apresentar independência para certos eventos climáticos pontuais (e.g., queda de granizo, inundações e incêndios causados por tempestades), outros eventos climáticos podem extrapolar os limites dessas regiões, como seca, temperaturas elevadas e incidência de radiação solar (Okhrin, Odeneing, and Xu 2013), de forma que tal divisão de áreas poderia não ser ótima.

Na prática, esse problema tem sido mitigado pela utilização de um sistema misto em que o risco sistêmico de eventos climáticos sobre a produção agrícola é assumido por governos federais, que acabam por assumir um papel de resseguradora quando ocorrem eventos extremos e sistêmicos, amenizando os efeitos sobre as seguradoras e incentivando o mercado de seguros agrícolas (Hazell and Varangis 2020; Mason, Hayes, and Lence 2003).

Numa tentativa de melhor compreender a dependência espacial de riscos climáticos em produtos de seguro, os primeiros estudos realizados utilizaram técnicas estatísticas baseadas, principalmente, na correlação de variáveis climáticas e dos efeitos negativos sobre a produção agrícola causados por eventos climáticos (Woodard and Garcia 2008; Wang and Zhang 2003; Miranda and Glauber 1997). Em particular, Goodwin (2001) destaca evi-



dências de baixa correlação entre as regiões estudadas durante os períodos de normalidade climática. Entretanto, essas correlações aumentam rapidamente quando as referidas regiões passam a sofrer alterações em seus padrões climáticos, como períodos de seca. Esses resultados evidenciam que métodos de diversificação espacial baseados apenas em técnicas de correlação podem falhar em capturar eventos em que haja forte dependência, sendo justamente tais eventos os mais preocupantes em termos de risco sistêmico em produtos de seguros agrícolas.

Riscos sistêmicos têm sido objeto de preocupação na indústria de seguros (Carvalho and Guimarães 2024), e evidências empíricas indicam que a concentração de culturas pode intensificar os sinistros enfrentados pelas seguradoras (Dal Pozzo, Zorzi, and Ozaki 2025). Contudo, a diversificação da oferta de seguros entre diferentes culturas e regiões tem se mostrado uma estratégia eficaz para reduzir esses riscos sistêmicos (Torres et al. 2024; G. Martins and Signorini 2025). Nesse contexto, a modelagem de uma distribuição conjunta dos retornos financeiros em distintas regiões, combinada com um processo de otimização do portfólio para minimizar a variabilidade sem comprometer o retorno esperado, pode contribuir para a mitigação do risco sistêmico associado ao clima (Nguyen-Huy *et al.* 2019).

A identificação da dependência espacial entre eventos climáticos adversos e perdas agrícolas é fundamental para aprimorar a modelagem de riscos e a precificação de seguros agrícolas (Schmitt *et al.* 2024). Compreender como os riscos estão correlacionados espacialmente permite que (res)seguradoras desenvolvam estratégias de diversificação mais eficazes, reduzindo a exposição a perdas simultâneas em diferentes regiões (Sun and Wang 2022). Modelos que capturam essa estrutura de dependência possibilitam uma avaliação mais precisa do risco agregado, favorecendo uma precificação consequentemente mais ajustada ao risco real, redução dos carregamentos de risco, e uma subscrição mais eficiente (Michaelides, Mailhot, and Li 2025; Schmitt *et al.* 2024; Sun and Wang 2022). Além disso, avanços na aplicação da econometria espacial em contextos de seguros agrícolas têm evidenciado o potencial dessa ferramenta para capturar padrões de autocorrelação espacial e aprimorar a alocação geográfica de riscos (Mendonça and Ramos 2023). Nesse sentido, modelos que combinam estruturas autoregressivas e agrupamentos espaciais têm sido explorados para propor delimitações regionais mais aderentes aos padrões de risco climático do que aquelas baseadas apenas em divisões administrativas (Cerqueti, Maranzano, and Mattera 2024).

Embretschs *et al.* (2002) apontam que, apesar de ser de uso comum em áreas de finanças e seguros, medidas de correlação são úteis apenas para distribuições multivariadas normais e lineares, raramente encontradas em dados reais. Eles apontam, ainda, que as seguradoras tradicionalmente pressupõem independência estatística dos dados observados, situação que também raramente se mostra real, principalmente em carteiras que envolvam riscos climáticos. Diante desses problemas e da crescente preocupação com os efeitos econômicos causados sobre a produção agrícola por mudanças climáticas, a última década foi marcada pela utilização de novas ferramentas estatísticas capazes de melhor capturar os efeitos climáticos sobre a agricultura e auxiliar na precificação de seguros agrícolas. Dentre essas ferramentas, destacam-se as cópulas (Goodwin and Hungerford 2015; Rensi and Carvalho 2023; Okhrin, Odeneing, and Xu 2013; Nguyen-Huy *et al.* 2019; Xu *et al.* 2010) e as técnicas de econometria espacial (Park, Brorsen, and Harri 2019; Adhikari, Belasco, and Knight 2010; Yun and Gramig 2022; Goodwin and Piggott 2020; Mendonça and Ramos 2023).

Nesse sentido, Okhrin *et al.* (2013) verificaram dependência espacial usando análises estatísticas de riscos climáticos. Por meio de dados simulados, concluíram que a diversificação espacial na China, usando os agrupamentos encontrados, poderia reduzir o valor do prêmio de risco de seguros agrícolas. Analogamente, Nguyen-Huy *et al.* (2019) encontraram que a diversificação espacial de riscos climáticos na Austrália poderia reduzir riscos relacionados a secas extremas por um fator de 0,48 em nível nacional. Para a região europeia, especificamente na Espanha, Salgueiro e Tarazon-Rodon (2021), utilizando distribuições normais multivariadas, verificaram que a diversificação espacial de riscos pode levar à diminuição da taxa de carregamento dos seguros agrícolas. Tais estudos são fortes indicadores de que a definição e utilização de agrupamento de regiões por riscos climáticos usando cópulas poderia oferecer maior diversificação para as seguradoras e resseguradoras em relação à diversificação oferecida por regiões geopolíticas e estudos de correlação linear.

Utilizando-se de econometria espacial, Goodwin e Piggott (2020) verificaram que, nos EUA, a recente modernização tecnológica e o uso de sementes geneticamente alteradas podem ter causado um impacto positivo na produção agrícola das duas últimas décadas, mesmo com a ocorrência de eventos climáticos extremos no período. Yun e Gramig, (2022), por sua vez, realizaram um extenso estudo para verificar a eficácia de 14 diferentes modelos espaciais na predição de produção agrícola nos EUA, utilizando



diferentes variáveis climáticas, e apontam que essa técnica apresenta bons resultados preditivos. Adicionalmente, Cerqueti, Maranzano, and Mattera (2024) analisaram a concentração do mercado agrícola europeu a partir da aplicação do modelo *spatially-clustered spatial autoregression* (SCSAR), uma extensão dos modelos de regressão linear espacialmente agrupados, e concluíram que a metodologia melhora a segmentação das regiões, identificando padrões de risco e destacando efeitos locais heterogêneos.

Para a América Latina, Abrego-Perez e Valencia-Arboleda (2023), usaram dados de precipitação e colheita em plantios de café na Colômbia para comparar a efetividade de duas metodologias para a criação de contratos de seguro agrícola usando índices climáticos. Nessa comparação, contratos estruturados a partir de um modelo de cópula bivariada com quantis dinâmicos se mostraram superiores a contratos estruturados por modelos lineares (*decomposition singular spectrum analysis*, SSA). Os autores indicam que técnicas que utilizam cópulas para a formação de índices climáticos podem aumentar a eficiência de *hedge* e diminuir o prêmio puro do seguro para os fazendeiros. Mendonça e Ramos (2023), por sua vez, analisaram a distribuição espacial dos seguros rurais no Brasil, destacando a heterogeneidade na cobertura dos seguros e a concentração das apólices nas regiões Sul e Centro-Oeste. Através de análise espacial, identificaram uma tendência crescente na dependência espacial dos seguros, sugerindo que há áreas ainda não atendidas que demandam estratégias de cobertura específicas. No entanto, o estudo não aborda a diversificação de portfólio das seguradoras agrícolas.

2.2. O Seguro Agrícola no Brasil

A política agrícola brasileira tem se estruturado ao longo das décadas para fortalecer o setor e reduzir os impactos de fatores adversos, incluindo riscos climáticos. Santana *et al.* (2014) destacam que, embora avanços como incentivos governamentais e novas tecnologias tenham impulsionado a produção, a gestão dos riscos agrícolas ainda enfrenta desafios, exigindo instrumentos mais eficazes de proteção.

Nesse cenário, o seguro agrícola tornou-se um dos principais mecanismos de estabilidade para os produtores rurais, complementando outras políticas de suporte ao setor. Segundo Buainain *et al.* (2014), o seguro rural, junto ao crédito agrícola e ao Programa Nacional de Fortalecimento da Agricultura

Familiar (PRONAF), forma um tripé essencial para a segurança da produção. Programas como o Programa de Subvenção ao Prêmio do Seguro Rural (PSR) buscam ampliar o acesso dos agricultores ao seguro, mas ainda carecem de estratégias mais amplas de mitigação de riscos, como a diversificação espacial dos seguros, fator essencial para a sustentabilidade do mercado no Brasil.

Dada a grande importância do setor agrícola no Brasil, o governo brasileiro tem buscado minimizar os impactos climáticos sobre a produção agrícola por meio de programas como o Zoneamento Agrícola de Risco Climático (ZARC), regulamentado pelo Decreto-Lei nº 9.841/2019, que fornece orientações em tempo real sobre os melhores momentos de plantio de cada cultura em diversas regiões. Embora esse programa ofereça grande auxílio aos produtores, ele não necessariamente reduz a probabilidade de perdas causadas por eventos climáticos extremos - como secas ou geadas - que ainda podem ocorrer mesmo dentro do período indicado.

Khan e Rashid (2022) estudaram os efeitos de mudanças climáticas em 179 países, com dados de 1990-2020, e verificaram que, para a maioria dos indicadores estudados, as mudanças impactaram negativamente o crescimento econômico. Ampliando a compreensão das perdas agrícolas no território nacional, o governo brasileiro publicou um histórico de perdas na agricultura nacional para os anos entre 2000-2021 (Brasil 2021). Neste histórico, percebe-se que os eventos climáticos que afetam as diversas produções estudadas são os mais diversos possíveis, e.g., geadas, secas, alta pluviosidade e altas temperaturas. Em casos extremos, as perdas para os produtores ultrapassaram R\$1 bilhão. Neste histórico é importante notar que os eventos extremos muitas vezes ultrapassaram as divisas geográficas estaduais, atingindo diferentes culturas agrícolas simultaneamente em mais de um estado da federação, indicando que diversificação regional baseada apenas em divisões geopolíticas, como as unidades federativas (UF), pode não ser suficiente para mitigar os riscos climáticos dos portfólios de seguradoras brasileiras.

Para incentivar o mercado de seguros agrícolas no Brasil, e proteger economicamente os agricultores, o governo federal possui dois programas de incentivo: o Fundo de Estabilidade do Seguro Rural (FESR) e o Programa de Subvenção ao Prêmio do Seguro Rural (PSR). O FESR é um fundo que objetiva oferecer proteção às seguradoras em ocorrências catastróficas que afetem os segurados, efetivamente fazendo com que o governo federal

assuma o papel final de uma resseguradora, responsabilizando-se pelos eventos de sinistro de alta monta. Já o PSR atua diretamente junto aos agricultores, oferecendo subsídios sobre o prêmio de seguro agrícola para torná-lo mais acessível ao produtor rural. Enquanto tais programas podem, efetivamente, atuar sobre a disponibilidade de ofertas de produtos de seguro, eles exercem pouca influência na questão central de diversificação dos riscos e no barateamento dos produtos de seguros por não atuarem na diversificação dos riscos do ponto de vista da seguradora (Ye *et al.* 2020).

Tradicionalmente, os estudos de zoneamento realizados no Brasil sobre clima e produtividade agrícola analisam as necessidades individuais de culturas específicas, visando estabelecer os melhores cultivos para cada condição climática, mas não consideram questões de dependência espacial em relação à ocorrência de eventos adversos causados por condições climáticas inesperadas (Fritzsons, Eduardo Mantovani, and Silveira Wrege 2016). Assim, há poucos subsídios para que seguradoras criem portfólios de seguros com maior diversificação espacial dos riscos.

Nesse sentido, os estudos de diversificação espacial de riscos climáticos no Brasil ainda são bastante incipientes, principalmente quando no contexto de seguros. Principalmente utilizando econometria espacial. Destaca-se Torres, Bacha, and Antunes (2024), que analisaram os programas federais de seguro rural (PROAGRO e PSR) pela ótica dos gastos do governo e de sua adoção pelos agricultores, encontrando associação espacial (pelo I de Moran) por parte dos agricultores na adoção do PROAGRO, na Região Sul do Brasil, e do PSR, nas Regiões Sul e Centro-Oeste. Assim como Mota *et al.* (2020), que avaliaram a eficácia de diferentes métodos de séries temporais, incluindo um método envolvendo redes neurais, para projetar o prêmio e a ocorrência de sinistros em seguros agrícolas. Contudo, os autores não encontraram um método que se mostrasse eficiente para todas as regiões estudadas, sendo que para cada região um método distinto apresentou melhores resultados. Ainda assim, apesar dos recentes trabalhos na literatura internacional que usam econometria espacial em outros contextos (e.g., Economia Regional), não foram encontrados estudos que as utilizem tal metodologia para a análise de diversificação espacial de riscos climáticos em seguros agrícolas, especialmente no Brasil.

3. Metodologia e Dados

3.1. Levantamento e Tratamento dos Dados

Os dados climáticos de diversas regiões brasileiras foram obtidos a partir do banco de dados do Instituto Nacional de Meteorologia (INMET). As estações meteorológicas foram selecionadas de acordo com sua localização geográfica e tempo de operação, de maneira a cobrir todo o território nacional com dados a partir de janeiro/2006 e até agosto/2023. Dentre os dados disponíveis, foram usados aqueles referentes às temperaturas média, mínima e máxima, à pluviometria total, à umidade, ao vento médio e à insolação, todos referentes às médias mensais, disponibilizadas pelo próprio INMET, obtidos por estações convencionais e estações automáticas, sem distinção.

Tais dados climáticos foram agrupados por UF utilizando-se média simples. Para meses esporádicos em que não havia dados climáticos os valores foram calculados a partir da média simples entre os dados dos meses imediatamente anterior e imediatamente posterior. Para períodos com mais de um mês sequencial sem observações climáticas foi utilizada a média simples das observações climáticas observadas nas regiões de entorno da região com dados faltantes. Por ter longos período sem dados climáticos para todo o estado de Rondônia, esse estado foi removido da base de dados e não foi utilizado nas análises.

Os dados de sinistros de seguros agrícolas (sinistros diretos, i.e., valores indenizados pela operação da supervisionada, incluindo o cosseguro cedido) foram obtidos a partir dos dados divulgados no Sistema de Estatísticas da SUSEP e agrupados pelos seguintes ramos: 1101 (Seguro Agrícola sem Cobertura do FESR), 1102 (Seguro Agrícola com Cobertura do FESR) e 1161 (Agrícola).

Tendo em vista o objetivo deste estudo, a partir destes dados são estimados modelos de regressão tendo como variável dependente os sinistros em seguros agrícolas e como variáveis preditoras as medições climáticas. A modelagem conta ainda com componentes para capturar a relação espacial entre as variáveis utilizadas, a partir de métodos de Econometria Espacial.

3.2. A modelagem usando Econometria Espacial

A econometria espacial lida com interações de unidades econômicas no espaço geográfico, e considera a interdependência, *spillovers* e heterogeneidade que estejam presentes nos dados ou no modelo econométrico e que sejam relacionadas a efeitos espaciais como, por exemplo, autocorrelação espacial (Anselin 1988). É, portanto, uma técnica mais adequada do que os modelos lineares mais básicos, como o OLS, para capturar fenômenos onde a relação espacial é relevante, por exemplo em dados climáticos (Fonseca, Carvalho, and Araujo 2024).

Em modelos espaciais, as interações são contabilizadas por uma matriz de vizinhança W (Kelejian and Piras 2017; Anselin 1988) na qual cada elemento w_{ij} indica a proximidade das unidades i e j . Se $w_{ij} \neq 0$, diz-se que i e j são vizinhos e, portanto, podem interagir de alguma maneira significativa como, por exemplo, *spillovers*, externalidades ou efeitos de proximidade geográfica (Kelejian and Piras 2017).

Uma matriz de vizinhança $n \times n$ pode ser escrita como:

$$W = \begin{bmatrix} W_1 \\ \vdots \\ W_n \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1j} & \dots & w_{1(n-1)} & w_{1n} \\ & & & & & \ddots & \\ w_{n1} & w_{n2} & \dots & w_{nj} & \dots & w_{n(n-1)} & w_{nn} \end{bmatrix} \quad (1)$$

Então, um modelo espaço-temporal geral de dados em painel, com n observações na seção transversal e t períodos de tempo, pode ser definido como:

$$y_{it} = \rho W y_{it} + \alpha \iota_n + X_{it} \beta + W X_{it} \theta + u_{it} \quad (2)$$

$$u_{it} = \lambda W \mu_{it} + u_i + \tau_t + \nu_{it}, t = 1, \dots, T, i=1, \dots, n \quad (3)$$

em que y_{it} é um vetor $n \times 1$ de observações das unidades i explicadas no tempo t , ι_n é um vetor $n \times 1$ de 1's associados ao termo constante (α), X_{it} é uma matriz $n \times k$ de observações sobre k variáveis exógenas cujos valores variam ao longo das unidades i transversais e do tempo t , W é a matriz de vizinhança $n \times n$ (exógena, não negativa), representando os efeitos específicos omitidos de cada localidade, u_{it} é um vetor $n \times 1$ de ruídos, ν_{it} , μ_i e τ_t são vetores $n \times 1$ de ruídos brancos i.i.d., com ν_{it} denotando os erros estocásticos e μ_i e τ_t podendo representar tanto efeitos fixos como aleatórios para indivíduos e tempo. β e θ são vetores $k \times 1$ de parâmetros, e α , ρ e λ

são escalares. ρ determina a força do *lag* espacial da variável dependente, mede a influência dos valores vizinhos nas variáveis independentes e λ é responsável por filtrar a dependência espacial no termo residual, contabilizando os efeitos globais. Este modelo assume que a matriz W é invariante ao longo do tempo, em um painel balanceado.

De acordo com Kubara e Kopczewska (2023), as especificações dos modelos espaciais derivam da introdução de restrições nos parâmetros gerais do modelo espacial. Por exemplo, o modelo autorregressivo espacial (SAR) tem apenas ρ como parâmetro restante, enquanto o modelo de erro espacial (SEM) tem apenas o parâmetro λ . Já o modelo autorregressivo espacial com erro de correlação (SARAR) combina ambos os parâmetros.

A matriz de vizinhança pode ser construída de diversas maneiras (Anselin 1988). Neste trabalho foram testadas quatro matrizes de vizinhança obtidas por diferentes métodos: determinado número de vizinhos mais próximos, vizinhos dentro de uma distância máxima, vizinhos por periferia *rook* e vizinhos por periferia *queen*. Essas quatro formas são adequadas para dados espaciais expressos por polígonos no mapa (Anselin 1988), como é o caso da base trabalhada neste artigo, já que os dados de sinistro coletados são agrupados por UF. Para o caso do número de vizinhos e distância, foram testados diferentes valores até encontrar um ponto ótimo (onde todas as unidades possuíssem ao menos um vizinho e os resultados dos Testes Multiplicadores de Lagrange fossem mais significativos, com o mínimo custo computacional possível), que seriam então comparados às matrizes *queen* e *rook*, sendo que foram escolhidos 3 vizinhos mais próximos (3-knn) e 855 Km de distância.

Anselin (1988) indica que os modelos espaciais podem ser mais facilmente estimados partindo-se do modelo de mínimos quadrados ordinário (OLS) e testando a inclusão dos diferentes efeitos espaciais (θ , ρ ou λ). Assim, primeiramente foi estimado o melhor modelo OLS, depois testou-se a existência de interação espacial nos dados pela aplicação de Multiplicadores de Lagrange (LM) nos resíduos do OLS (Florax, Folmer, and Rey 2003).

Para a realização dos testes LM, é necessário definir a matriz de vizinhança que representa a relação espacial a ser testada. A matriz de ponderação ótima foi selecionada pela regressão do modelo espacial mais simples pos-



sível (o SLX, que é o OLS acrescido do *lag* espacial – parâmetro θ – nas variáveis independentes) com as diferentes matrizes de vizinhança, e foi escolhida a matriz cuja regressão apresentava o menor *Akaike Information Criterion* (AIC), como recomendado por Kubara e Kopczewska (2023).

Os testes LM indicam também a natureza da relação espacial, caso ela seja significativa (ou seja, aponta-se se a relação é significante na parcela autoregressiva ou no erro ou em ambos). Dessa forma, esses testes também servem de base para quais modelos devem ser avaliados (SAR e SDM, SEM e SDEM ou SARAR) para além do SLX.

Assim, o fluxo metodológico é o seguinte: 1. tratamento dos dados; 2. estimação do melhor OLS; 3. construção das matrizes de vizinhança; 4. realização dos testes LM e modelagem do SLX para as diferentes matrizes; 5. decisão por seguir ou não com a modelagem espacial e definição da matriz de vizinhança a partir dos resultados anteriores; 6. regressão dos diferentes modelos espaciais possíveis apontados pelos testes LM com a matriz de vizinhança escolhida.

3.3. Análise Descritiva dos Dados

A Figura 1 indica a distribuição de todas as estações meteorológicas cujos dados foram utilizados nesse trabalho. Nota-se que a densidade de estações meteorológicas não é uniforme em todo o território brasileiro, com forte concentração nas regiões litorâneas e nas regiões Sul e Sudeste. Comparando a distribuição das estações meteorológicas com os dados de prêmios emitidos e sinistros diretos (Figura 3), percebe-se que os estados com maior participação no mercado nacional de seguros agrícolas (Rio Grande do Sul, Paraná, São Paulo, Mato Grosso, Mato Grosso do Sul e Goiás) são monitorados climaticamente em toda sua extensão, o que assegura a qualidade da modelagem espacial, dado que as variáveis preditoras encontram-se em proximidade à variável dependente (sinistros) para a maior parte da base de dados.

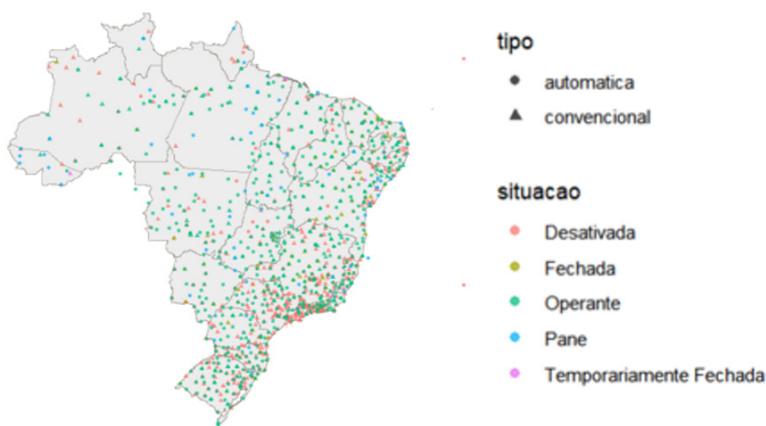


Figura 1 - Distribuição das estações meteorológicas do INMET

Nota: o mapa apresenta as 1260 estações existentes e sua situação no final de 2023 (659 estavam em estado operante). Estações automáticas (602, sendo 507 operantes) coletam dados de forma contínua e os transmitem diretamente para os servidores de processamento. Estações convencionais (658, sendo 152 operantes) coletam os dados em horários fixos, 3 vezes ao dia, e necessitam de um observador que leia os dados registrados nos equipamentos.

Fonte: elaboração própria.

A Figura 2 mostra dados climáticos históricos médios de todo o território brasileiro (entre 2006 e 2023), agrupados por UF. Percebe-se que temperaturas elevadas são comuns no Brasil como um todo, com os estados da região sul apresentando menores temperaturas e menor amplitude média histórica, como é esperado dado o clima dessa região em relação às outras. Observa-se também que a precipitação, umidade e insolação são variáveis que apresentam considerável variabilidade entre as UFs.

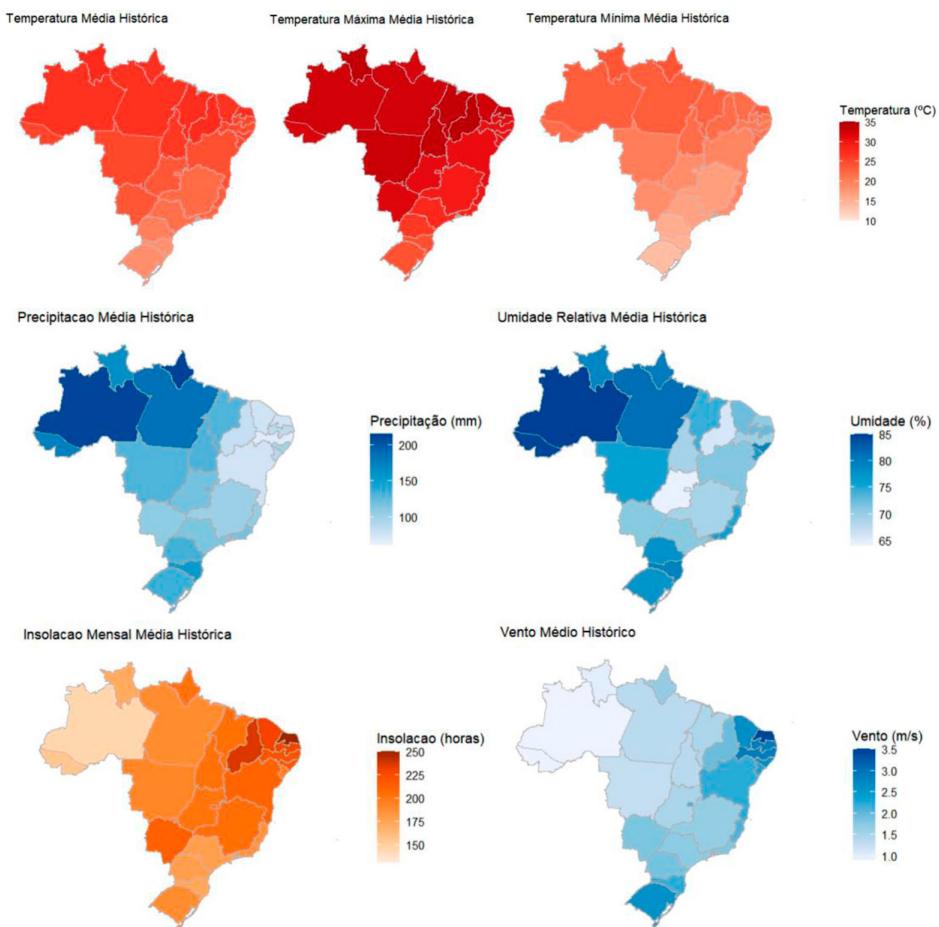


Figura 2 - Dados climáticos médios históricos

Fonte: elaboração própria.

A Figura 3 indica os prêmios totais emitidos e os sinistros diretos registrados por UF entre janeiro/2006 e agosto/2023, mostrando a forte concentração de emissões nos estados do Rio Grande do Sul, Paraná e São Paulo, e emissões menores nos estados do Mato Grosso do Sul, Goiás, Mato Grosso e Minas Gerais, com os outros estados tendo participações bastante inferiores nas emissões de prêmios. Para os sinistros ocorridos percebe-se o mesmo padrão de distribuição. Tais dados indicam forte concentração espacial das carteiras de seguros agrícolas no Brasil, tornando-as

extremamente suscetíveis a eventos climáticos, mesmo que tais eventos não ocorram de forma ampla em todo o território nacional. Essa relação de dependência será explicitada pelos modelos econométricos, ao relacionar a ocorrência de condições climáticas específicas com os dados de sinistros. Dada a alta concentração das carteiras de seguro agrícola, mesmo que um evento climático seja restrito a apenas uma UF, podem ocorrer impactos catastróficos no portfólio como um todo.

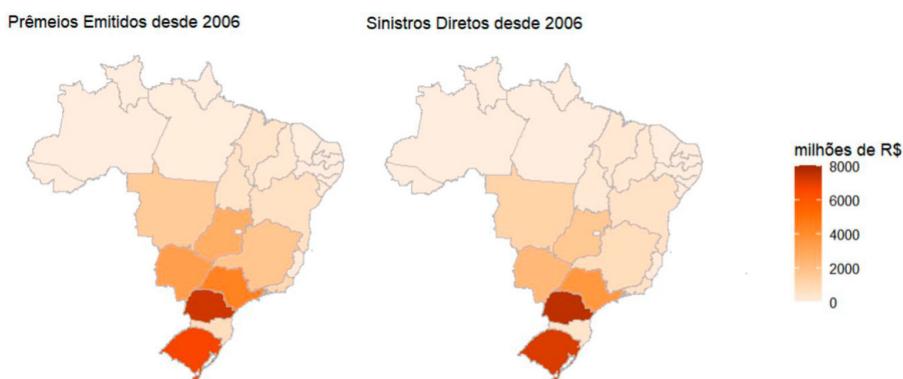


Figura 3 - Prêmios emitidos e sinistros diretos para seguros agrícolas no Brasil

Nota. Compreende os ramos 1101, 1102 e 1161 da SUSEP.
Fonte: elaboração própria.

4. Resultados e Discussões

4.1. Análises Espaciais

A Tabela 1 apresenta o modelo obtido por regressão simples pelo método dos Mínimos quadrados ordinários (OLS) que foi utilizado como modelo base para as análises espaciais. É possível perceber que todas as variáveis climáticas apresentadas contribuem, considerando um nível de significância de 5%, para o montante de sinistros diretos (variável dependente).

Tabela 1 - Coeficientes do modelo de regressão em painel (OLS)

Variável	Coeficiente	Erro Padrão	Valor p
Precipitação	113.347,5	46.660,2	0,015
Temp. Média	-12.470.977,8	2.013.619,3	<0,001
Temp. Mínima	2.151.689,4	711.651,1	0,003
Temp. Máxima	-2.308.240,8	1.040.074,1	0,027
Umidade	-4.242.107,2	633.539,2	<0,001
Vento Médio	-78.448.660,4	14.133.913,4	<0,001
Precipitação*Temp. Mínima	-4.964,6	2.139,1	0,020
Vento Médio*Temp. Máxima	1.870.261,5	321.245,3	<0,001
Temp. Média*Umidade	140.694,9	22.702,9	<0,001
Umidade*Vento Médio	186.808,0	93.529,5	0,046
AIC		204243,1	
BIC		204315,8	
Teste de Hausman (Efeitos Fixos x Aleatórios)		Efeitos Fixos	<0,001
Teste de Hausman (Efeitos Fixos x Pooling)		Efeitos Fixos	<0,001

Fonte: Elaboração própria.

O impacto das variáveis interagidas é especialmente interessante, pois elas podem ser interpretadas como eventos climáticos específicos que frequentemente estão associados à ocorrência de sinistros (Getirana, Libonati, and Cataldi 2021; Son et al. 2021; Mota, Miquelluti, and Ozaki 2020).

A interação entre *Precipitação* e *Temperatura Mínima* pode indicar geadas principalmente quando essa interação apresenta valores baixos devido à baixa temperatura e/ou baixo índice de precipitação, de forma que quanto menor o valor da interação, mais ela é representativa de um evento de geada e mais sinistros resultam deste evento (Bootsma 1976). Já a interação entre *Temperatura Média* e *Umidade* pode apontar eventos extremos de seca ou excesso de chuvas, assim como a interação entre *Vento* e *Umidade*, que pode representar efeitos de monções e massas de ar (Getirana, Libonati, and Cataldi 2021). A interação entre *Vento* e *Temperatura Máxima* pode representar eventos de seca e incêndios, que podem se alastrar rapidamente com os ventos (Son et al. 2021; Fonseca et al. 2019). Para essas interações, os coeficientes diretamente proporcionais ao valor dos sinistros são esperados, seja pelas temperaturas intensas das secas ou pela umidade extrema de eventos como excesso de chuvas. Os coeficientes negativos das variáveis climáticas isoladas são atenuados pelos efeitos interativos.

Este modelo isoladamente já aponta a existência de uma relação entre as condições climáticas e os sinistros agrícolas, mas sua precisão pode ser melhorada com a inclusão dos componentes que capturam relações espaciais.

Para a análise espacial, quatro diferentes matrizes de vizinhança entre as UFs brasileiras foram geradas, sendo elas: 3 vizinhos (3-knn), distância de 855km, *rook* e *queen*. A matriz 3-knn considerou como região de vizinhança as 3 UFs mais próximas. A matriz de distância considerou todos os estados cujo centro geográfico esteja dentro do raio de 855km a partir do centro geográfico da UF de referência. A matriz *rook* considerou como vizinhas as UFs que compartilham uma mesma fronteira e a matriz *queen* considerou as UFs que compartilhem a mesma fronteira ou um mesmo vértice.

Para cada uma das matrizes de vizinhança foram realizados testes LM utilizando o modelo OLS obtido (Tabela 2). Com exceção do teste robusto para *lags* de erros (RLM error) para a matriz de distância, todos os testes indicaram a relevância de efeitos espaciais para a modelagem. Desta forma, seguimos com a modelagem espacial, determinando a matriz de vizinhança que seria utilizada a partir dos resultados dos modelos de *Lag Espacial sobre X* (SLX), que foram estimados para cada uma das matrizes, conforme descrito na seção 3.2.

Tabela 2 - Testes de multiplicadores de Lagrange

	Matriz 3-knn	Matriz 855km dist.	Matriz <i>rook</i>	Matriz <i>queen</i>
LM lag	980,58	346,49	288,81	288,81
p-value	<0,001	<0,001	<0,001	<0,001
LM error	944,65	351,83	274,6	274,6
p-value	<0,001	<0,001	<0,001	<0,001
RLM lag	42.437	0,27982	24.561	24.561
p-value	<0,001	0,5968	<0,001	<0,001
RLM error	6.515	56.146	10.352	10.352
p-value	0,0107	0,01781	0,001	0,001

Fonte: elaboração própria.

Comparando os modelos estimado por SLX (Tabela 3), a matriz de vizinhança por distância apresentou os melhores valores tanto pelo critério AIC como pelo BIC. Assim, a matriz de vizinhança por distância foi utilizada para as análises espaciais.



Tabela 3 - Modelos obtidos pelo método SLX utilizando-se cada uma das matrizes de vizinhança

	Matriz 3-knn		Matriz 855km dist.		Matriz rook		Matriz queen	
	Coefficiente	Valor p	Coefficiente	Valor p	Coefficiente	Valor p	Coefficiente	Valor p
Precipitação	92,56 (53.747)	0,999	107.140 (50.053)	0,032	87.586 (48.350)	0,070	87.586 (48.350)	0,070
Temp. média	-6.595.100 (2.363.800)	<0,001	-6.352.800 (2.145.200)	0,003	-5.560.600 (2.235.200)	0,013	-5.560.600 (2.235.200)	0,013
Umidade	-3.118.400 (779.720)	<0,001	-2.672.800 (675.470)	<0,001	-2.560.200 (697.050.)	<0,001	-2.560.200 (697.050)	<0,001
Vento médio	-71.848.000 (16.122.000)	<0,001	-67.954.000 (14.780.000)	<0,001	-53.049.000 (15.305.000)	<0,001	-53.049.000 (15.305.000)	<0,001
Temp. mínima	1.370.200 (771.270)	0,008	1.892.000 (731.080)	0,010	1.959.100, (742.470)	0,008	1.959.100 (742.470)	0,008
Temp. máxima	-3.142.000 (1.177.100)	<0,001	-2.502.700 (1.064.300)	0,019	-1.160.400 (1.119.300)	0,300	-1.160.400 (1.119.300)	0,300
Precipitação(lag)	88.810 (27.061)	0,001	10.877.000 (3.090.900)	<0,001	29.170 (8.479.60)	<0,001	29.170,00 (8.479.60)	<0,001
Temp. média(lag)	-8.546.900 (1.150.200)	<0,001	-2.339.300.000 (246.630.000)	<0,001	-6.521.700 (676.370)	<0,001	-6.521.700 (676.370)	<0,001
Vento médio(lag)	-8.750.700 (8.165.900)	0,284	-2.831.900.000 (532.200.000)	<0,001	-3.345.600 (1.502.600)	0,026	-3.345.600 (1.502.600)	0,026
Temp. mínima(lag)	2.857.900 (422.640)	<0,001	859.470.000 (137.950.000)	<0,001	2.146.200 (353.560)	<0,001	2.146.200 (353.560)	<0,001
Umidade(lag)	-781.170 (378.980)	0,0393	-220.580.000 (41.780.000)	<0,001	-604.920 (121.160)	<0,001	-604.920, (121.160)	<0,001
Temp. máxima(lag)	3.281.000 (602.360)	<0,001	961.470.000 (151.360.000)	<0,001	2.179.400 (417.290)	<0,001	2.179.400 (417.290)	<0,001
Precipitação*Temp. mínima	42,79 (2.442,10)	0,986	-5.088,90 (2.234)	0,023	-3.842,80 (2.177,40)	0,078	-3.842,80 (2.177,40)	0,078
Vento médio*Temp. máxima	1.683.100 (382.600)	<0,001	1.786.600 (340.230)	<0,001	1.256.500,00 (340.990,00)	<0,001	1.256.500 (340.990)	<0,001
Temp. média*Umidade	98.361 (28.446)	<0,001	99.517 (23.326)	<0,001	89.759,00 (24.270,00)	<0,001	89.759 (24.270)	<0,001
Umidade*Vento médio	218.860 (104.040)	0,036	107.220 (100.300)	0,285	129.040,00 (101.250,00)	0,203	129.040 (101.250)	0,203
Precipitação(lag)*Temp.mínima(lag)	-1.207,80 (421,92)	0,004	-19.687.000 (7.566.400)	0,009	-208,37 (71)	0,003	-208,37 (71)	0,003
Vento médio(lag)*Temp. máxima(lag)	53.127 (61.592)	0,388	-33.194.000 (759.510.000)	0,965	7.180,10 (10.055,00)	0,475	7.180,10 (10.055)	0,475
Temp. média(lag)*Umidade(lag)	7.973,90 (4.679,90)	0,089	195.830.000 (77.033.000)	0,011	3.205,70 (718,95)	<0,001	3.205,70 (718,95)	<0,001
Vento medio(lag)*Umidade(lag)	13.357 (18.195)	0,463	2.015.900.000 (402.980.000)	<0,001	4.276,20 (5.234,80)	0,414	4.276,20 (5.234,80)	0,414
R ²	0,053		0,057		0,047		0,047	
R ² Ajustado	0,045		0,049		0,039		0,039	
AIC	204118		204097		204152		204152	
BIC	204257		204236		204290		204290	
n	26		26		26		26	
t	210		210		210		210	

Nota: Valores entre parênteses indicam o erro padrão associado a cada coeficiente.

Fonte: elaboração própria.

Tabela 4 - Estimativas dos coeficientes dos modelos espaciais

	SEM Coeficiente	SAR Coeficiente	SARAR Coeficiente	SDM Coeficiente	SDEM Coeficiente
Precipitação	33.281 (47.098)	57.572 (45.103)	40.119 (46.450)	82.608 ^g (47.867)	74.940 (48.563)
Temp. média	-5.710.560** (2.020.006)	-7.177.599*** (1.928.118)	-5.903.065** (2.005.402)	-4.937.000* (2.030.300)	-5.898.500** (2.091.100)
Umidade	-3.232.110*** (652.439)	-3.269.027*** (605.264)	-3.170.097*** (657.757)	-2.391.100*** (650.280)	-2.438.600*** (677.480)
Vento médio	-68.640.441*** (14.642.518)	-70.649.547*** (14.355.735)	-68.936.595*** (14.580.091)	-61.921.000*** (14.697.000)	-62.160.000*** (14.916.000)
Temp. mínima	1.216.208 ^g (694.845)	2.055.973** (687.137)	1.427.417* (693.925)	2.170.600** (703.300)	2.847.900*** (710.720)
Temp. máxima	-4.032.417*** (1.067.448)	-3.687.690*** (1.057.265.50)	-4.005.016*** (1.065.497)	-2.157.600* (1.082.300)	-1.823.900 (1.109.500)
Precipitação*Temp. mínima	-1.557 (2.141)	-2.571 (2.059)	-1.844 (2.116)	-4.103 ^g (2.146)	-3.686 ^g (2.188)
Vento médio*Temp. máxima	1.591.686*** (336.035)	1.664.669** (327.328)	1.613.099*** (333.246)	1.384.100*** (337.290)	1.382.400*** (345.270)
Temp. média*Umidade	99.115*** (23.101)	98.480*** (21.621)	96.542** (23.223)	79.803*** (22.241)	78.834*** (23.400)
Umidade*Vento médio	231.430* (93.230)	239.105** (89.905)	231.029* (92.314)	221.010* (97.046)	234.610* (96.656)
Precipitação(lag)	- -	- -	- (3.065.600)	7.481.300* (3.214.600)	7.127.600* (3.214.600)
Temp. média(lag)	- -	- -	- (255.100.000)	-2.775.000.000*** (279.780.000)	-3.081.900.000*** (279.780.000)
Umidade(lag)	- -	- -	- (39.850.000)	-207.290.000** (43.649.000)	-234.460.000*** (43.649.000)
Vento médio(lag)	- -	- -	- (570.940.000)	-1.267.200.000* (593.750.000)	-1.685.900.000** (593.750.000)
Temp. mínima(lag)	- -	- -	- (143.160.000)	1.260.800.000*** (159.950.000)	1.430.800.000*** (159.950.000)
Temp. máxima(lag)	- -	- -	- (166.510.000)	1.091.900.000*** (187.790.000)	1.235.000.000*** (187.790.000)
Precipitação(lag)*Temp. mínima(lag)	- -	- -	- (7.532.100)	-12.084.000 (8.499.100)	-10.696.000 (8.499.100)
Vento médio(lag)*Temp. máxima(lag)	- -	- -	- (763.530.000)	-707.230.000 (847.840.000)	-907.370.000 (847.840.000)
Temp. média(lag)*Umidade(lag)	- -	- -	- (73.960.000)	147.330.000* (84.962.000)	156.770.000 ^g (84.962.000)
Umidade(lag)*Vento médio(lag)	- -	- -	- (401.750.000)	1.267.500.000** (451.080.000)	1.653.200.000*** (451.080.000)
AIC	203.669	203.362	203.462	203.203	203.430
BIC	203.749	203.442	203.548	203.348	203.575
λ	23,72**	-	14,23	-	20,50***
ρ	-	23,57***	14,95	20,62***	-

Nota: os erros-padrão estão entre parênteses. Os níveis de significância são: ***p<0.001; **p<0.01; *p<0.05; ^gp<0.1, respectivamente. Fonte: elaboração própria.



A Tabela 4 mostra cinco modelos espaciais obtidos pelos métodos de Modelo Espacial sobre Erros (SEM), modelo Espacial Autorregressivo (SAR), modelo Espacial Autorregressivo com estrutura autorregressiva adicional sobre o erro (SARAR), Modelo Espacial de Durbin (SDM) e Modelo Espacial de Durbin sobre o Erro (SDEM). Comparando os AIC e BIC, o modelo SDM apresenta-se como o melhor dentre os cinco. Entretanto, nota-se que os cinco modelos mostram comportamento bastante semelhante para as variáveis climáticas estudadas.

Pelos testes LM, tanto o componente autorregressivo (modelos SAR ou SDM) quanto o termo de erro (modelos SEM ou SDEM) apresentaram parâmetros significantes, indicando a existência de efeitos espaciais no modelo. O modelo SARAR, por sua vez, não apresenta significância nos parâmetros espaciais, sugerindo que, ao incluir a estrutura de vizinhança tanto na variável dependente (SAR) como no erro (SEM), esses efeitos espaciais se anulam.

O modelo espacial com melhor ajuste foi o SDM, que capta dependências espaciais (ρ) e *spillovers* (XW). Simplificando as equações 2 e 3, esse modelo pode ser representado como:

$$y_{it} = \rho W y_{it} + \alpha \iota_n + X_{it}\beta + W X_{it}\theta + \tau_t + v_{it} \quad (4)$$

Assim, há evidências de que os valores de sinistros dos estados vizinhos afetam o sinistro de um estado específico, assim como as variáveis independentes medidas nos estados vizinhos também afetam o sinistro do estado observado. Como exemplo, eventos de seca em um determinado estado poderiam provocar a diminuição dos níveis de reservatórios de água e de rios que são utilizados para irrigação de plantações em outros estados, principalmente em casos cujas nascentes se localizam fora do estado onde a plantação é realizada.

Quanto aos impactos das variáveis explicativas, nos cinco modelos apresentados na Tabela 4, os efeitos da precipitação não foram estatisticamente significantes ao nível de 5%, indicando que esta variável pode ter baixa relevância direta em relação ao montante de sinistros, não sendo, portanto, uma boa variável preditiva de sinistros diretos. Uma possível explicação para isso pode ser o efeito da irrigação artificial presente nas grandes produções, tornando os cultivos menos suscetíveis a pequenos períodos de seca. O segundo pode estar relacionado ao programa ZARC do governo

federal, que indica, de forma preditiva, as melhores épocas para o plantio de cada uma das culturas para diversas regiões geográficas.

A precipitação torna-se significante quando analisada espacialmente em relação às UFs vizinhas (i.e., precipitação-lag), sugerindo que se trata de uma variável de sinalizadora de efeitos indiretos, de modo que é causadora de sinistros apenas em caso de abundância. Neste caso, causa enchentes e alagamentos.

Em contrapartida, a umidade se mostrou fortemente significante, indicando que esta é uma variável com bom poder preditivo dos montantes de sinistros. A Figura 4 apresenta, para as três principais UFs do mercado de seguros agrícolas, o nível de umidade relativa do ar e o montante de sinistros diretos entre 2006-2023, apontando a forte seca registrada em 2020/2021 (Getirana, Libonati, and Cataldi 2021) acompanhada por grande aumento dos sinistros.

Nota-se também que a ocorrência concomitante de vento médio e temperatura máxima em altas magnitudes relaciona-se com aumentos de sinistros. Isso pode estar associado à maior probabilidade de incêndios nas plantações (Son et al. 2021; Fonseca et al. 2019). Adicionalmente, Son et al. (2021) argumentam que as alterações de temperatura relacionadas aos eventos de mudanças climáticas podem elevar a frequência de incêndios em plantações.

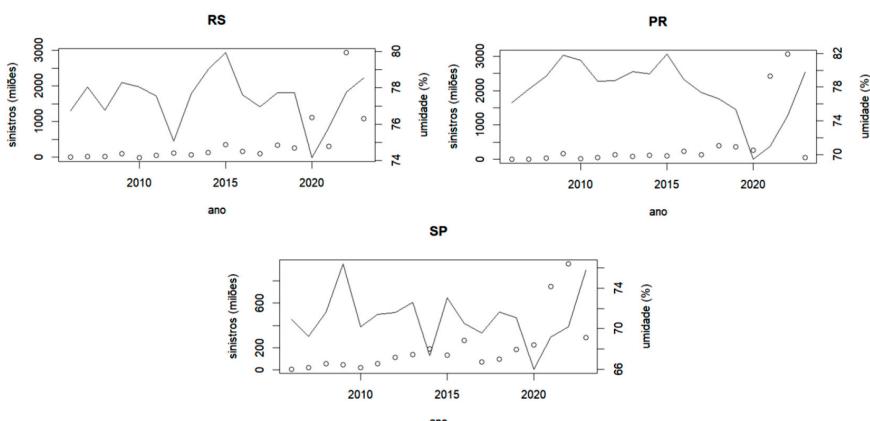


Figura 4 - Sinistros diretos e umidade por ano, nos três principais estados brasileiros em relação a prêmios emitidos

Fonte: elaboração própria.

As estimativas apontam que a *temperatura mínima média* exerce efeito estatisticamente significante nos sinistros diretos ($\beta = 2.170.600, p < 0,001$). Tal variável pode ser uma boa preditora de eventos de geada (Bootsma 1976), principalmente quando avaliada em conjunto com a *umidade relativa* ($\beta = -2.391.100, p < 0,001$) e a presença de *ventos fortes* ($\beta = -61.921.000,00, p < 0,001$). No Brasil, há evidências de que a geada é um dos principais causadores de sinistros em culturas importantes: milho de segunda safra, trigo e uva (Braga *et al.* 2021). E essas culturas estão localizadas (i.e., situadas entre o sul do Paraná e o norte do Rio Grande do Sul, principalmente nos municípios de maior altitude) justamente onde há o maior risco de ocorrência de geadas (Wrege *et al.* 2018). Segundo Braga *et al.* (2021), duas situações podem levar a sinistros por geadas, uma relacionada a baixas temperaturas (geada branca) e outra relacionada com a combinação entre baixas temperaturas, vento e baixa umidade (geada negra). *Caeteris paribus*, a variação de uma unidade na combinação entre baixa umidade e baixa temperatura (geada negra) pode levar a um aumento de sinistros da ordem de R\$80 milhões ($\beta = 79.803, p < 0,001$), enquanto a variação de uma unidade na combinação entre alta umidade e ventos fortes pode aumentar os sinistros na ordem de R\$220 milhões ($\beta = 221.010, p < 0,05$).

Quando são avaliados fatores ligados à *seca* (evento relevante causador de sinistros agrícolas), é comum utilizar a precipitação para o cálculo de índices climáticos para a precificação de seguros (Miquelluti, Ozaki, and Miquelluti 2022; Abrego-Perez and Valencia-Arboleda 2023). Entretanto, o modelo SDM aqui estimado indica que a *umidade* exerce efeito significante sobre os sinistros diretos ($\beta = -2.391.100, p < 0,001$), enquanto a *precipitação* é pouco significante estatisticamente ($\beta = 82.608, p < 0,1$). Isso indica que a *umidade* pode ser uma variável mais importante para o cálculo de índices climáticos, em detrimento da (ou em conjunto com a) *precipitação*. Tal resultado pode ser pouco frequente na literatura, mas não é inédito. A precipitação acumulada pode não refletir adequadamente o estresse hídrico das culturas ao longo do tempo, enquanto que níveis de umidade (principalmente quando associados a altas temperaturas) refletem melhor, a longo prazo, dinâmicas de evapotranspiração e a retenção de água no solo, servindo como indicativo de secas (Zhang *et al.* 2021; A. P. Martins *et al.* 2016). Nesse sentido, Rattis *et al.* (2021) sugerem que o aumento de eventos de baixa umidade relativa do ar no Brasil pode estar revertendo parte dos ganhos com a intensificação da produção agrícola observada desde 1980. Ressaltamos, entretanto, que esse resultado também

pode derivar de uma limitação deste trabalho dada a distribuição desigual das estações meteorológicas no Brasil, que pode impactar a precisão da modelagem para regiões com menor cobertura.

A Tabela 5 indica os efeitos diretos e indiretos que as variáveis climáticas de uma UF exercem sobre o sinistro direto estimado. Percebe-se que o efeito indireto supera o efeito direto em muitas ordens de grandeza, o que pode indicar que os efeitos climáticos não ficam restritos às áreas geográficas de uma só UF, afetando concomitantemente diversos UFs.

Tabela 5 - Efeitos diretos e indiretos sobre cada variável climática presente no modelo SDM.

Variável	Direto	Indireto	Total
Precipitação	8,26x10^04	1,13x10^43	1,13x10^43
Temp. média	-4,94x10^06	-6,77x10^44	-6,77x10^44
Umidade	-2,39x10^06	-3,28x10^44	-3,28x10^44
Vento médio	-6,19x10^07	-8,50x10^45	-8,50x10^45
Temp. mínima	2,17x10^06	2,98x10^44	2,98x10^44
Temp. máxima	-2,16x10^06	-2,96x10^44	-2,96x10^44
Precipitação*Temp. mínima	-4,10x10^03	-5,63x10^41	-5,63x10^41
Vento médio*Temp. máxima	1,38x10^06	1,90x10^44	1,90x10^44
Temp. média*Umidade	7,98x10^04	1,09x10^43	1,09x10^43
Umidade*Vento médio	2,21x10^05	3,03x10^43	3,03x10^43
Precipitação(lag)	7,48x10^06	1,03x10^45	1,03x10^45
Temp. média(lag)	-2,78x10^09	-3,81x10^47	-3,81x10^47
Umidade lag)	-2,07x10^08	-2,84x10^46	-2,84x10^46
Vento médio(lag)	-1,27x10^09	-1,74x10^47	-1,74x10^47
Temp. mínima(lag)	1,26x10^09	1,73x10^47	1,73x10^47
Temp. máxima(lag)	1,09x10^09	1,50x10^47	1,50x10^47
Precipitação(lag)*Temp. mínima(lag)	-1,21x10^07	-1,66x10^45	-1,66x10^45
Vento médio(lag)*Temp. máxima(lag)	-7,07x10^08	-9,70x10^46	-9,70x10^46
Temp. média(lag)*Umidade(lag)	1,47x10^08	2,02x10^46	2,02x10^46
Umidade(lag)*Vento médio(lag)	1,27x10^09	1,74x10^47	1,74x10^47

Fonte: elaboração própria.

A forte concentração geográfica das carteiras de seguro agrícola, quando combinada com os resultados do modelo espacial, alerta para grandes potenciais de risco catastrófico, pois o efeito nos sinistros em uma UF está sujeito não só às ocorrências climáticas naquela região, mas também em seu entorno, já que os eventos causadores podem se espalhar (e.g., incêndios) entre unidades vizinhas. Assim, o risco deveria ser pulverizado diversificando as localidades (e as culturas) das apólices nas carteiras. Essa

concentração espacial é um indicador do porquê carteiras agrícolas em geral apresentam alta sinistralidade no Brasil (Euphasio Junior and Carvalho 2022). Para além da diversificação do risco, técnicas modernas de agricultura podem ser incentivadas, reduzindo o impacto de determinadas variáveis climáticas sobre as plantações, como é o caso da irrigação, que reduz o efeito das secas.

5. Considerações Finais

Neste trabalho buscou-se encontrar os fatores climáticos explicativos de indenizações pagos em seguros agrícolas no Brasil usando métodos de econometria espacial. Inicialmente, foi possível perceber que existe uma forte concentração das carteiras de seguros em poucas UFs do país, todas muito próximas entre si. Adicionalmente à essa concentração, eventos climáticos extremos constituem-se em riscos fundamentais (i.e., atingindo muitas unidades simultaneamente expostas), podendo atingir grandes regiões geográficas.

Tal concentração, por si só, é um fator de risco relevante não apenas para o mercado de seguros agrícolas, mas também para toda a economia brasileira, cujo PIB é fortemente dependente do setor agrícola. Assim, o país poderia se beneficiar de políticas públicas que incentivasse uma maior dispersão da produção agrícola por seu território.

Analizando os modelos espaciais estimados, todos são consistentes ao apontar que as variáveis climáticas estão fortemente associadas aos sinistros. Em particular, a precipitação não apresenta efeito significante diretamente, apenas quando afeta simultaneamente múltiplos vizinhos, indicando enxentes e alagamentos. Mas a força do vento e a umidade (indicador principal de secas, se baixo, e de geadas, se elevadas e na presença de baixas temperaturas) são fatores relevantes para explicar os sinistros. Estes resultados encontram respaldo na literatura (Getirana, Libonati, and Cataldi 2021; Son *et al.* 2021; Mota, Miquelluti, and Ozaki 2020).

Os achados desta pesquisa podem beneficiar seguradoras e resseguradoras ao fornecer uma compreensão mais precisa dos riscos climáticos e sua distribuição espacial, permitindo uma melhor especificação e diversificação dos portfólios de seguros agrícolas. Além disso, formuladores de políticas públicas podem utilizar os resultados para incentivar a dispersão da produção agrícola e reduzir a vulnerabilidade econômica do setor. Agricultores tam-

bém podem se beneficiar de produtos de apólices de seguro mais viáveis, enquanto as instituições financeiras podem tomar decisões mais embasadas sobre alocação de recursos no agronegócio.

Esse trabalho não é imune a limitações. A distribuição desigual das estações meteorológicas no Brasil pode impactar a precisão da modelagem para regiões com menor cobertura (ainda que essas regiões sejam também as de menor representatividade nas carteiras seguradas). A estrutura de dependência espacial está suposta estacionária, de modo que se está supondo que os efeitos do clima sobre os sinistros são os mesmos entre 2006-2023. Para estudos futuros, sugere-se estender os modelos aqui estimados incorporando a dinâmica temporal nos modelos espaciais, capturando os crescentes efeitos das alterações climáticas. Ademais, pode-se comparar as estimativas aqui obtidas com modelos de cúpulas espaciais, uma vertente que tem ganhado crescente relevância na literatura.

Referências

- Abrego-Perez, Adriana, and Carlos Felipe Valencia-Arboleda. 2023. “A Drought Index as a Way to Improve Hedging Effectiveness for Copula Insurance Models.” *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4353828>.
- Adhikari, Shyam, Eric J. Belasco, and Thomas O. Knight. 2010. “Spatial Producer Heterogeneity in Crop Insurance Product Decisions within Major Corn Producing States.” *Agricultural Finance Review* 70 (1): 66–78. <https://doi.org/10.1108/00021461011042648>.
- Anselin, Luc. 1988. *Spatial Econometrics: Methods and Models*. Kluwer Academic Publishers, Deodrecht.
- Bootsma, A. 1976. “Estimating Minimum Temperature and Climatological Freeze Risk in Hilly Terrain.” *Agricultural Meteorology* 16 (3): 425–43. [https://doi.org/10.1016/0002-1571\(76\)90010-8](https://doi.org/10.1016/0002-1571(76)90010-8).
- Braga, Gustavo Bastos, Hewlley Maria Acioli Imbuzeiro, Gabrielle Ferreira Pires, Lais Rosa de Oliveira, Rodney Alves Barbosa, and Katia de Fatima Vilela. 2021. “Frost Risk and Rural Insurance in Brazil.” *Revista Brasileira de Meteorologia* 36 (4): 703–11. <https://doi.org/10.1590/0102-7786360137>.
- Brás, Teresa Armada, Júlia Seixas, Nuno Carvalhais, and Jonas Jägermeyr. 2021. “Severity of Drought and Heatwave Crop Losses Tripled over the Last Five Decades in Europe.” *Environmental Research Letters* 16 (6): 065012. <https://doi.org/10.1088/1748-9326/abf004>.
- Brasil. 2021. *Histórico de Perdas Na Agricultura Brasileira*. Ministério da Agricultura, Pecuária e Abastecimento - Secretaria de Política Agrícola.
- Buainain, Antônio Márcio, Carlos A M Santana, Felipe Prince Silva, Junior Ruiz Garcia, and Pedro Loyola. 2014. “O Tripé Da Política Agrícola Brasileira Crédito Rural, Seguro e Pronaf.” In *O Mundo Rural No Brasil Do Século 21: A Formação de Um Novo Padrão Agrário e Agrícola*. 1ed. Brasília/DF: Embrapa Informação Tecnológica. <https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/seguro-rural/observatorio-do-seguro-rural/estudos/estudos-2014/2014-antonio-marcio-buainain-o-tripe-da-politica-agricola-brasileira-credito-rural-seguro-e-pronaf.pdf>.



- Carvalho, João Vinícius França, and Acássio Silva Guimarães. 2024. "Systemic Risk Assessment Using Complex Networks Approach: Evidence from the Brazilian (Re)Insurance Market." *Research in International Business and Finance* 67 (January):102065. <https://doi.org/10.1016/j.ribaf.2023.102065>.
- Cerqueti, Roy, Paolo Maranzano, and Raffaele Mattera. 2024. "Spatially-Clustered Spatial Autoregressive Models with Application to Agricultural Market Concentration in Europe." *Journal of Agricultural, Biological, and Environmental Statistics*, July. <https://doi.org/10.1007/s13253-024-00672-4>.
- Chang, Jen-Hu. 1977. "Tropical Agriculture: Crop Diversity and Crop Yields." *Economic Geography* 53 (3): 241. <https://doi.org/10.2307/143190>.
- Dal Pozzo, Beatriz Salandin, André Luis Zorzi, and Vitor Augusto Ozaki. 2025. "Seguro Agrícola Na Lavoura de Soja: Fatores de Impacto Nos Resultados Das Seguradoras." *Revista de Economia e Sociologia Rural* 63. <https://doi.org/10.1590/1806-9479.2025.284948>.
- Embrechts, Paul, Alexander J. McNeil, and Daniel Straumann. 2002. "Correlation and Dependence in Risk Management: Properties and Pitfalls." In *Risk Management*, 176–223. Cambridge University Press. <https://doi.org/10.1017/CBO9780511615337.008>.
- Euphasio Junior, Jorge Wilson, and João Vinícius França Carvalho. 2022. "Reinsurance and Solvency Capital: Mitigating Insurance Companies' Ruin Probability." *Revista de Administração Contemporânea* 26 (1). <https://doi.org/10.1590/1982-7849rac2022200191.en>.
- FAO. 2023. *The Impact of Disasters on Agriculture and Food Security 2023*. Rome, Italy: FAO, United Nations. <https://doi.org/10.4060/cc7900en>.
- Florax, Raymond J.G.M., Hendrik Folmer, and Sergio J. Rey. 2003. "Specification Searches in Spatial Econometrics: The Relevance of Hendry's Methodology." *Regional Science and Urban Economics* 33 (5): 557–79. [https://doi.org/10.1016/S0166-0462\(03\)00002-4](https://doi.org/10.1016/S0166-0462(03)00002-4).
- Fonseca, Marisa Gesteira, Lincoln Muniz Alves, Ana Paula Dutra Aguiar, Egidio Arai, Liana Oighenstein Anderson, Thais Michele Rosan, Yosio Edemir Shimabukuro, and Luiz Eduardo Oliveira Cruz Aragão. 2019. "Effects of Climate and Land-use Change Scenarios on Fire Probability during the 21st Century in the Brazilian Amazon." *Global Change Biology* 25 (9): 2931–46. <https://doi.org/10.1111/gcb.14709>.
- Fonseca, Nathalia Costa, João Vinícius França Carvalho, and Thiago Dutra Araujo. 2024. "When There's No November Rain: Developing a Parametric Insurance for Hydroelectric Energy Generators in Brazil." In *Anais Do 52º Encontro Nacional de Economia*, 1–20.
- Fritzsons, Elenice, Luiz Eduardo Mantovani, and Marcos Silveira Wrege. 2016. "Relação Entre Altitude e Temperatura: Uma Contribuição Ao Zoneamento Climático No Estado de Santa Catarina, Brasil (Relationship between Altitude and Temperature: A Contribution to Climatic Zoning for the State of Santa Catarina, Brazil)." *Revista Brasileira de Climatologia* 18 (July). <https://doi.org/10.5380/abclima.v18i0.39471>.
- Getirana, Augusto, Renata Libonati, and Marcio Cataldi. 2021. "Brazil Is in Water Crisis—It Needs a Drought Plan." *Nature* 600 (7888): 218–20.
- Goodwin, Barry K., and Ashley Hungerford. 2015. "Copula-Based Models of Systemic Risk in U.S. Agriculture: Implications for Crop Insurance and Reinsurance Contracts." *American Journal of Agricultural Economics* 97 (3): 879–96. <https://doi.org/10.1093/ajae/aau086>.
- Goodwin, Barry K., and Nicholas E. Piggott. 2020. "Has Technology Increased Agricultural Yield Risk? Evidence from the Crop Insurance Biotech Endorsement." *American Journal of Agricultural Economics* 102 (5): 1578–97. <https://doi.org/10.1002/ajae.12087>.
- Goodwin, Barry K. 2001. "Problems with Market Insurance in Agriculture." *American Journal of Agricultural Economics* 83 (3): 643–49.
- Guimarães, Thais Camolesi, and Alexandre Toshiro Igari. 2019. "Mudança Do Clima e Seus Impactos No Seguro Agrícola No Brasil." *Revista Em Agronegócio e Meio Ambiente* 12 (4): 1583. <https://doi.org/10.17765/2176-9168.2019v12n4p1583-1604>.

- Hazell, Peter, and Panos Varangis. 2020. "Best Practices for Subsidizing Agricultural Insurance." *Global Food Security* 25 (September 2019): 100326. <https://doi.org/10.1016/j.gfs.2019.100326>.
- Hochman, Zvi, David L Gobbett, and Heidi Horan. 2017. "Climate Trends Account for Stalled Wheat Yields in Australia since 1990." *Global Change Biology* 23 (5): 2071–81. <https://doi.org/10.1111/gcb.13604>.
- IPCC. 2012. "Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaption: Special Report of the Intergovernmental Panel on Climate Change." New York, NY: Cambridge University Press.
- Keljeian, Harry, and Gianfranco Piras. 2017. *Spatial Econometrics*. Academic Press.
- Khan, Majid, and Abdul Rashid. 2022. "(A)Symmetry Effects of Climate Changes on Economic Growth: A Panel Data Analysis." *International Review of Economics* 69 (4): 571–607. <https://doi.org/10.1007/s12232-022-00406-3>.
- Kubara, Maria, and Katarzyna Kopczewska. 2023. "Akaike Information Criterion in Choosing the Optimal K-Nearest Neighbours of the Spatial Weight Matrix." *Spatial Economic Analysis*, 1–19. <https://doi.org/10.1080/17421772.2023.2176539>.
- Lowder, Sarah K, Marco V Sánchez, and Raffaele Bertini. 2019. *Farms, Family Farms, Farmland Distribution and Farm Labour What Do We Know Today?* Rome: Food and Agriculture Organization of the United Nations.
- Malhi, Gurdeep Singh, Manpreet Kaur, and Prashant Kaushik. 2021. "Impact of Climate Change on Agriculture and Its Mitigation Strategies: A Review." *Sustainability* 13 (3): 1318. <https://doi.org/10.3390/su13031318>.
- Martins, Amanda Posselt, Sérgio Ely Valadão Gigante de Andrade Costa, Ibanor Anghinoni, Taise Robinson Kunrath, Diego Cecagno, José Miguel Reichert, Fabrício Balerini, Lúcia Rebello Dillenburg, and Paulo César de Faccio Carvalho. 2016. "Soil Moisture and Soybean Physiology Affected by Drought in an Integrated Crop-Livestock System." *Pesquisa Agropecuária Brasileira* 51 (8): 978–89. <https://doi.org/10.1590/S0100-204X2016000800010>.
- Martins, Gilson, and Guilherme Signorini. 2025. "Enhancing Crop Insurance Analysis with Agricultural Zoning Data." *Revista de Economia e Sociologia Rural* 63. <https://doi.org/10.1590/1806-9479.2025.284274>.
- Mason, Chuck, Dermot J. Hayes, and Sergio H. Lence. 2003. "Systemic Risk in U.S. Crop Reinsurance Programs." *Agricultural Finance Review* 63 (1): 23–39. <https://doi.org/10.1108/00214980380001139>.
- Mendonça, Walef Machado de, and Patrícia De Siqueira Ramos. 2023. "Spatial Autocorrelation Analysis of Multivariate Rural Insurance Data." *Brazilian Journal of Biometrics* 41 (4): 398–411. <https://doi.org/10.28951/bjb.v41i4.642>.
- Michaelides, Marie, Mélina Mailhot, and Yongkun Li. 2025. "Probabilistic Crop Yields Forecasts With Spatio-Temporal Conditional Copula Using Extreme Weather Covariates," March. <https://arxiv.org/abs/2503.22807v1>.
- Miquelluti, Daniel Lima, Vitor Augusto Ozaki, and David José Miquelluti. 2022. "An Application of Geographically Weighted Quantile Lasso to Weather Index Insurance Design." *Revista de Administração Contemporânea* 26 (3): e200387. <https://doi.org/10.1590/1982-7849rac2022200387.en>.
- Miranda, Mario J., and Joseph W. Glauber. 1997. "Systemic Risk, Reinsurance, and the Failure of Crop Insurance Markets." *American Journal of Agricultural Economics* 79 (1): 206–15. <https://doi.org/10.2307/1243954>.
- Monteleone, Beatrice, Iolanda Borzì, Brunella Bonaccorso, and Mario Martina. 2023. "Quantifying Crop Vulnerability to Weather-Related Extreme Events and Climate Change through Vulnerability Curves." *Natural Hazards* 116 (3): 2761–96. <https://doi.org/10.1007/s11069-022-05791-0>.
- Mota, Arthur Lula, Daniel Lima Miquelluti, and Vitor Augusto Ozaki. 2020. "Predição de Sinistros Agrícolas: Uma Abordagem Comparativa Utilizando Aprendizagem de Máquina." *Economia Aplicada* 24 (4): 533–54. <https://doi.org/10.11606/1980-5330/ea161194>.
- Nguyen-Huy, Thong, Ravinesh C Deo, Shahbaz Mushtaq, Jarrod Kath, and Shahjahan Khan. 2019. "Copula Statistical Models for Analyzing Stochastic Dependencies of Systemic Drought Risk and Potential Adaptation Strategies." *Stochastic Environmental Research and Risk Assessment* 33 (3): 779–99. <https://doi.org/10.1007/s00477-019-01662-6>.
- Okhrin, Ostap, Martin Odening, and Wei Xu. 2013. "Systemic Weather Risk and Crop Insurance: The Case of China." *Journal of Risk and Insurance* 80 (2): 351–72. <https://doi.org/10.1111/j.1539-6975.2012.01476.x>.
- Ozaki, Vitor A. 2007. "O Papel Do Seguro Na Gestão Do Risco Agrícola e Os Empecilhos Para o Seu Desenvolvimento." *Revista Brasileira de Risco e Seguro* 2 (4): 75–92.



- Park, Eunchun, B. Wade Brorsen, and Ardian Harri. 2019. "Using Bayesian Kriging for Spatial Smoothing in Crop Insurance Rating." *American Journal of Agricultural Economics* 101 (1): 330–51. <https://doi.org/10.1093/ajae/ayy045>.
- Phéliblé-Guinvarc'h, Martial V., and Jean E. Cordier. 2006. "A Private Management Strategy for the Crop Yield Insurer: A Theoretical Approach and Tests." *Insurance: Mathematics and Economics* 39 (1): 35–46. <https://doi.org/10.1016/j.inmatheco.2006.01.003>.
- Rattis, Ludmila, Paulo M. Brando, Marcia N. Macedo, Stephanie A. Spera, Andrea D. A. Castanho, Eduardo Q. Marques, Nathane Q. Costa, Divino V. Silverio, and Michael T. Coe. 2021. "Climatic Limit for Agriculture in Brazil." *Nature Climate Change* 11 (12): 1098–1104. <https://doi.org/10.1038/s41558-021-01214-3>.
- Rensi, Rafael Tonet, and João Vinícius França Carvalho. 2023. "De Basileia Para o Campo: Estimando a Estrutura de Dependência de Default Em Portfólios de Crédito Rural Por Meio de Cúpulas." In *Anais: XLVII EnANPAD*, 1–19. São Paulo.
- Salgueiro, Andrea Martínez, and Maria-Antonia Tarazon-Rodon. 2021. "Is Diversification Effective in Reducing the Systemic Risk Implied by a Market for Weather Index-Based Insurance in Spain?" *International Journal of Disaster Risk Reduction* 62 (August):102345. <https://doi.org/10.1016/j.ijdrr.2021.102345>.
- Santana, Carlos A M, Antônio Márcio Buainain, Felipe Prince, Silva Junior Ruiz, and Garcia Pedro Loyola. 2014. "Política Agrícola Avanços e Retrocessos Ao Longo de Uma Trajetória Positiva." In *O Mundo Rural No Brasil Do Século 21: A Formação de Um Novo Padrão Agrário e Agrícola*. 1ed.Brasília/DF: Embrapa Informação Tecnológica. <https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/seguro-rural/observatorio-do-seguro-rural/estudos/estudos-2014/2014-carlos-a-m-santana-politica-agrícola-avancos-e-retrocessos-ao-longo-de-uma-trajetoria-positiva.pdf>.
- Schmitt, Jonas, Frank Offermann, Andreia F.S. Ribeiro, and Robert Finger. 2024. "Drought Risk Management in Agriculture: A Copula Perspective on Crop Diversification." *Agricultural Economics* 55 (5): 823–47. <https://doi.org/10.1111/AGEC.12851>.
- Son, Rackhun, Hyungjun Kim, Shih-Yu (Simon) Wang, Jee-Hoon Jeong, Sung-Ho Woo, Ji-Yoon Jeong, Byung-Doo Lee, et al. 2021. "Changes in Fire Weather Climatology under 1.5 °C and 2.0 °C Warming." *Environmental Research Letters* 16 (3): 034058. <https://doi.org/10.1088/1748-9326/abe675>.
- Su, Yang, Benoit Gabrielle, and David Makowski. 2021. "The Impact of Climate Change on the Productivity of Conservation Agriculture." *Nature Climate Change* 11 (7): 628–33. <https://doi.org/10.1038/s41558-021-01075-w>.
- Sultan, Benjamin, Dimitri Defrance, and Toshichika Iizumi. 2019. "Evidence of Crop Production Losses in West Africa Due to Historical Global Warming in Two Crop Models." *Scientific Reports* 9 (1): 12834. <https://doi.org/10.1038/s41598-019-49167-0>.
- Sun, Yan, and Ke Wang. 2022. "The Implication of Copula-Based Models for Crop Insurance and Reinsurance Under Systemic Risk." *Frontiers in Environmental Science* 10 (July). <https://doi.org/10.3389/fenvs.2022.916494>.
- The World Bank. 2022. "Agriculture, Forestry, and Fishing, Value Added (% of GDP)." 2022.
- Torres, Ronaldo, Carlos José Caetano Bacha, and Luzia Aparecida Antunes. 2024. "Análise Dos Programas Federais de Seguro Rural No Brasil de 2000 a 2022." *Revista de Economia e Sociologia Rural* 62 (3): e281275. <https://doi.org/10.1590/1806-9479.2023.281275>.
- Torres, Ronaldo, André Luis Zorzi, Gabriele Silva Almeida, and Vitor Augusto Ozaki. 2024. "Avaliação Do Seguro Agrícola, Riscos Sistêmicos e Diversificação." *Revista de Economia e Agronegócio* 21 (2): 1–18. <https://doi.org/10.25070/re.a.v21i2.15372>.
- Wang, H Holly, and Hao Zhang. 2003. "On the Possibility of a Private Crop Insurance Market: A Spatial Statistics Approach." *The Journal of Risk and Insurance* 70 (1): 111–24.
- Woodard, Joshua D., and Philip Garcia. 2008. "Basis Risk and Weather Hedging Effectiveness." *Agricultural Finance Review* 68 (1): 99–117. <https://doi.org/10.1108/00214660880001221>.
- Wrege, Marcos Silveira, Elenice Fritzsons, Márcia Toffani Simão Soares, Angélica Prela-Pântano, Silvio Steinmetz, Paulo Henrique Caramori, Bernadete Radin, and Cristina Pandolfo. 2018. "Risco de Ocorrência de

- Geadas Na Região Centro-Sul Do Brasil.” *Revista Brasileira de Climatologia* 22 (June). <https://doi.org/10.5380/abclima.v22i0.57306>.
- Xu, Wei, Guenther Filler, Martin Odening, and Ostap Okhrin. 2010. “On the Systemic Nature of Weather Risk.” *Agricultural Finance Review* 70 (2): 267–84. <https://doi.org/10.1108/00021461011065283>.
- Ye, Tao, Wuyang Hu, Barry J. Barnett, Jiwei Wang, and Yu Gao. 2020. “Area Yield Index Insurance or Farm Yield Crop Insurance? Chinese Perspectives on Farmers’ Welfare and Government Subsidy Effectiveness.” *Journal of Agricultural Economics* 71 (1): 144–64. <https://doi.org/10.1111/1477-9552.12326>.
- Yun, Seong D., and Benjamin M. Gramig. 2022. “Spatial Panel Models of Crop Yield Response to Weather: Econometric Specification Strategies and Prediction Performance.” *Journal of Agricultural and Applied Economics* 54 (1): 53–71. <https://doi.org/10.1017/aae.2021.29>.
- Zhang, Peng, Xin Yang, Yiting Chen, Zhenhua Wei, and Fulai Liu. 2021. “Dissecting the Combined Effects of Air Temperature and Relative Humidity on Water-Use Efficiency of Barley under Drought Stress.” *Journal of Agronomy and Crop Science* 207 (4): 606–17. <https://doi.org/10.1111/JAC.12475>.

DECLARAÇÃO DE DISPONIBILIDADE DE DADOS

Os dados utilizados neste estudo estão disponíveis mediante solicitação ao autor. Dados adicionais e informações complementares também poderão ser fornecidos para fins de verificação ou replicação. A disponibilização está condicionada à inexistência de restrições de acesso público.

AGRADECIMENTOS

- ♦ João Vinícius de França Carvalho agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq – pelo apoio financeiro, por meio da Bolsa de Produtividade em Pesquisa (Processo 305589/2024-5).
- ♦ Nathalia Costa Fonseca agradece à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Capes – pelo apoio financeiro, por meio da Bolsa de Doutorado (Processo 88887.955886/2024-00).

CONTRIBUIÇÕES DE AUTORIA

JC: Conceitualização, Curadoria de dados, Análise formal, Aquisição de financiamento, Investigação, Metodologia, Administração de projetos, Recursos, Programas, Supervisão, Validação, Visualização, Escrita - rascunho original e Escrita - revisão e edição.

NF: Curadoria de dados, Análise formal, Investigação, Metodologia, Recursos, Programas, Validação, Visualização, Escrita - rascunho original e Escrita - revisão e edição.

DB: Curadoria de dados, Análise formal, Investigação, Metodologia, Recursos, Programas, Validação, Visualização, Escrita - rascunho original e Escrita - revisão e edição.

CONFLITO DE INTERESSE

Os autores declaram não terem quaisquer conflitos de interesse.

EDITOR-CHEFE

Dante Mendes Aldrichi  <https://orcid.org/0000-0003-2285-5694>

Professor - Department of Economics University of São Paulo (USP)

EDITOR ASSOCIADO

Rodrigo Lanna Franco da Silveira  <https://orcid.org/0000-0002-1208-5713>

