

INEFICIÊNCIAS REGIONAIS E EXTERNALIDADES DO CRÉDITO RURAL: EVIDÊNCIAS DE MODELOS ESPACIAIS QUANTÍLICOS PARA O BRASIL

2. Análise de dados espaciais e Econometria Espacial

Luís Abel da Silva Filho

Professor do Departamento de Economia da URCA
Pesquisador visitante da DIRUR/IPEA; Pesquisador Associado do NEREUS-USP
luis.abel@urca.br

Pedro Vasconcelos Maia do Amaral

Professor do Centro de Desenvolvimento e Planejamento Regional da Universidade Federal de Minas Gerais – UFMG.
pedroamaral@cedeplar.ufmg.br

RESUMO: Este estudo investiga os impactos do crédito agrícola sobre a produção agropecuária nos municípios brasileiros, considerando as origens e finalidades do financiamento, por meio de uma abordagem econométrica espacial inovadora. Utilizando dados entre 2019 e 2023, a pesquisa aplica o modelo Spatial Durbin Model (SDM), em sua versão tradicional e quantílica, para analisar efeitos diretos e indiretos do crédito sobre o Valor Bruto da Produção Agrícola (VBP), distinguindo entre linhas de custeio e investimento, e entre fontes públicas e privadas de crédito. A análise espacial pelo índice de Moran e LISA confirma padrões de concentração de crédito e produção nas regiões Sul e Centro-Oeste, acentuando as desigualdades regionais. Os resultados evidenciam que o crédito rural exerce influência significativa e heterogênea ao longo da distribuição da produtividade agrícola, com efeitos positivos mais concentrados em municípios de maior desempenho. Além disso, observam-se externalidades espaciais relevantes, especialmente em modalidades de crédito para investimento, revelando efeitos de transbordamento sobre municípios vizinhos. O artigo destaca a importância de políticas públicas direcionadas que considerem os efeitos espaciais do crédito rural, visando à redução das disparidades territoriais e ao fomento de uma agricultura mais equitativa e sustentável.

PALAVRAS-CHAVE: crédito agrícola, produção, econometria espacial.

ABSTRACT: This study examines the impact of agricultural credit on agricultural production in Brazilian municipalities, considering the origins and purposes of financing, using an innovative spatial econometric approach. Using data from 2019 to 2023, the research applies the Spatial Durbin Model (SDM), in its traditional and quantile versions, to analyze the direct and indirect effects of credit on the Gross Value of Agricultural Production (VBP), distinguishing between financing and investment lines, and between public and private sources of credit. The spatial analysis using the Moran index and LISA confirms patterns of credit and production concentration in the South and Central-West regions, accentuating regional inequalities. The results indicate that rural credit has a significant and heterogeneous impact on the distribution of agricultural productivity, with positive effects being more concentrated in higher-performing municipalities. Additionally, relevant spatial externalities are observed, particularly in investment credit modalities, indicating spillover effects on neighboring municipalities. The article emphasizes the importance of targeted public policies that account for the spatial effects of rural credit, aiming to mitigate territorial disparities and foster more equitable and sustainable agricultural practices.

KEYWORDS: agricultural credit, production, spatial econometrics.

JEL: Q00, Q14, Q18.

1. CONSIDERAÇÕES INICIAIS

A agricultura ocupa posição estratégica na economia brasileira, destacando-se como pilar do superávit comercial, do abastecimento alimentar e da geração de empregos (Conceição & Conceição, 2014; Moreira et al., 2016; Azevedo et al., 2023; Ferreira et al., 2024). Esse protagonismo está fortemente condicionado à capacidade de financiamento dos produtores, uma vez que o crédito permite a aquisição de tecnologias, insumos e equipamentos que impulsionam a produtividade e a competitividade do setor (Assunção & Bragança, 2019; Assunção et al., 2020; Pellegrina, 2022; Leite et al., 2023; Rezende & Oliveira, 2021). Dentre os instrumentos de fomento, o crédito rural — seja para custeio, investimento ou comercialização — desempenha papel central, operacionalizado por bancos públicos e privados, pelos Fundos Constitucionais (FNO, FNE, FCO) e pelo BNDES (Souza & Mikio, 2018; Silva Filho et al., 2023; Gasques et al., 2020).

Apesar da importância do crédito agrícola, sua alocação no território nacional segue padrões historicamente concentrados, com forte incidência nas regiões Sul, Sudeste e Centro-Oeste, enquanto o Norte e o Nordeste enfrentam maiores barreiras de acesso devido a entraves institucionais, técnicos e infraestruturais (Santos & Rodrigues, 2021; Souza et al., 2022; Trindade & Cruz, 2019; Zeller & Schiesari, 2020). Tais assimetrias resultam em disparidades produtivas relevantes, limitando a competitividade de grande parte do território e ampliando desigualdades regionais (Borges & Parré, 2022; Silva Filho et al., 2024). Compreender como o crédito influencia a produção agropecuária, portanto, é essencial para subsidiar políticas públicas capazes de promover um desenvolvimento agrícola mais equitativo e territorialmente sensível (World Bank, 2020; FAO, 2021).

Embora a literatura reconheça os efeitos positivos do crédito rural sobre a produtividade, ainda são escassos os estudos que o analisam sob uma perspectiva espacial e condicional, especialmente considerando a origem e o tipo de financiamento (custeio ou investimento). Grande parte dos trabalhos adota modelos econométricos convencionais, que não capturam adequadamente os efeitos de dependência espacial, limitando a compreensão das externalidades intermunicipais (Elhorst, 2014; Anselin, 1988). Ao ignorar os efeitos de transbordamento, esses estudos subestimam o alcance real do crédito, conforme apontado por LeSage e Pace (2009) e explorado por Silva Filho et al. (2023, 2024), que identificaram interações espaciais relevantes no contexto agrícola brasileiro.

Este artigo contribui de forma inédita à literatura ao aplicar o modelo Spatial Durbin Model (SDM) em sua versão quantílica para investigar os impactos diretos e indiretos do crédito rural sobre a produção agropecuária dos 5.570 municípios brasileiros entre 2019 e 2023. A combinação de econometria espacial e quantílica permite capturar não apenas os efeitos distributivos do crédito ao longo da produtividade, mas também as externalidades territoriais que afetam municípios vizinhos. Além de diferenciar os efeitos por tipo de crédito (custeio e investimento) e por fonte (bancos privados, BNDES e Fundos Constitucionais), o estudo integra indicadores de autocorrelação espacial (Moran e LISA) para identificar clusters de concentração agrícola. Ao propor essa abordagem metodológica, o trabalho avança no entendimento dos efeitos territoriais do crédito agrícola e oferece subsídios concretos para o redesenho de políticas públicas orientadas à equidade e à eficiência regional.

2. PROCEDIMENTOS METODOLÓGICOS ADOTADOS

Esta seção foi destinada à apresentação dos procedimentos metodológicos adotado, para melhor compreensão dos desdobramentos elencados sequencialmente neste estudo. Os modelos estimados foram todos apresentados em anexos, mesmo não sendo eles utilizados para as análises, sendo indicado aquele que melhor adequou-se ao conjunto de dados, ou seja, o método mais parcimonioso, e com resultados mais robustos, conforme a escolha feita por meio dos testes. Outrossim, todos os testes para a escolha do melhor modelo, conforme orientado pela literatura, estão presentes neste artigo.

2.1 Base de Dados e Recorte Temporal

A pesquisa utiliza dados referentes ao período de 2019 a 2023, com ênfase nos municípios brasileiros. As variáveis utilizadas no estudo incluem o Valor Bruto da Produção Agrícola (VBP)

como variável dependente, além de crédito total emitido por bancos privados para custeio e investimento agrícola, crédito emitido à agricultura pelo Banco Nacional de Desenvolvimento Econômico e Social (BNDES), crédito para custeio e investimento emitido pelos Fundos Constitucionais de Financiamento (em suas regiões de operação), número de ocupados formais na lavoura temporária, precipitação anual em milímetros e seu quadrado, além de dummies regionais para capturar efeitos específicos de localização geográfica.

2.2 Escolha do Modelo

Para capturar as interações espaciais presentes nos dados, foram testados diversos modelos econométricos espaciais, conforme sugere a literatura (Anselin, 1988; LeSage e Pace, 2009; Rey e Anselin, 2007; Arbia, 2014) partindo-se do Modelo de Regressão Linear Ordinária (OLS), e do Modelo de Defasagem Espacial (SLX), e avançando nos modelos que consideram a heterogeneidade espacial possível no conjunto de dados, tais quais: o Modelo Autorregressivo Espacial (SAR), o Modelo de Erros Espaciais (SEM), o Modelo de Defasagem Espacial com Interações Espaciais (SDM), o Modelo de Erros Espaciais Defasados (SDEM) e o Modelo Autorregressivo Espacial com Erros Espaciais (SARAR). A seleção do modelo mais adequado foi baseada na parcimônia e na capacidade de capturar dependências espaciais tanto nos regressores quanto na variável dependente. Sua escolha ocorreu por meio de testes como: LM e LM em sua versão robusta e ainda o teste de randomização do Índice de Moran e a simulação de Monte Carlo nos resíduos, conforme descrição, abaixo.

2.3 Modelo Escolhido

Com base nos testes aplicados e na literatura especializada, o Modelo de Defasagem Espacial com Interações Espaciais (SDM) foi escolhido como o mais adequado para a análise. Esse modelo permite a consideração de efeitos diretos e indiretos da variável explicada e das variáveis explicativas, proporcionando uma avaliação mais precisa das interações espaciais.

O modelo SDM pode ser representado pela seguinte equação:

$$y = \rho W y + X \beta + W X \theta + \varepsilon \quad (1)$$

onde y representa a variável dependente (Valor Bruto da Produção Agrícola - VBP), ρ é o coeficiente de defasagem espacial da variável dependente, W é a matriz de pesos espaciais, X é a matriz de variáveis explicativas, β é o vetor de coeficientes das variáveis explicativas, θ representa os coeficientes da interação espacial das variáveis explicativas e ε é o termo de erro. Este modelo, conforme apresentado, nos dar resultados considerando a média da variável dependente. Com isso, para testar as disparidades dos efeitos do crédito sobre o VBP, para além da média, estimou-se o modelo quantílico para capturar a heterogeneidade dos impactos espaciais ao longo da distribuição condicional da variável dependente, conforme descrição, abaixo.

O modelo SDM Quantílico é representado pela equação:

$$Q\tau(y|X) = \rho\tau W y + X\beta\tau + W X\theta\tau + \varepsilon\tau \quad (2)$$

onde $Q\tau(y|X)$ representa o quantil τ da distribuição condicional da variável dependente, permitindo identificar diferenças nos efeitos espaciais ao longo dos quantis da distribuição do VBP agrícola dos municípios brasileiros. A escolha desses modelos possibilita uma análise aprofundada dos impactos espaciais do crédito agrícola na produção agropecuária dos municípios estudados, garantindo maior confiabilidade e precisão na identificação dos padrões espaciais subjacentes aos dados analisados.

Assim, a seção seguinte aborda uma ampla revisão da literatura internacional e nacional, com o fito de situarmos os resultados analíticos no contexto da literatura vigente.

3. REVISÃO DA LITERATURA

Esta seção está destinada a apresentar uma revisão de literatura internacional e nacional acerca dos impactos do crédito agrícola sobre a sua produção ao redor do mundo.

3.1. Estudos internacionais

A literatura internacional tem destacado, de forma consistente, o papel do crédito agrícola como instrumento crucial para a elevação da produtividade e para o fortalecimento da resiliência no setor rural. Diversas metodologias têm sido mobilizadas para investigar os determinantes do acesso ao crédito, seus impactos na produção e na eficiência agrícola, bem como suas limitações contextuais. Saqib et al. (2018) e Chandio et al. (2019), ambos estudando o Paquistão, demonstram, ainda que por abordagens distintas, que características como educação, renda e tamanho da propriedade são determinantes no acesso ao crédito e que este, por sua vez, está associado a ganhos relevantes de produtividade. Enquanto Saqib et al. apontam que agricultores mais escolarizados têm 20% mais chances de acesso, Chandio et al. revelam um aumento de 15% na produtividade de quem acessa crédito formal, reforçando a hipótese de que o crédito é um insumo tão essencial quanto os fatores produtivos tradicionais.

A análise de Mamatzakis e Staikouras (2020) expande esse debate ao contexto europeu, ao mostrar que choques negativos nas taxas de juros e passivos totais após a crise de 2009 limitaram os investimentos agrícolas na periferia da zona do euro. Tal achado se articula com a contribuição de Moss e Suh (2020), que, ao explorarem os efeitos do Dodd-Frank Act nos Estados Unidos, revelam que a elevação dos custos regulatórios reduziu o crédito ofertado por bancos comunitários. Juntos, esses estudos demonstram como fatores macroeconômicos e regulatórios moldam o ambiente de crédito agrícola, atuando como restrições externas à expansão da produção, mesmo em economias desenvolvidas. Ambos destacam, ainda, a necessidade de políticas financeiras mais flexíveis e adaptadas às realidades locais.

No campo das inovações tecnológicas, Patel et al. (2021) apresentam um estudo pioneiro ao propor um sistema de crédito baseado em blockchain e IoT no setor agroalimentar indiano. A redução de 12% no tempo de processamento do crédito com o uso do KRanTi evidencia como a tecnologia pode minimizar barreiras operacionais, especialmente em países com infraestrutura bancária deficiente. Complementarmente, Mohsin et al. (2022), analisando a China, apontam que o crédito FinTech tem potencial para ampliar o financiamento agrícola, embora sua efetividade decresça marginalmente com o tempo. Ambas as investigações ressaltam que, além da presença de crédito, sua agilidade, transparência e alcance são variáveis fundamentais para o sucesso das políticas de financiamento rural em contextos emergentes.

Estudos com foco na África Ocidental e Subsaariana adicionam uma camada temporal e institucional à análise. Oloukoi (2022), ao estudar o crédito de curto prazo na WAEMU, mostra que os impactos sobre o valor agregado agrícola são visíveis apenas no longo prazo, defendendo políticas de juros mais baixos e horizontes mais amplos. Já Beaman et al. (2023), em Mali, e Sher et al. (2023), no Paquistão, investigam o papel dos diferentes tipos de crédito sobre o comportamento produtivo e de mercado dos pequenos agricultores. Ambos revelam que mecanismos como microcrédito e crédito sem juros aumentam não apenas a produção, mas também a inclusão comercial e tecnológica. Os achados reforçam que a heterogeneidade nos efeitos do crédito depende de sua estrutura, da composição dos beneficiários e das restrições enfrentadas.

A relação entre crédito e adaptação climática é aprofundada por Olutumise (2023), ao demonstrar que o acesso ao financiamento influencia diretamente a intensidade das estratégias de adaptação utilizadas por agricultores nigerianos. A pesquisa identifica que produtores com acesso ao crédito aplicam mais estratégias de resiliência frente a eventos extremos, sendo o crédito um mediador crítico entre vulnerabilidade ambiental e capacidade de resposta agrícola. Essa abordagem dialógica conecta-se ao estudo de Salima et al. (2023), que, no contexto do Malawi, evidencia os efeitos divergentes do crédito formal e informal sobre a segurança alimentar das famílias, sendo o primeiro associado a melhorias significativas e o segundo a retrocessos. Ambos os estudos acentuam a dimensão social do crédito agrícola, indo além da produção e alcançando o bem-estar das famílias rurais.

Anofe et al. (2024), por sua vez, ampliam a perspectiva setorial ao analisar os efeitos do crédito bancário comercial sobre diferentes segmentos da agropecuária nigeriana. Os resultados apontam que apenas a produção de gado respondeu positivamente ao crédito, indicando assimetrias na alocação e nos impactos entre as atividades agropecuárias. Esta contribuição se articula com os

achados anteriores ao mostrar que a eficácia do crédito depende da estrutura produtiva local e da granularidade das políticas públicas. A ausência de impactos em outros segmentos, como culturas alimentares e pesca, alerta para a necessidade de políticas mais orientadas à inclusão de setores negligenciados pelo sistema financeiro tradicional.

Tomando como conjunto, esses estudos revelam que o crédito agrícola, embora vital, não opera de forma isolada. Seu impacto é mediado por variáveis como escolaridade, acesso à tecnologia, desenho institucional, temporalidade da aplicação e contexto climático e social. Além disso, evidenciam que a literatura internacional ainda carece de abordagens que considerem explicitamente os efeitos espaciais da alocação do crédito sobre a produção. Tal lacuna metodológica limita a compreensão das externalidades territoriais do crédito, especialmente em contextos com forte heterogeneidade regional.

Dessa forma, ao se observar que a maioria dos estudos revisados concentra-se em territórios espacialmente homogêneos ou em análises microeconômicas pontuais, torna-se evidente a escassez de investigações que explorem modelos de econometria espacial aplicados ao crédito rural. A utilização de modelos como o Spatial Durbin Model (SDM) ou sua versão quantílica, praticamente ausente na literatura internacional, representa um avanço analítico necessário para capturar os efeitos diretos e indiretos do crédito na produção agrícola. Essa constatação justifica a adoção, no presente estudo, de uma abordagem que incorpora a dimensão espacial como elemento estruturante para compreender os padrões de financiamento rural e sua eficácia em territórios marcados por desigualdades estruturais.

3.2. Crédito agrícola no Brasil

A literatura brasileira tem avançado significativamente na análise dos impactos do crédito rural sobre a produção agrícola, evidenciando tanto seu potencial como instrumento de fomento quanto suas limitações estruturais e regionais. Um aspecto recorrente é a concentração geográfica dos recursos. Trindade e Cruz (2019) demonstram que, entre 2000 e 2010, a quase totalidade do crédito agrícola se concentrou nas regiões Sul e Sudeste, com participação marginal da Região Norte. Esses achados são corroborados por Zeller e Schiesari (2020), que identificam que municípios mais ricos e com maior capital humano têm maior acesso ao Pronaf, sugerindo uma distribuição regressiva dos recursos. Ambos os estudos destacam a urgência de políticas de crédito mais equitativas, especialmente para regiões periféricas e agricultores familiares.

A dimensão estrutural do crédito também é examinada por Borges e Parré (2022), que aplicam modelos VAR e demonstram que o crédito rural precede o crescimento do PIB agropecuário, estimando um valor ótimo de R\$ 58 bilhões por trimestre para maximizar a produção. Tal relação de causalidade temporal reforça o papel do crédito como variável estratégica no planejamento da política agrícola. Complementarmente, Souza et al. (2022) argumentam que os efeitos do crédito são heterogêneos entre as culturas e regiões, mostrando que, embora o impacto médio seja positivo, sua eficácia depende da estrutura produtiva local. Essas conclusões convergem para a necessidade de calibragem territorial e setorial das linhas de crédito, especialmente diante das assimetrias produtivas do território nacional.

A análise de Almeida e Cruz (2022) amplia essa discussão ao investigar a relação entre crédito e crescimento agrícola em um horizonte mais longo. Os autores demonstram que, em culturas de maior valor agregado, o crédito é particularmente eficaz na alavancagem de produtividade e investimentos. A contribuição deste trabalho é central, pois mostra que o crédito atua como catalisador da modernização agrícola, inclusive ao fortalecer cadeias produtivas de maior complexidade. Em diálogo com esses achados, Gasques et al. (2020) argumentam que os ganhos de produtividade na agricultura brasileira, especialmente no Centro-Oeste, estão fortemente vinculados ao crédito, à tecnologia e à escala de produção, apontando para uma interação sinérgica entre esses fatores.

Estudos mais recentes vêm incorporando metodologias espaciais para captar externalidades territoriais do crédito rural. Silva Filho et al. (2024), ao aplicarem modelos espaciais sobre os municípios das regiões Norte, Nordeste e Centro-Oeste, identificam que os efeitos positivos do

crédito público sobre a produção agrícola são locais, não se estendendo aos municípios vizinhos. Embora modestos, os efeitos são estatisticamente significativos, revelando que os Fundos Constitucionais e o BNDES exercem um papel importante na indução da produção, mas carecem de um desenho institucional que favoreça os encadeamentos regionais. Essa limitação é aprofundada em outro estudo dos mesmos autores, com foco no Nordeste, em que o modelo SDEM mostra que variáveis como fertilização, mecanização e precipitação atuam como condicionantes do impacto do crédito (Silva Filho et al., 2024).

O uso da econometria espacial ainda é incipiente no Brasil, mas sua aplicação tem evidenciado padrões complexos de dependência regional. Estudos como o de Mation et al. (2021), ao analisarem a política de crédito agrícola sob a ótica da redistribuição territorial, mostram que os efeitos do crédito são ampliados quando combinados com políticas de infraestrutura e extensão rural. Da mesma forma, Porsse et al. (2018) destacam que os efeitos do crédito são mais significativos em regiões com maior densidade tecnológica e institucional, sugerindo que o crédito, isoladamente, não é suficiente para desencadear ciclos virtuosos de desenvolvimento agrícola. Esses achados ampliam a compreensão de que a eficácia do crédito está condicionada a uma arquitetura territorial e institucional mais ampla.

Além da dimensão produtiva, a literatura também tem abordado os impactos ambientais e de sustentabilidade. André e Ramos (2023) avaliam o Fundo Amazônia e concluem que, quando bem direcionado, o crédito pode contribuir para a redução do desmatamento e para o ordenamento territorial. Esse enfoque é relevante para a agenda contemporânea, pois associa crédito não apenas à produção, mas também à conservação ambiental e ao uso racional dos recursos naturais. No entanto, os autores alertam para o desafio de isolar os efeitos do crédito das demais políticas públicas atuantes no território, o que reforça a necessidade de avaliações integradas e multiescalares.

Outro ponto emergente na literatura nacional refere-se à segmentação dos instrumentos financeiros. Como destacam Campanharo et al. (2022), a diferenciação entre crédito para custeio e investimento deve ser levada em consideração nas análises de impacto, dado que suas finalidades e maturações são distintas. O estudo mostra que o crédito para investimento tem efeitos mais duradouros sobre a produtividade, enquanto o custeio opera majoritariamente no curto prazo. Esse aspecto também aparece nos trabalhos de Buainain et al. (2014), que ressaltam o papel dos recursos de longo prazo no fortalecimento da agricultura familiar e na mitigação de desigualdades socioeconômicas no campo.

Em síntese, a literatura brasileira tem revelado avanços significativos na compreensão dos efeitos do crédito agrícola, embora ainda concentre suas análises em modelos tradicionais e pouco explore as interações espaciais e intertemporais. Há um consenso de que o crédito exerce impacto positivo sobre a produção, mas sua eficácia depende da configuração regional, do tipo de cultura, da maturação dos investimentos e do desenho institucional das políticas. Nesse cenário, estudos que incorporam abordagens espaciais, segmentação das linhas de financiamento e interações com outras políticas públicas representam caminhos promissores para uma compreensão mais robusta e integrada da política de crédito rural no Brasil.

4. RESULTADOS E DISCUSSÕES

Esta seção apresenta os principais resultados e discussões à luz da literatura econômica vigente.

4.1. Índice Lisa para VBP e crédito nos municípios brasileiros – 2020-2023

Esta subseção apresenta os resultados para o índice de Moran referente aos municípios brasileiros, no que diz respeito ao valor bruto da produção per capita – 2019-2023; distribuição espacial do crédito per capita à agricultura – 2019-2023.

Na Figura 1, abaixo, está plotada a análise do Índice LISA para o Valor Bruto da Produção Agrícola per capita nos municípios brasileiros nos anos de 2019 e 2023. Os resultados evidenciam mudanças na composição dos clusters espaciais. No ano de 2019, o cluster alto-alto foi composto

por 776 municípios, representando 13,93% do total de municípios brasileiros (5.570). Em 2023, esse cluster foi reduzido para 736 municípios, correspondendo a 13,21% do total. Essa redução de 40 municípios equivale a uma variação percentual negativa de 5,15. Porém, o que chama a atenção, de fato, é a forte concentração de clusters alto-alto em municípios das regiões Sul e Sudeste, conforme identificado em outros estudos (Trindade e Cruz, 2019).

Por outro lado, o cluster baixo-baixo apresentou uma dinâmica inversa. Em 2019, ele abrangia 1.356 municípios, ou 24,34% do total. Já em 2023, houve um aumento para 1.392 municípios, representando 24,98% do total. Esse acréscimo de 36 municípios reflete uma variação percentual positiva de 2,65%, sugerindo um agravamento da concentração de municípios em regiões com baixos valores de produção agrícola per capita. Também chama a atenção a elevada concentração de municípios no cluster baixo-baixo na região Norte e Nordeste, refletindo a polarização macrorregional brasileira, conforme evidenciada em outros estudos (Moura, Silva & Sousa, 2024).

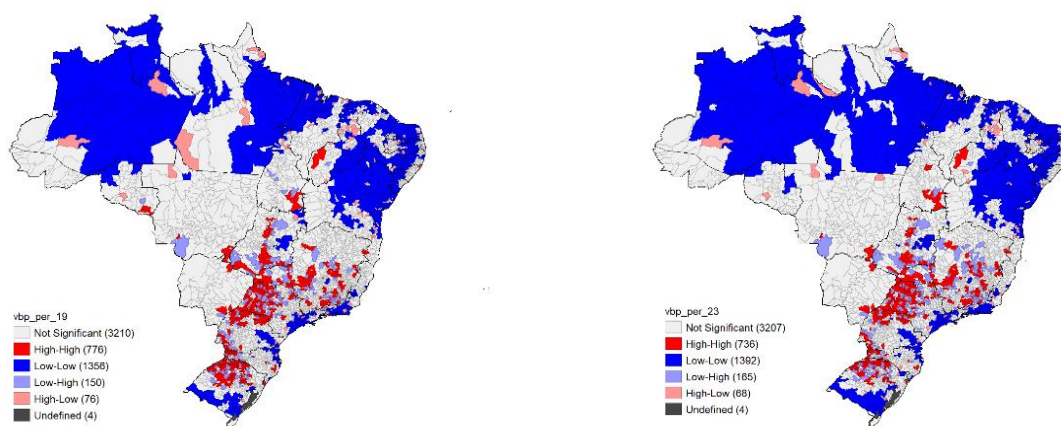


Figura 1: índice LISA para o valor bruto da produção per capita nos municípios brasileiros – 2020-2023

Essas mudanças apontam para dinâmicas distintas entre os clusters. Enquanto o cluster alto-alto mostra uma tendência de desconcentração, o cluster baixo-baixo evidencia a persistência e o aumento de regiões caracterizadas por baixa produção agrícola per capita. Essa evolução pode estar associada a fatores como desigualdades regionais, acesso limitado a recursos e infraestrutura, além de desafios específicos enfrentados por pequenos municípios em áreas mais isoladas, o que convergem aos estudos internacionais, os quais mostram que agricultores mais ricos e com grandes propriedades são sobremaneira beneficiados com oferta e crédito à produção (Saqib *et al.*, 2018; Chandio *et al.*, 2019) e aqueles expostos a maiores riscos climáticos apresentam maiores dificuldades na aquisição (Saqib *et al.*, 2018).

Esses resultados ressaltam a importância de políticas públicas direcionadas a reduzir as desigualdades regionais, com foco em promover maior equidade no desenvolvimento agrícola e na distribuição dos benefícios econômicos entre os municípios brasileiros, uma vez que há concentração de crédito a agricultura, conforme relatado em Trindade e Cruz (2019). Ademais, é oportuno enfatizar que a composição alto-alto mantém padrão de concentração nas regiões economicamente mais dinâmicas e a composição baixo-baixo fica sobremaneira concentrada em regiões de menor dinamismo.

Na Figura 2 estão os dados para a análise do Índice LISA para a distribuição espacial do crédito per capita à agricultura nos municípios brasileiros nos anos de 2019 e 2023. Os resultados revelam mudanças importantes na composição dos clusters alto-alto e baixo-baixo. Em 2019, o cluster alto-alto foi composto por 1.394 municípios, representando 25,02% do total de municípios brasileiros (5.570). Em 2023, esse cluster foi reduzido para 1.148 municípios, correspondendo a 20,61% do total. Essa diminuição de 246 municípios equivale a uma variação percentual negativa de 17,65%, indicando uma possível desconcentração significativa nas regiões com maiores níveis

de crédito per capita, mesmo que a literatura (Zeller e Schiesari, 2020) e os dados ainda mostrem que o crédito é concentrado nos municípios mais dinâmicos economicamente.

O cluster baixo-baixo, por sua vez, também apresentou uma redução expressiva. Em 2019, ele era composto por 1.000 municípios, representando 17,96% do total. Em 2023, esse número caiu para 703 municípios, o que equivale a 12,62% do total. Essa redução de 297 municípios reflete uma variação percentual negativa de 29,70%, sugerindo uma diminuição nas áreas caracterizadas por baixos níveis de crédito per capita ou promovendo uma redistribuição entre as outras formações de clusters.

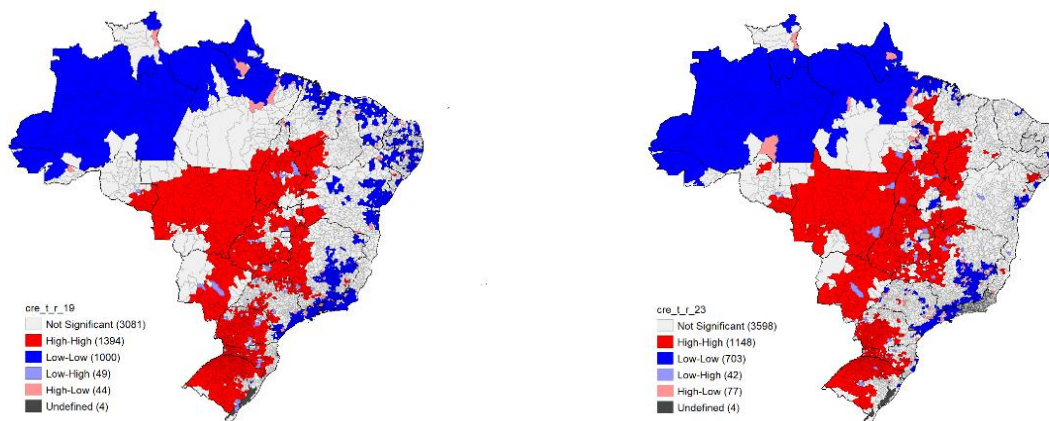


Figura 2: índice LISA da distribuição espacial do crédito per capita à agricultura nos municípios brasileiros – 2020-2023

Essas alterações nos clusters indicam uma redistribuição na alocação de crédito per capita, com uma redução tanto nas áreas de maior concentração quanto nas áreas de menor concentração, o que pode estar sendo tomada pela composição de outros clusters ou municípios que podem ter perda de significância (como pode ser visualizado na Figura 2). Essa dinâmica pode estar associada a políticas que buscam maior uniformidade na distribuição de recursos ou a mudanças nas características econômicas e demográficas dos municípios. Todavia, é oportuno destacar que os resultados convergem ao estudo de Trindade e Cruz (2019), em que mostra a concentração de crédito nos municípios das regiões Sul e Sudeste, sendo aqui acrescentada a concentração de crédito, também no Centro-oeste do Brasil.

Os resultados sugerem que, embora a concentração de crédito nas áreas mais favorecidas tenha diminuído, houve também uma significativa redução nas áreas menos favorecidas, além do aumento do número de municípios sem significância. Isso reforça a necessidade de monitoramento contínuo e de políticas que assegurem o acesso equitativo ao crédito agrícola, especialmente para municípios que ainda enfrentam dificuldades para alcançar melhores índices de desenvolvimento no setor agrícola nacional, sobretudo nas regiões Norte e Nordeste do país. Outrossim, os resultados convergem à literatura que evidencia maiores dificuldades de pequenos produtores à aquisição de crédito (Saqib et al., 2028) e que mostra que agricultores com maiores níveis de conhecimento e que produzem em municípios mais ricos são mais acessíveis a recursos financeiros à produção (Zeller e Schiesari, 2020).

4.2. Análise Econométrica Espacial – municípios brasileiros

Esta seção destina-se a apresentação dos resultados econométricos espaciais para a análise dos efeitos do crédito concedido em suas diversas modalidades e por diversas fontes, sobre o valor bruto da produção agrícola nos municípios brasileiros no ano de 2023. Nas subseções 4.2.1 apresenta-se os resultados dos testes de escolha do modelo e nas subseções 4.2.3 e 4.2.4 tem-se os resultados econométricos espaciais.

4.2.1. Testes LM e LM robustos e testes de randomização do índice de Moran dos Resíduos e Simulação de Monto Carlo para a escolha do Modelo Espacial

As Tabelas 1 e 2 abaixo apresentam os testes aplicados para a escolha dos modelos. Conforme sugestões de Anselin (1988), Fazekas e Lauridsen, (1999), Elhorst (2010), Phillips e Rossi (2014) e Anselin e Amaral (2024). Os testes de Multiplicador de Lagrange – LM e Multiplicador de Lagrange – LM robustos são aplicados ao OLS e ao SLX para detectar presença de autocorrelação espacial nos termos do erro ou na variável dependente, em sua versão robusta corrige-se a autocorrelação espacial para a variável dependente, bem como ajusta os resultados para a presença de dependência espacial nos erros, isolando o efeito da autocorrelação na variável dependente, conforme apresentação abaixo.

A Tabela 1 apresenta os resultados dos testes LM (Lagrange Multiplier) e suas versões robustas aplicados aos modelos OLS e SLX para o VBP per capita da agricultura nos municípios brasileiros. Esses testes avaliam a presença de autocorrelação espacial nos erros (LMerr) e na variável dependente (LMlag). O teste LM para erro espacial (LMerr) mostra valores elevados e altamente significativos nos dois modelos, sendo 194,33 no OLS e 173,87 no SLX, ambos com p-valores inferiores a 0,000. Esses resultados indicam que há uma forte dependência espacial nos resíduos, mesmo após a inclusão de efeitos espaciais explicativos no modelo SLX. Já o teste LM para dependência espacial na variável dependente (LMlag) apresenta comportamento diferente, com valores de 68,951 no modelo OLS e 183,79 no modelo SLX. Esse aumento no SLX indica que o modelo introduziu parte dos efeitos espaciais diretamente na variável dependente.

As versões robustas dos testes (RLMerr e RLMlag) fornecem informações mais específicas sobre o tipo predominante de autocorrelação espacial. O RLMerr apresenta um valor elevado de 148,51 no modelo OLS, mas no SLX cai consideravelmente para 14,323. Isso sugere que o modelo SLX é mais eficaz em reduzir a autocorrelação nos erros, resultado da inclusão de variáveis que capturam parte dos efeitos espaciais. No entanto, o teste robusto para dependência espacial na variável dependente (RLMlag) mostra valores semelhantes em ambos os modelos, sendo 23,128 no OLS e 24,245 no SLX, indicando que a autocorrelação permanece na variável dependente. Portanto, a inclusão de efeitos espaciais explicativos no modelo SLX reduz a autocorrelação nos erros, mas não elimina completamente a dependência espacial.

Tabela 1: Teste LM para os modelos OLS e SLX para o VBP per capita da agricultura nos municípios brasileiros

OLS			SLX		
LMerr = 194.33	df = 1	p-value < 0.000	LMerr = 173.87	df = 1	p-value < 0.000
LMlag = 68.951	df = 1	p-value < 0.000	LMlag = 183.79	df = 1	p-value < 0.000
RLMerr = 148.51	df = 1	p-value < 0.000	RLMerr = 14.323	df = 1	p-value < 0.000
RLMlag = 23.128	df = 1	p-value = 0.000	RLMlag = 24.245	df = 1	p-value = 0.000

Source: The authors elaborate on the estimation results.

Os resultados dos testes apontam para a necessidade de utilizar modelos espaciais mais robustos para capturar adequadamente a estrutura espacial dos dados. Embora o modelo SLX tenha reduzido parte da autocorrelação nos erros, a persistência da autocorrelação na variável dependente sugere que modelos como SAR, SDM, SDEM ou SEM podem ser mais apropriados. Esses modelos incorporam de forma explícita os efeitos espaciais, seja na variável dependente, nas independentes, em ambas as variáveis, seja nos resíduos, o que pode melhorar a especificação geral do modelo. A escolha de um modelo adequado é essencial para garantir que os resultados das análises sejam consistentes e não enviesados devido a omissão de efeitos espaciais relevantes.

Portanto, os testes LM e LM robusto demonstram que a estrutura espacial dos dados deve ser considerada na modelagem para evitar interpretações incorretas. A autocorrelação espacial identificada nos testes reforça a importância de modelos espaciais mais complexos, que são capazes de capturar melhor a interdependência entre os municípios brasileiros. A aplicação de modelos mais adequados deve resultar em uma melhora na qualidade dos ajustes e nas inferências estatísticas,

aumentando a validade dos resultados sobre o impacto do VBP per capita da agricultura na região. Assim, foram estimados os modelos OLS, SLX, SAR, SEM, SDM, SDEM e SARAR e aplicados os testes de escolha, conforme tabela abaixo. Adicionalmente, foram comparados o critério de informação de Akaike e o Log Likelihood, para escolher aquele que melhor ajusta os dados.

A Tabela 2 apresenta os resultados dos testes de Moran's I e da simulação de Monte Carlo para avaliar a autocorrelação espacial residual em diferentes modelos espaciais. O índice de Moran sob randomização indica valores elevados e significativos nos modelos OLS, SLX e SAR, com estatísticas de 14,005, 13,2480 e 11,1930, respectivamente. Esses resultados sugerem uma forte dependência espacial nos resíduos desses modelos, evidenciando que eles não são capazes de capturar completamente os efeitos espaciais presentes nos dados, conforme já sinalizado na Tabela 1. Os p-valores associados a esses modelos são todos menores que 0,001, indicando que a autocorrelação é estatisticamente significativa. Dessa forma, os modelos OLS, SLX e SAR apresentam limitações em lidar com a estrutura espacial dos dados, necessitando de ajustes mais robustos.

Nos modelos SDM, SDEM, SEM e SARAR, os valores do índice de Moran se aproximam de zero, o que indica que esses modelos conseguem neutralizar a autocorrelação espacial. Os p-valores dos testes sob randomização para esses modelos são superiores a 0,7, o que demonstra que não há evidência significativa de dependência espacial residual. Isso reflete a capacidade desses modelos em incorporar efeitos espaciais de forma mais eficiente, seja através da inclusão de variáveis explicativas espaciais ou por meio de termos de erro espacialmente autocorrelacionados. Esses resultados indicam que, para dados com forte dependência espacial, como o VBP per capita da agricultura, modelos como o SDM ou o SARAR são mais indicados.

Tabela 2: Teste I de Moran sob randomização e Simulação de Monte Carlo I de Moran para estimativas do VBP per capita da agricultura na área de atuação dos Fundos Constitucionais

Model	OLS Level per capita	SLX Level per capita	SAR Level per capita	SDM Level per capita	SDEM Level per capita	SEM Level per capita	SARAR Level per capita
Moran's I statistic st dev	14,005	13,248	11,193	-0.974	-0.745	-0.891	-0.760
p-value	0	0	0	0.8352	0.772	0.813	0.776
Moran's I Monte Carlo Simulation							
Model	OLS Level per capita	SLX Level per capita	SAR Level per capita	SDM Level per capita	SDEM Level per capita	SEM Level per capita	SARAR Level per capita
Statistic	0,111	0,105	0,089	-0.007	-0.006	-0.007	-0.006
p-value	0	0	0	0.834	0.745	0.828	0.774

Source: The authors elaborate on the estimation results.

A simulação de Monte Carlo reforça esses achados, apresentando estatísticas próximas de zero nos modelos SDM, SDEM, SEM e SARAR. Os p-valores para esses modelos permanecem elevados, corroborando a ausência de autocorrelação espacial nos resíduos. Por outro lado, os modelos OLS, SLX e SAR mantêm estatísticas elevadas e significativas na simulação de Monte Carlo, o que confirma sua inadequação para capturar adequadamente a estrutura espacial. A simulação de Monte Carlo é um complemento importante ao teste de Moran, pois permite uma avaliação mais robusta, especialmente em contextos em que a distribuição teórica pode não ser perfeitamente adequada.

Diante desses resultados, o modelo SDM se destaca como a melhor escolha para o conjunto de dados analisado, tanto pelos testes de validação apresentados na Tabela 2, quanto pela minimização do critério de informação de Akaike e pela maximização do Log Likelihood (ver anexo A). Esse modelo é capaz de lidar simultaneamente com a dependência espacial tanto nas variáveis explicativas quanto na variável dependente, proporcionando uma especificação mais completa. A adoção de modelos espaciais apropriados é crucial para evitar inferências incorretas, garantindo que os efeitos regionais sejam devidamente capturados. Portanto, o SDM é recomendado para análises que envolvam o VBP per capita em regiões com forte interação espacial, como os municípios brasileiros, analisados neste estudo.

Assim, a subseção seguinte apresenta os resultados do modelo SDM para a análise dos impactos do crédito agrícola sobre a sua produção.

4.2.1.1. Spatial Durbin Model – SDM para o VBP Per capita

A Tabela 3 apresenta os efeitos diretos e indiretos dos diferentes tipos de crédito agrícola sobre o Valor Bruto da Produção Agropecuária per capita (VBP) nos municípios brasileiros, estimados por meio do modelo Spatial Durbin Model (SDM). A inclusão da variável defasada do VBP de 2019 (*vbp_per_19*) como instrumento para correção de endogeneidade revelou um coeficiente altamente significativo (0.872), indicando forte persistência temporal na produção agrícola, como demonstrado em contextos similares por Arellano e Bond (1991), Blundell e Bond (1998), Roodman (2009), Bond, Hoeffler e Temple (2001) e Loayza, Schmidt-Hebbel e Servén (2000). O efeito indireto negativo (-0.204) sugere que aumentos da produção em municípios vizinhos podem ter impacto concorrencial, refletindo a disputa por insumos ou crédito, o que também foi identificado por Silva Filho et al. (2024) em estudo sobre o Nordeste brasileiro

Tabela 3: Impactos dos créditos per capita à agricultura sobre o VBP per capita dos municípios brasileiros – 2023 – SDM.

	<i>Dependent variable: vbp_per_23</i>	
	(SDM)	SDM(lag)
<i>vbp_per_19</i>	0.872*** (0.004)	-0.204*** (0.019)
<i>cper_inv_19</i>	-0.000 (0.003)	0.001 (0.006)
<i>cper_inv_20</i>	-0.005* (0.003)	0.012* (0.006)
<i>cper_inv_21</i>	0.004 (0.003)	-0.006 (0.006)
<i>cper_inv_22</i>	-0.002 (0.002)	0.002 (0.005)
<i>cper_cust_19</i>	0.003 (0.003)	-0.017*** (0.006)
<i>cper_cust_20</i>	-0.001 (0.003)	-0.0004 (0.007)
<i>cper_cust_21</i>	-0.007** (0.003)	0.002 (0.007)
<i>cper_cust_22</i>	-0.001 (0.003)	0.002 (0.006)
<i>cper_cust_23</i>	0.007*** (0.003)	0.010 (0.006)
<i>cper_bnd_19</i>	0.0004 (0.002)	-0.005 (0.005)
<i>cper_bnd_20</i>	-0.004* (0.002)	0.004 (0.005)
<i>cper_bnd_21</i>	-0.003 (0.002)	0.008 (0.005)
<i>cper_bnd_22</i>	-0.001 (0.002)	-0.006 (0.004)
<i>cper_fun_cust_19</i>	-0.005 (0.003)	-0.008 (0.007)
<i>cper_fun_cust_20</i>	-0.002	0.005

	(0.004)	(0.009)
cper_fun_cust_21	-0.0005 (0.004)	0.001 (0.008)
cper_fun_cust_22	0.003 (0.003)	-0.009 (0.007)
cper_fun_cust_23	-0.005* (0.003)	0.020*** (0.005)
cper_fun_inv_19	0.004 (0.005)	-0.013 (0.011)
cper_fun_inv_20	- 0.016*** (0.005)	0.020* (0.012)
cper_fun_inv_21	-0.003 (0.005)	0.010 (0.012)
cper_fun_inv_22	0.010** (0.004)	-0.007 (0.009)
o_for_lt_22	-0.005 (0.006)	0.013 (0.013)
o_for_lt_23	0.005 (0.006)	-0.013 (0.013)
ml_chuva_23	0.001 (0.028)	0.008 (0.040)
ml_chuva2_23	-0.0004 (0.003)	-0.002 (0.004)
d_no	-0.080 (0.095)	0.130 (0.097)
d_ne	-0.206** (0.086)	0.208** (0.089)
d_se	-0.019 (0.064)	0.090 (0.066)
d_co	0.044 (0.083)	-0.050 (0.088)
Constant	-0.016 (0.132)	
Observations	5,570	
Log Likelihood	879.252	
sigma ²	0.042	
Akaike Inf. Crit.		-1,628.505
Wald Test (df = 1)		168.302***
LR Test (df = 1)		161.206***

Note: *p<0.05; **p<0.01; ***p<0.001.

Os efeitos dos créditos para investimento variam substancialmente conforme o ano de concessão. O crédito para investimento de 2020 (cper_inv_20) apresentou impacto direto negativo (-0.005), significativo a 10%, sugerindo possíveis efeitos de maturação do capital investido, coerente com os achados de Campanharo et al. (2022), que destacam os prazos mais longos para retorno nos investimentos agrícolas. No entanto, seu efeito indireto foi positivo e significativo (0.012), o que pode indicar externalidades produtivas positivas para os municípios vizinhos – fenômeno descrito como “efeito de transbordamento” também por LeSage e Pace (2009) e confirmado empiricamente por Silva Filho et al. (2024).

Os créditos de custeio apresentaram padrões distintos. O crédito para custeio de 2023 (*cper_cust_23*) teve um efeito direto positivo e altamente significativo (0.007), reforçando a literatura que identifica maior impacto do crédito de curto prazo sobre a produção corrente (Souza et al., 2022; Borges & Parré, 2022). Já o crédito de 2021 (*cper_cust_21*) revelou impacto negativo significativo (-0.007), o que pode estar relacionado a choques climáticos ou dificuldades operacionais naquele ano, dado que o crédito de custeio é sensível a variações conjunturais. Esses resultados mostram a heterogeneidade temporal dos efeitos, já apontada por Almeida e Cruz (2022).

A análise dos efeitos do BNDES é mais moderada. Em geral, os coeficientes associados aos créditos do BNDES (*cper_bnd_19* a *cper_bnd_22*) não apresentaram significância estatística robusta. Exceção feita ao crédito de 2020 (*cper_bnd_20*), que mostrou efeito direto negativo (-0.004), significativo ao nível de 10%, possivelmente refletindo restrições ou ineficiências operacionais já identificadas em análises institucionais do banco. Essa ausência de significância também foi observada por Silva Filho et al. (2024), que identificaram impactos localizados do crédito do BNDES apenas em alguns contextos regionais.

Com relação aos Fundos Constitucionais de Financiamento, há destaque para os efeitos indiretos. O crédito para custeio de 2023 (*cper_fun_cust_23*) teve um efeito indireto positivo e altamente significativo (0.020), embora seu efeito direto tenha sido negativo e marginalmente significativo (-0.005). Esses achados reforçam a hipótese de que os fundos regionais podem ter efeitos redistributivos ou de estímulo produtivo nas áreas vizinhas, dependendo da eficiência de sua implementação. Resultados similares foram encontrados por Silva Filho et al. (2024) nas regiões Norte e Centro-Oeste, que evidenciaram efeitos de curto alcance territorial, concentrados nos municípios receptores.

No que se refere aos créditos para investimento dos Fundos Constitucionais, o crédito de 2020 (*cper_fun_inv_20*) também apresentou essa dualidade: impacto direto negativo (-0.016), significativo a 1%, e efeito indireto positivo (0.020), significativo a 10%. Tal padrão é consistente com os achados de Zeller e Schiesari (2020), que apontam que os efeitos positivos do crédito dependem fortemente de fatores institucionais locais, como capacidade técnica, infraestrutura e governança municipal. Assim, enquanto o município receptor pode não apresentar capacidade plena de absorção do recurso no curto prazo, municípios vizinhos podem se beneficiar indiretamente por meio de redes produtivas ou de comercialização.

De modo geral, os resultados da Tabela 3 reforçam a literatura nacional e internacional ao mostrar que os efeitos do crédito rural não são uniformes no tempo nem no espaço. Eles dependem da origem e da modalidade do crédito, do contexto institucional local e das interações espaciais entre os municípios. Estudos como os de Saqib et al. (2018), Chandio et al. (2019) e Beaman et al. (2023) já haviam identificado que o acesso ao crédito e seus impactos variam segundo perfil do produtor, estrutura de mercado e capacidade de gestão. Este estudo, ao utilizar o modelo SDM, confirma que as externalidades espaciais e a heterogeneidade regional são elementos centrais para compreender os efeitos do crédito sobre a produção agrícola, e oferece evidências empíricas robustas para fundamentar políticas mais territoriais, flexíveis e orientadas por resultados.

4.2.1.2. Spatial Durbin Model – SDM Quantílico Per capita

A Tabela 4 apresenta os resultados do modelo SDM quantílico, permitindo identificar como os efeitos do crédito agrícola variam ao longo da distribuição condicional da produção agropecuária per capita (VBP). Os resultados revelam uma heterogeneidade substancial nos impactos do crédito público e regional, sobretudo entre municípios de baixa e alta produtividade agrícola, reforçando a importância de abordagens metodológicas que considerem as especificidades locais e a distribuição espacial dos efeitos.

Tabela 4: SDM Quantílico espacial para o valor bruto da produção nos municípios brasileiros em função do crédito à agricultura.

Variáveis	<i>Dependent variable: vbp_per_23</i>					
	1ºDecil	1ºQuartil	Mediana	3ºQuartil	9ºPercentil	99ºPercentil

vbp_per_19	0.831*** (0.005)	0.871*** (0.002)	0.896*** (0.002)	0.918*** (0.002)	0.934*** (0.003)	0.914*** (0.027)
cper_inv_19	-0.001 (0.003)	-0.002 (0.001)	-0.001 (0.001)	-0.003** (0.001)	-0.002 (0.002)	0.002 (0.022)
cper_inv_20	0.004 (0.003)	0.0001 (0.002)	-0.002 (0.001)	-0.001 (0.001)	-0.003 (0.002)	-0.0002 (0.017)
cper_inv_21	0.001 (0.003)	0.0004 (0.001)	0.00003 (0.001)	0.0004 (0.001)	0.003* (0.002)	0.023 (0.015)
cper_inv_22	-0.003 (0.003)	-0.001 (0.001)	-0.0002 (0.001)	-0.001 (0.001)	-0.003 (0.002)	-0.008 (0.017)
cper_cust_19	-0.002 (0.003)	-0.003*** (0.001)	-0.003* (0.001)	-0.003** (0.001)	-0.002 (0.002)	0.005 (0.022)
cper_cust_20	0.001 (0.003)	-0.001 (0.002)	-0.001 (0.002)	-0.001 (0.002)	-0.004 (0.002)	-0.015 (0.026)
cper_cust_21	-0.002 (0.003)	-0.001 (0.001)	-0.003** (0.002)	-0.003* (0.002)	-0.002 (0.002)	-0.022 (0.019)
cper_cust_22	0.0001 (0.003)	0.001 (0.001)	0.001 (0.001)	0.002 (0.001)	0.003 (0.002)	-0.009 (0.021)
cper_cust_23	0.007*** (0.003)	0.005*** (0.001)	0.004*** (0.001)	0.002* (0.001)	0.003 (0.002)	0.009 (0.020)
cper_bnd_19	-0.002 (0.002)	-0.002** (0.001)	-0.001* (0.001)	-0.0001 (0.001)	-0.001 (0.001)	0.019 (0.014)
cper_bnd_20	-0.005** (0.002)	-0.002** (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.0005 (0.002)	-0.016 (0.017)
cper_bnd_21	-0.001 (0.002)	-0.002 (0.001)	-0.001 (0.001)	-0.002** (0.001)	-0.003** (0.001)	-0.017 (0.014)
cper_bnd_22	0.001 (0.002)	-0.0005 (0.001)	-0.001** (0.001)	-0.001 (0.001)	-0.003** (0.001)	-0.010 (0.014)
cper_fun_cust_19	-0.004 (0.003)	-0.003** (0.001)	-0.003** (0.001)	-0.002 (0.001)	-0.007** (0.003)	-0.011 (0.030)
cper_fun_cust_20	-0.001 (0.003)	0.00002 (0.002)	-0.002 (0.001)	-0.001 (0.002)	-0.0003 (0.004)	-0.019 (0.038)
cper_fun_cust_21	-0.003 (0.004)	-0.001 (0.002)	0.001 (0.001)	-0.001 (0.002)	-0.005 (0.004)	0.020 (0.032)
cper_fun_cust_22	0.005 (0.004)	0.003* (0.002)	0.002* (0.001)	0.004*** (0.001)	0.007*** (0.003)	0.022 (0.028)
cper_fun_cust_23	-0.003 (0.003)	-0.001 (0.001)	0.001 (0.001)	0.001 (0.001)	0.001 (0.002)	-0.004 (0.032)
cper_fun_inv_19	0.001 (0.005)	-0.002 (0.002)	-0.0004 (0.002)	-0.002 (0.002)	-0.007 (0.005)	0.014 (0.058)
cper_fun_inv_20	-0.003 (0.005)	-0.007*** (0.002)	-0.004** (0.002)	-0.001 (0.002)	0.002 (0.005)	-0.032 (0.058)
cper_fun_inv_21	-0.007 (0.005)	-0.002 (0.002)	-0.002 (0.002)	-0.001 (0.002)	-0.0002 (0.005)	0.037 (0.052)
cper_fun_inv_22	0.005 (0.004)	0.005*** (0.002)	0.002 (0.002)	0.002 (0.002)	0.006* (0.004)	-0.024 (0.029)
o_for_lt_22	-0.006** (0.003)	-0.006*** (0.002)	-0.001 (0.002)	0.0003 (0.002)	-0.008* (0.004)	0.024 (0.037)
o_for_lt_23	0.007*** (0.003)	0.006*** (0.002)	0.002 (0.002)	-0.001 (0.002)	0.006 (0.004)	-0.028 (0.037)

	(0.002)	(0.002)	(0.002)	(0.002)	(0.004)	(0.037)
ml_chuva_23	-0.019	0.007	0.001	0.007	0.024*	0.158
	(0.130)	(0.028)	(0.006)	(0.011)	(0.013)	(0.200)
ml_chuva2_23	0.001	-0.001	-0.0002	-0.001	-0.003*	-0.021
	(0.010)	(0.002)	(0.001)	(0.001)	(0.002)	(0.021)
d_no	-0.292**	-0.051	0.009	-0.001	0.015	-1.088
	(0.138)	(0.046)	(0.060)	(0.059)	(0.099)	(2.033)
d_ne	-0.176	-0.079*	-0.008	-0.032	-0.020	-1.008
	(0.126)	(0.042)	(0.059)	(0.057)	(0.090)	(0.705)
d_se	-0.138	-0.019	0.029	0.050	0.104**	-0.251
	(0.113)	(0.030)	(0.050)	(0.055)	(0.051)	(0.497)
d_co	-0.036	0.063	0.083	0.042	0.059	-0.569
	(0.133)	(0.043)	(0.056)	(0.058)	(0.074)	(0.604)
vbp_per_19_lag	0.014***	-0.007**	-0.008***	-0.008***	-0.002	0.049
	(0.005)	(0.003)	(0.002)	(0.003)	(0.004)	(0.042)
cper_inv_19_lag	-0.007	-0.010***	-0.004	-0.004*	-0.009**	0.014
	(0.006)	(0.003)	(0.002)	(0.003)	(0.004)	(0.041)
cper_inv_20_lag	0.022***	0.008***	0.006**	0.007**	0.009*	0.052
	(0.006)	(0.003)	(0.003)	(0.003)	(0.005)	(0.048)
cper_inv_21_lag	-0.003	0.007**	0.001	-0.004	-0.001	-0.048
	(0.006)	(0.003)	(0.003)	(0.003)	(0.004)	(0.039)
cper_inv_22_lag	-0.004	0.004	-0.002	0.001	0.001	0.033
	(0.005)	(0.002)	(0.002)	(0.003)	(0.004)	(0.036)
cper_cust_19_lag	-0.009*	-0.006**	-0.004*	-0.002	-0.004	-0.076*
	(0.005)	(0.003)	(0.003)	(0.003)	(0.005)	(0.041)
cper_cust_20_lag	0.013**	-0.001	-0.001	-0.005	-0.008	-0.070
	(0.006)	(0.003)	(0.004)	(0.003)	(0.006)	(0.056)
cper_cust_21_lag	-0.011	0.001	-0.005	-0.009**	-0.0003	0.072
	(0.007)	(0.003)	(0.003)	(0.004)	(0.005)	(0.047)
cper_cust_22_lag	-0.007	-0.0002	0.006**	0.009***	0.0005	0.036
	(0.006)	(0.003)	(0.003)	(0.003)	(0.005)	(0.047)
cper_cust_23_lag	0.010*	0.006*	0.005*	0.011***	0.014***	0.033
	(0.006)	(0.003)	(0.003)	(0.003)	(0.005)	(0.049)
cper_bnd_19_lag	-0.013***	-0.004**	-0.0005	0.002	0.001	0.015
	(0.004)	(0.002)	(0.002)	(0.002)	(0.003)	(0.036)
cper_bnd_20_lag	0.015***	0.006***	0.004**	0.003	-0.001	0.002
	(0.004)	(0.002)	(0.002)	(0.002)	(0.003)	(0.038)
cper_bnd_21_lag	0.0004	-0.002	-0.002	0.0004	0.003	0.038
	(0.004)	(0.002)	(0.002)	(0.002)	(0.003)	(0.037)
cper_bnd_22_lag	-0.009***	-0.006***	-0.002	-0.006***	-0.0003	-0.012
	(0.004)	(0.002)	(0.002)	(0.002)	(0.003)	(0.031)
cper_fun_cust_19_lag	-0.016**	-0.009***	-0.004	-0.004	-0.010	0.007
	(0.006)	(0.003)	(0.003)	(0.003)	(0.006)	(0.067)
cper_fun_cust_20_lag	-0.004	0.001	0.002	0.006	0.011	0.071
	(0.007)	(0.004)	(0.003)	(0.004)	(0.008)	(0.099)
cper_fun_cust_21_lag	-0.002	0.002	-0.0005	-0.003	0.004	-0.030
	(0.007)	(0.003)	(0.003)	(0.003)	(0.006)	(0.084)
cper_fun_cust_22_lag	0.001	-0.007***	-0.006**	-0.009***	-0.016***	-0.046
	(0.007)	(0.003)	(0.002)	(0.003)	(0.006)	(0.061)

cper_fun_cust_23_lag	0.019*** (0.005)	0.011*** (0.002)	0.008*** (0.002)	0.008*** (0.002)	0.014** (0.006)	0.036 (0.045)
cper_fun_inv_19_lag	-0.0003 (0.011)	-0.001 (0.005)	-0.004 (0.004)	0.00003 (0.004)	-0.0003 (0.011)	0.057 (0.127)
cper_fun_inv_20_lag	0.012 (0.012)	0.002 (0.005)	-0.002 (0.004)	-0.010** (0.005)	-0.002 (0.011)	0.066 (0.116)
cper_fun_inv_21_lag	-0.013 (0.011)	0.001 (0.006)	0.002 (0.005)	0.011** (0.005)	0.012 (0.012)	-0.072 (0.140)
cper_fun_inv_22_lag	0.011 (0.008)	0.005 (0.004)	0.011*** (0.004)	0.007** (0.003)	0.002 (0.007)	-0.037 (0.080)
o_for_lt_22_lag	0.021** (0.010)	0.008 (0.005)	0.001 (0.004)	0.005 (0.005)	-0.002 (0.008)	0.001 (0.107)
o_for_lt_23_lag	-0.022** (0.010)	-0.007 (0.005)	0.001 (0.004)	-0.002 (0.005)	0.008 (0.008)	-0.028 (0.107)
ml_chuva_23_lag	0.002 (0.073)	0.073** (0.029)	0.004 (0.036)	0.014 (0.027)	0.034 (0.051)	-0.265 (0.671)
ml_chuva2_23_lag	-0.002 (0.006)	-0.007*** (0.002)	-0.001 (0.003)	-0.001 (0.002)	-0.003 (0.004)	0.019 (0.051)
d_no_lag	0.407*** (0.143)	0.115** (0.049)	0.034 (0.061)	0.022 (0.061)	-0.010 (0.101)	1.600 (2.054)
d_ne_lag	0.266** (0.133)	0.115** (0.045)	0.031 (0.060)	0.033 (0.058)	-0.003 (0.091)	1.053 (0.725)
d_se_lag	0.308*** (0.118)	0.103*** (0.033)	0.024 (0.051)	-0.014 (0.055)	-0.073 (0.051)	0.350 (0.515)
d_co_lag	0.073 (0.141)	-0.034 (0.047)	-0.072 (0.058)	-0.057 (0.061)	-0.051 (0.075)	0.712 (0.647)
Constant	-0.056 (0.368)	-0.280** (0.109)	-0.011 (0.122)	-0.029 (0.087)	-0.087 (0.175)	1.037 (2.205)
Observations	5,570	5,570	5,570	5,570	5,570	5,570

Note: *p<0.05; **p<0.01; ***p<0.001.

O crédito para investimento de 2020 (cper_inv_20_lag) mostrou elasticidades positivas e significativas nos quantis inferiores da distribuição, com valores de 0,008 no primeiro quartil e 0,006 na mediana. Esses efeitos sugerem que os municípios com menor VBP agrícola se beneficiam mais intensamente dos investimentos realizados em municípios vizinhos, possivelmente devido a encadeamentos produtivos e compartilhamento de infraestrutura. Essa evidência é compatível com a literatura de econometria espacial, especialmente os trabalhos de LeSage e Pace (2009), que destacam o papel das externalidades regionais e dos efeitos de transbordamento espacial em modelos de desenvolvimento agrícola.

Em contraste, o crédito para investimento dos Fundos Constitucionais em 2022 (cper_fun_inv_22_lag) apresentou coeficientes negativos e significativos nos quantis inferiores, com -0,007 no primeiro quartil e -0,006 na mediana. Essa dinâmica pode refletir dificuldades na execução ou absorção dos investimentos em regiões de baixa capacidade institucional ou infraestrutura precária, aspectos já levantados por Zeller e Schiesari (2020) e reforçados por Campanharo et al. (2022), que alertam para a alocação regressiva dos recursos do Pronaf e demais fundos públicos. Assim, o impacto do crédito parece condicionado à capacidade institucional dos municípios em implementá-lo de forma eficaz.

Os efeitos espaciais por região também são expressivos. A variável indicadora para municípios da Região Norte (d_no_lag) apresentou um coeficiente de 0,407 no primeiro decil, enquanto a do Nordeste (d_ne_lag) teve 0,115 no primeiro quartil, ambos estatisticamente

significativos. Esses resultados indicam que a localização geográfica, mesmo que controlada por outras variáveis, exerce influência sobre os efeitos marginais do crédito, possivelmente pela proximidade com polos produtivos regionais ou pela existência de políticas federais voltadas a essas regiões. Estudos como os de Silva Filho et al. (2024) já haviam apontado que os efeitos dos Fundos Constitucionais, embora localizados, são mais perceptíveis nas regiões economicamente menos desenvolvidas.

Outra evidência importante diz respeito à assimetria dos efeitos ao longo da distribuição. Enquanto municípios de menor produtividade mostram respostas mais significativas ao crédito público indireto, os municípios mais produtivos, localizados nos quantis superiores, apresentam elasticidades menores ou estatisticamente insignificantes. Esse padrão é coerente com os achados de Almeida e Cruz (2022), que indicam que o crédito opera como alavanca em realidades com menor acúmulo de capital e maior restrição de liquidez. Em contextos de alta produtividade, por outro lado, o crédito tende a ter retornos marginais decrescentes, dado que os produtores já operam com maior eficiência técnica e financeira.

A ausência de significância para algumas variáveis nos quantis superiores pode estar associada a fatores estruturais e conjunturais. Municípios com alta produtividade muitas vezes acessam crédito por canais privados ou alternativos, como cooperativas, o que dilui os efeitos dos fundos públicos nas análises agregadas. Além disso, como destacado por Beaman et al. (2023), o impacto do crédito depende também da seleção dos beneficiários e do uso efetivo dos recursos, sendo que a heterogeneidade no retorno ao capital é mais acentuada em contextos de pequena escala e informalidade.

A Tabela 4, portanto, evidencia que os efeitos do crédito rural são condicionados por fatores espaciais, institucionais e distributivos. As variações nos coeficientes ao longo dos quantis revelam que políticas uniformes de crédito podem falhar em alcançar eficiência alocativa e equidade regional. A combinação de variáveis defasadas, modelagem espacial e regressão quantílica permite avançar na compreensão desses impactos e fundamenta a necessidade de políticas territorializadas e sensíveis à heterogeneidade da agricultura brasileira.

Esses achados estão alinhados à literatura internacional recente, que também evidencia variações significativas nos efeitos do crédito conforme o perfil produtivo dos municípios, as condições de acesso e a natureza dos instrumentos financeiros utilizados. Os resultados confirmam a importância do uso de metodologias que permitam capturar os efeitos diferenciais do crédito agrícola, como proposto por autores como Loayza, Schmidt-Hebbel e Servén (2000) e Mohsin et al. (2022).

5. CONSIDERAÇÕES FINAIS

Este estudo investigou a relação entre o crédito rural e a produção agrícola no Brasil a partir de uma abordagem espacial, utilizando os modelos Spatial Durbin Model (SDM) e SDM Quantílico, além de Análise Exploratória de Dados Espaciais – AEDE. Os resultados do Índice LISA para o Valor Bruto da Produção Agrícola (VBP) e para o crédito revelaram padrões espaciais significativos, evidenciando que a distribuição do crédito e da produção agrícola no país não ocorre de maneira homogênea. Observou-se que, entre 2019 e 2023, houve uma redução na concentração de crédito em algumas regiões, enquanto os clusters de alta e baixa produtividade se mantiveram relativamente persistentes. Essas evidências indicam que, apesar de um avanço na distribuição dos recursos financeiros, ainda há desafios para garantir que os impactos positivos do crédito sejam amplamente difundidos entre os municípios brasileiros.

A análise econométrica espacial demonstrou que o crédito exerce impactos diretos e indiretos sobre a produção agrícola, sendo que alguns tipos de crédito apresentaram efeitos positivos no crescimento do VBP, enquanto outros mostraram efeitos negativos ou pouco expressivos. O modelo SDM revelou que o crédito tem um papel fundamental na expansão da produção agrícola, mas que seus efeitos podem variar conforme o tipo de financiamento e a localização geográfica. Notadamente, constatou-se que o crédito para custeio de curto prazo mostrou efeitos positivos mais imediatos, enquanto o crédito para investimento teve impactos mais

diluídos no tempo, o que sugere a necessidade de políticas diferenciadas para cada modalidade de financiamento. Ademais, os efeitos espaciais identificados indicam que a produção agrícola nos municípios vizinhos pode influenciar significativamente a produção local, evidenciando uma dinâmica de interdependência que deve ser considerada no planejamento de políticas agrícolas e creditícias.

A principal contribuição deste estudo reside na aplicação inédita do SDM quantílico para analisar os impactos do crédito na produção agrícola em diferentes níveis de produção municipal. Os resultados mostraram que os efeitos do crédito são heterogêneos ao longo da distribuição condicional do VBP, sendo mais expressivos em municípios com menor valor da produção. Essa descoberta é crucial, pois indica que as regiões menos produtivas podem depender mais fortemente do crédito para impulsionar sua produção, enquanto regiões mais desenvolvidas podem ter acesso a outras formas de financiamento ou apresentar menores restrições de liquidez. Esse resultado reforça a importância de um desenho político que considere as especificidades regionais na distribuição dos recursos, garantindo que o crédito seja utilizado de maneira eficiente para promover um crescimento mais equilibrado do setor agropecuário.

Entretanto, algumas limitações devem ser reconhecidas. O estudo baseia-se em dados agregados por municípios, e não por indivíduos, o que pode ser uma limitação da análise, pois impede a observação de dinâmicas microeconômicas mais detalhadas dentro o próprio município. Também seria relevante aprofundar a investigação sobre os mecanismos através dos quais o crédito impacta a produção agrícola, incluindo fatores como infraestrutura, mecanização e avanços tecnológicos, variáveis não mensuradas nas pesquisas em níveis municipais brasileiros, já que o último censo agropecuário dopais é de 2017.

Os achados deste estudo são relevantes para a formulação de políticas públicas voltadas à promoção do setor agropecuário. O reconhecimento da existência de efeitos espaciais e heterogeneidade na efetividade do crédito destaca a necessidade de políticas mais segmentadas, que levem em conta as particularidades de cada região. A distribuição equitativa dos recursos, aliada a um planejamento estratégico que maximize os efeitos positivos do crédito e minimize seus impactos negativos, pode contribuir significativamente para um crescimento mais sustentável e inclusivo da agricultura brasileira. Assim, este estudo reforça a importância de uma gestão integrada do crédito rural como instrumento de desenvolvimento econômico e redução das desigualdades regionais no país.

6. REFERÊNCIAS BIBLIOGRÁFICAS

Akram, W., Hussain, Z., Sabir, H. M., & Hussain, I. (2008). Impact of agricultural credit on growth and poverty in Pakistan (time series analysis through error correction model). *European Journal of Scientific Research*, 23(2), 243-251. Disponível em: <https://doi.org/10.1080/13504850701719538>

Alencar, L. M. F., & Araújo, J. A. (2015). O impacto do crédito rural no produto agropecuário brasileiro. *Revista de Economia e Sociologia Rural*, 53(4), 729-746. <https://doi.org/10.1590/1234-56781806-947900530404>

Almeida, J. R., & Cruz, L. B. (2022). Crédito rural e crescimento agrícola: Uma análise empírica para o Brasil. *Revista de Desenvolvimento Econômico*, 24(2), 45-67.

Almeida, S. R., Lima, J. P., & Ferreira, M. E. (2021). The effects of extreme precipitation on agricultural productivity in Brazil. *Climatic Change*, 165(3), 45-60. <https://doi.org/10.1007/s10584-021-03012-3>

Anofe, O. C., Ogonna, O. C. S., & Nwolisa, E. F. (2024). Commercial banks' credit and agricultural sector output: A disaggregated approach. *African Banking and Finance Review Journal*, 9(9), 1-16.

Anselin, L. (1988). Lagrange multiplier test diagnostics for spatial dependence and spatial heterogeneity. *Geographical Analysis*, 20(1), 1-17. <https://doi.org/10.1111/j.1538-4632.1988.tb00159.x>

- Anselin, L. (1988). *Spatial econometrics: Methods and models*. Springer. <https://doi.org/10.1007/978-94-015-7799-1>
- Anselin, L. (1995). Local indicators of spatial association—LISA. *Geographical Analysis*, 27(2), 93–115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L., & Amaral, P. (2024). Endogenous spatial regimes. *Journal of Geographical Systems*, 26(2), 209-234. <https://doi.org/10.1007/s10109-023-00411-2>
- Arbia, G. (2014). *A Primer for Spatial Econometrics: With Applications in R*. Palgrave Macmillan. <https://doi.org/10.1057/9781137415544>
- Arbia, G. (2014). *A primer for spatial econometrics: With applications in R*. Palgrave Macmillan. <https://doi.org/10.1057/9781137358174>
- Arellano, M., & Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *Review of Economic Studies*, 58(2), 277–297. <https://doi.org/10.2307/2297968>
- Assunção, J., & Bragança, A. (2019). Technological Change and Deforestation: Evidence from the Brazilian Soybean Revolution. *Input Brazil*. <https://doi.org/10.1007/s10640-019-00383-w>
- Assunção, J., Souza, P. (2020). The Impact of Rural Credit on Brazilian Agriculture and the Environment. *Climate Policy Initiative*. <https://doi.org/10.2166/wst.2020.224>
- Assunção, J., Souza, P., & Mikio, T. (2020). The Impact of Rural Credit on Brazilian Agriculture and the Environment. *Climate Policy Initiative*. <https://doi.org/10.2166/wst.2020.224>
- Assunção, J., Souza, P., Mikio, T., & Fernandes, T. (2020). The Impact of Rural Credit on Brazilian Agriculture and the Environment. *Climate Policy Initiative*. <https://doi.org/10.2166/wst.2020.224>
- Azevedo, D. S. D., Arruda, P. M., & Castelar, P. S. (2023). Dynamic Elasticities of the Trade Balance of Brazilian Agriculture in Relation to the Exchange Rate. *The International Trade Journal*. <https://doi.org/10.1080/08853908.2023.2165201>
- Beaman, L., Karlan, D., Thuysbaert, B., & Udry, C. (2023). Selection into credit markets: Evidence from agriculture in Mali. *Econometrica*, 91(5), 1595-1627.
- Beaman, L., Magruder, J., & Robinson, J. (2023). Selection into credit markets: Evidence from agriculture in Mali. *American Economic Review*, 113(4), 1107–1139. <https://doi.org/10.1257/aer.20200757>
- Bivand, R. S., Pebesma, E., & Gómez-Rubio, V. (2013). *Applied spatial data analysis with R* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4614-7618-4>
- Blundell, R., & Bond, S. (1998). Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics*, 87(1), 115–143. [https://doi.org/10.1016/S0304-4076\(98\)00009-8](https://doi.org/10.1016/S0304-4076(98)00009-8)
- Bond, S., Hoeffler, A., & Temple, J. (2001). GMM estimation of empirical growth models. *CEPR Discussion Paper No. 3048*. <https://doi.org/10.2139/ssrn.290522>
- Borges, M. J., & Parré, J. L. (2021). O impacto do crédito rural no produto agropecuário brasileiro. *Revista de Economia e Sociologia Rural*, 60(2), e230521.
- Brasil, Companhia Nacional de Abastecimento (CONAB). (2023). Conab reduz estimativa para colheita de grãos no Brasil devido aos impactos climáticos do El Niño. *Globo Rural*. Recuperado de <https://www.globorural.globo.com>
- Brasil, Instituto Nacional de Meteorologia (INMET). (2023). El Niño pode causar impactos na agricultura brasileira. *INMET Notícias*. Recuperado de <https://portal.inmet.gov.br>
- Buainain, A. M., Alves, E., Silveira, J. M. da, & Navarro, Z. (2014). *O mundo rural no Brasil do século 21: A formação de um novo padrão agrário e agrícola*. Embrapa. <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1000367>
- Campanharo, W. A., Grisa, C., & Schneider, S. (2022). Crédito rural e desenvolvimento territorial: Limites e possibilidades da atuação do Pronaf no Brasil contemporâneo. *Revista de Economia e Sociologia Rural*, 60(3), e232014. <https://doi.org/10.1590/1806-9479.2022.232014>

Campanharo, W. A., Grisa, C., & Schneider, S. (2022). Crédito rural e desenvolvimento territorial: Limites e possibilidades da atuação do Pronaf no Brasil contemporâneo. *Revista de Economia e Sociologia Rural*, 60(3), e232014. <https://doi.org/10.1590/1806-9479.2022.232014>

Chandio, A. A., Jiang, Y., Rehman, A., & Rauf, A. (2020). Short and long-run impacts of climate change on agriculture: an empirical evidence from China. *International Journal of Climate Change Strategies and Management*, 12(2), 201-221.

Conceição, J. C. P. R., & Conceição, P. H. Z. (2014). Agricultura: Evolução e Importância para a Balança Comercial Brasileira. Instituto de Pesquisa Econômica Aplicada (IPEA), Texto para Discussão No. 1944. Disponível em: <https://repositorio.ipea.gov.br/handle/11058/3031>.

Costa, J. M., Silva, R. F., & Almeida, P. H. (2022). The impact of long-term agricultural investments on productivity in Brazilian municipalities. *Revista Brasileira de Economia*, 76(3), 321-345. <https://doi.org/10.5935/0034-7140.20220015>

de Abreu Campos, R. F., Domingues, É. P., Magalhães, A. S., & do Prado Tanure, T. M. (2024). The economic impacts of the rural credit: An analysis of the Brazilian National Family Farming Strengthening Program by biome. *Regional Science Policy & Practice*, 16(10), 100115. <https://doi.org/10.1111/rsp3.100115>

de Medeiros, A. P., Bender Filho, R., Vieira, K. M., & Ceretta, P. S. (2017). Análise do impacto do crédito rural na produção agrícola brasileira no período 2006-2014. *Revista em Agronegócio e Meio Ambiente*, 10(3), 729-755.

de Souza Ribeiro, J. R., & da Silva Filho, L. A. (2024). Determinants of international trade in brazilian soybeans and its main derivatives. *Contaduría y administración*, 69(3), 271-297.

Debarys, N., & Ertur, C. (2010). Testing for spatial autocorrelation in a fixed effects panel data model. *Regional Science and Urban Economics*, 40(6), 453-470. <https://doi.org/10.1016/j.regsciurbeco.2010.06.001>

Dos Santos, A. M., da Silva, C. F. A., de Almeida Junior, P. M., Rudke, A. P., & de Melo, S. N. (2021). Deforestation drivers in the Brazilian Amazon: assessing new spatial predictors. *Journal of environmental management*, 294, 113020.

Elhorst, J. P. (2010). Applied spatial econometrics: Raising the bar. *Spatial Economic Analysis*, 5(1), 9-28. <https://doi.org/10.1080/17421770903541772>

FAO. (2021). *The state of food and agriculture 2021: Making agrifood systems more resilient to shocks and stresses*. Food and Agriculture Organization of the United Nations. <https://doi.org/10.4060/cb4476en>

Fazekas, I., & Lauridsen, J. (1999). On the Lagrange Multiplier Test for Spatial Correlation in Econometric Models. *Computational Statistics*, 14(1), 25-45. <https://doi.org/10.1007/BF02365057>

Felema, J., Raiher, A. P., & Ferreira, C. R. (2013). Agropecuária brasileira: desempenho regional e determinantes de produtividade. *Revista de Economia e Sociologia Rural*, 51(3), 555-574. <https://doi.org/10.1590/S0103-20032013000300008>

Ferreira, F. C. M., Biazzin, C., & Hong, P. C. (2024). Transition Paths of Brazil from an Agricultural Economy to a Regional Powerhouse: A Global Supply Chain Perspective. *Sustainability*, 16(7), 2872. <https://doi.org/10.3390/su16072872>

Florax, R. J., & Rey, S. J. (1995). The impact of misspecified spatial interaction in linear regression models. In L. Anselin & R. J. Florax (Eds.), *New directions in spatial econometrics* (pp. 111-135). Springer. https://doi.org/10.1007/978-3-642-79877-1_7

Fonseca, M. A., Oliveira, R. T., & Santos, D. F. (2020). Efficiency analysis of BNDES financing in the Brazilian agricultural sector. *Revista de Política Agrícola*, 29(1), 45-60. <https://doi.org/10.1111/1477-9552.12345>

Gasques, J. G., Bastos, E. T., Bacchi, M. R. P., & Valdes, C. (2020). Produtividade da agricultura brasileira: Desempenho recente e principais desafios. *Revista de Política Agrícola*, 29(2), 5-22. <https://seer.sede.embrapa.br/index.php/RPA/article/view/1235>

Gasques, J. G., Bastos, E. T., Bacchi, M. R. P., & Valdes, C. (2020). Produtividade da agricultura brasileira: Desempenho recente e principais desafios. *Revista de Política Agrícola*, 29(2), 5-22. <https://seer.sede.embrapa.br/index.php/RPA/article/view/1235>

- Godfrey, L. G. (1978). Testing for higher order serial correlation in regression equations when the regressors include lagged dependent variables. *Econometrica*, 46(6), 1303-1310. <https://doi.org/10.2307/1913829>
- Koenker, R., & Bassett, G. (1978). Regression quantiles. *Econometrica*, 46(1), 33–50. <https://doi.org/10.2307/1913643>
- Koenker, R., & Bassett, G. (1978). Regression quantiles. *Econometrica*, 46(1), 33–50. <https://doi.org/10.2307/1913643>
- Leite, F. N. S., Castro, E. R., & Tateishi, H. R. (2023). Regional impacts of rural credit and rural insurance policies on crop area and productivity: evidence from São Paulo state, Brazil (2008 and 2017). *Agricultural Finance Review*, 83(2), 352-374. <https://doi.org/10.1108/AFR-02-2022-0024>
- LeSage, J. P., & Pace, R. K. (2009). *Introduction to spatial econometrics*. CRC Press. <https://doi.org/10.1201/9781420064254>
- LeSage, J. P., & Pace, R. K. (2009). *Introduction to spatial econometrics*. CRC Press. <https://doi.org/10.1201/9781420064254>
- LeSage, J., & Pace, R. K. (2009). *Introduction to Spatial Econometrics*. Chapman & Hall/CRC. <https://doi.org/10.1201/9781420064254>
- LeSage, J., & Pace, R. K. (2009). *Introduction to Spatial Econometrics*. CRC Press. <https://doi.org/10.1201/9781420064254>
- Lima, J. F., Alves, L. R., Piffer, M., & Piacenti, C. A. (2006). Análise regional das mesorregiões do estado do Paraná no final do século XX. *Análise Econômica*, 24(46), 7-26. <https://doi.org/10.22456/2176-5456.10845>
- Lima, J. R. F., Carvalho, J. R., & Lima, J. F. (2016). Crédito rural e produção das lavouras temporárias nos distintos cenários do nordeste brasileiro. *Revista de Economia e Sociologia Rural*, 54(3), 403–420. <https://doi.org/10.1590/1234-56781806-947900540304>
- Loayza, N., Schmidt-Hebbel, K., & Servén, L. (2000). What drives private saving across the world? *Review of Economics and Statistics*, 82(2), 165–181. <https://doi.org/10.1162/rest.2000.82.2.165>
- Loayza, N., Schmidt-Hebbel, K., & Servén, L. (2000). What drives private saving across the world? *Review of Economics and Statistics*, 82(2), 165–181. <https://doi.org/10.1162/rest.2000.82.2.165>
- Mation, L., Souza, P. H. G. F., & Gouveia, R. R. (2021). Crédito agrícola e desigualdade regional no Brasil: uma análise espacial e temporal. *Economia Aplicada*, 25(3), 457–480. <https://doi.org/10.1590/1413-8050/ea113338>
- Mohsin, A., Sheikh, M. R. I., Tushar, H., Iqbal, M. M., Far Abid Hossain, S., & Kamruzzaman, M. (2022). Does FinTech credit scale stimulate financial institutions to increase the proportion of agricultural loans?. *Cogent Economics & Finance*, 10(1), 2114176.
- Mohsin, M., Nadeem, M., & Zameer, H. (2022). Does FinTech credit promote agriculture loans? Evidence from Chinese provinces. *China Agricultural Economic Review*, 14(1), 35–52. <https://doi.org/10.1108/CAER-12-2020-0269>
- Moreira, A. R. B., Helfand, S. M., & Figueiredo, A. M. R. (2007). Explicando as diferenças na produtividade agrícola no Brasil. *Texto para Discussão nº 1254*, Instituto de Pesquisa Econômica Aplicada (IPEA). <https://repositorio.ipea.gov.br/handle/11058/1966>
- Moreira, V. R., Kureski, R., & Veiga, C. P. (2016). Assessment of the Economic Structure of Brazilian Agribusiness. *The Scientific World Journal*. <https://doi.org/10.1155/2016/1329875>
- Moura, M. C. A., Silva, J. F. M., & Sousa, E. P. (2024). Desempenho competitivo da agricultura familiar nas microrregiões do Brasil, 2006/2017. *Revista de Economia e Agronegócio*, 22(2), 1–30. <https://periodicos.ufv.br/rea/article/view/18307>
- Neves, M. D. C. R., Freitas, C. O., de Figueiredo Silva, F., de Moura Costa, D. R., & Braga, M. J. (2020). Does access to rural credit help decrease income inequality in Brazil? *Journal of Agricultural and Applied Economics*, 52(3), 440-460. <https://doi.org/10.1017/aae.2020.21>

Nogueira, A. C. M., Amaral, A. M. S., Andrade, J. M. S., Avelar, J. S., & Góes, B. C. (2023). Impacto do crédito rural no desenvolvimento da agricultura brasileira. *Revista em Agronegócio e Meio Ambiente*, 16(3), 1-16.

Oliveira, G. H., Martins, L. A., & Souza, V. C. (2023). Constitutional funds and agricultural development: An analysis of impacts on Brazilian municipalities. *Journal of Development Studies*, 59(4), 678-695. <https://doi.org/10.1080/00220388.2022.2071234>

Oliveira, N. M., & Piffer, M. (2018). Determinantes do perfil locacional das atividades produtivas no estado do Tocantins. *Boletim de Geografia*, 36(1), 92-111. <https://doi.org/10.4025/bolgeogr.v36i1.37292>

Oloukoi, L. (2022). Comparative effect of short-term credit granted to agriculture on agricultural added value in the West African countries. *Journal of Economics and Development*, 24(2), 176-195.

Olutumise, A. I. (2023). Impact of credit on the climate adaptation utilization among food crop farmers in Southwest, Nigeria: application of endogenous treatment Poisson regression model. *Agricultural and Food Economics*, 11(1), 7.

Patel, N., Shukla, A., Tanwar, S., & Singh, D. (2024). KRanTi: Blockchain-based farmer's credit scheme for agriculture-food supply chain. *Transactions on Emerging Telecommunications Technologies*, 35(4), e4286.

Pellegrina, H. (2022). Trade, Productivity, and the Spatial Organization of Agriculture: Evidence from Brazil. *Journal of Development Economics*. <https://doi.org/10.3886/E161163V1>

Phillips, P. C. B., & Rossi, F. (2014). Improved Lagrange Multiplier Tests in Spatial Autoregressions. *Econometric Theory*, 17(1), 139-175. <https://doi.org/10.1017/S0266466613000503>

Pires, M. J. D. S. (2023). *Características das estruturas produtivas agrícolas regionais brasileiras entre 1995 e 2021* (No. 2914). Texto para Discussão.

Porsse, A. A., Diniz, C. C., & Mota, P. R. (2018). Crédito rural, infraestrutura e crescimento regional: Evidências para o Brasil. *Revista Brasileira de Economia*, 72(4), 497-516. <https://doi.org/10.5935/0034-7140.20180023>

Rausch, L. L., Gibbs, H. K., Schelly, I., Brandão Jr, A., Morton, D. C., Filho, A. C., ... & Meyer, D. (2019). Soy expansion in Brazil's Cerrado. *Conservation Letters*, 12(6), e12671. <https://doi.org/10.1111/conl.12671>

Rey, S. J., & Anselin, L. (2007). PySAL: A Python Library of Spatial Analytical Methods. *The Review of Regional Studies*, 37(1), 5-27. <https://doi.org/10.52324/001c.8285>

Rezende, G. C., & Oliveira, A. M. H. (2021). Crédito rural e modernização da agricultura no Brasil: Uma análise de longo prazo. *Revista de Economia e Sociologia Rural*, 59(2), e220291. <https://doi.org/10.1590/1806-9479.2021.220291>

Roodman, D. (2009). How to do xtabond2: An introduction to difference and system GMM in Stata. *The Stata Journal*, 9(1), 86-136. <https://doi.org/10.1177/1536867X0900900106>

Salima, W., Manja, L. P., Chiwaula, L. S., & Chirwa, G. C. (2023). The impact of credit access on household food security in Malawi. *Journal of Agriculture and Food Research*, 11, 100490.

Santos, E. F., Rocha, P. R., & Gomes, L. F. (2022). Spatial externalities in agricultural productivity: An analysis of Brazilian regions. *Regional Science and Urban Economics*, 92, 103-115. <https://doi.org/10.1016/j.regsciurbeco.2021.103115>

Saqib, S. E., Kuwornu, J. K., Panezia, S., & Ali, U. (2018). Factors determining subsistence farmers' access to agricultural credit in flood-prone areas of Pakistan. *Kasetsart Journal of Social Sciences*, 39(2), 262-268

Sher, A., Mazhar, S., & Qiu, Y. (2024). Toward sustainable agriculture: The impact of interest-free credit on marketing decisions and technological progress in Pakistan. *Sustainable Development*, 32(1), 608-623.

Silva Filho, L. A., Azzoni, C. R., & Chagas, A. L. S. (2024). The impacts of public financing on the GDP of the municipalities of the north, northeast, and midwest of Brazil. *Estudios Económicos*, 41(83), 70-92. DOI: [10.52292/j.estudecon.2024.3497](https://doi.org/10.52292/j.estudecon.2024.3497).

Silva, J. P., & Souza, R. F. (2019). A trajetória recente do financiamento agrícola no Brasil: a importância do crédito rural público e privado. *Revista de Política Agrícola*, 28(4), 50–64. <https://doi.org/10.1590/rpa-2019-28-4-04>

Silva, L. M., & Pereira, T. S. (2021). The effects of agricultural credit on productivity in emerging regions of Brazil. *Agricultural Economics Research Review*, 34(2), 189-205. <https://doi.org/10.22004/ag.econ.307123>

Silva-Filho, L. A., Azzoni, C. R., Chagas, A. L. S., & Castro, G. (2023). Favorable credit to private agents and the local economies in the deprived regions of Brazil: a spatial panel analysis. *Letters in Spatial and Resource Sciences*, 16(1), 1-11. <https://doi.org/10.1007/s12076-023-00363-7>

Sossa, C. O., & Duarte, L. B. (2019). Análise da competitividade internacional do agronegócio brasileiro no período de 2003 a 2013. *Desenvolvimento em Questão*, 17(49), 59-78.

Souza, P., & Mikio, T. (2018). Credit for Investments in Brazilian Agriculture and the Role of the Brazilian Development Bank. *Journal of Agricultural and Applied Economics*. <https://doi.org/10.1017/aae.2018.21>

Souza, P.; Herschmann, S.; Assunção, J., 2020. (2020). Climate Policy Initiative (CPI). Política de Crédito Rural no Brasil: Agropecuária, Proteção Ambiental e Desenvolvimento Econômico. *Climate Policy Initiative*. Recuperado de <https://www.climatepolicyinitiative.org/wp-content/uploads/2020/12/REL-Politica-de-Credito-Rural-no-Brasil.pdf>

Spera, S. (2017). Agricultural intensification can preserve the Brazilian Cerrado: Applying lessons from Mato Grosso and Goiás to Brazil's last agricultural frontier. *Tropical Conservation Science*, 10, 1940082917720662. <https://doi.org/10.1177/1940082917720662>

Trabaquini, K., Galvão, L. S., Formaggio, A. R., & de Aragão, L. E. O. E. C. (2017). Soil, land use time, and sustainable intensification of agriculture in the Brazilian Cerrado region. *Environmental Monitoring and Assessment*, 189, 1-15. <https://doi.org/10.1007/s10661-017-5787-8>

Trindade, J. R. B., & Cruz, A. G. (2019). Crédito rural agrícola e impactos regionais sobre a dinâmica da produção agrícola brasileira no período de 2000 a 2010. *Revista Economia Ensaios*, 33(2).

Vedana, R., Rodrigues, K. C. T. T., Parré, J. L., & Shikida, P. F. A. (2020). Distribuição espacial da produtividade de cana-de-açúcar no Brasil. *Revista de Política Agrícola*, 28(4), 121.

World Bank. (2020). *Harvesting prosperity: Technology and productivity growth in agriculture*. World Bank Group. <https://doi.org/10.1596/978-1-4648-1393-1>

Yu, J., de Jong, R., & Lee, L.-F. (2015). Quasi-maximum likelihood estimation of spatial dynamic panel data models with fixed effects. *Journal of Econometrics*, 186(1), 62–78. <https://doi.org/10.1016/j.jeconom.2014.08.008>

Zeller, C., & Schiesari, L. (2020). Desigualdades no acesso ao crédito rural do Pronaf: Uma análise econométrica e institucional. *Revista de Economia Contemporânea*, 24(1), e212540. <https://doi.org/10.1590/19805527212540>

Zeller, M., & Schiesari, C. (2020). The unequal allocation of PRONAF resources: which factors determine the intensity of the program across Brazil?. *Revista de Economia e Sociologia Rural*, 58(3), e207126.