

UNIVERSIDADE FEDERAL DE MINAS GERAIS
CENTRO DE DESENVOLVIMENTO E PLANEJAMENTO REGIONAL

Projeto: Objetivo 4 da PNDR e a diversificação, agregação de valor e sustentabilidade em cadeias produtivas agrícolas no Cerrado

Meta 3 – Parte 1: Análise dos Fundos Constitucionais de Financiamento, sua distribuição espacial e seus mecanismos no Cerrado

Relatório Técnico

Coordenação Geral
Prof. Pedro Amaral (Cedeplar/UFMG)

Coordenação do Relatório
Prof. Luís Abel da Silva Filho (URCA)

Belo Horizonte/MG

Junho/2025

I. SUMÁRIO EXECUTIVO

I.I. Introdução ao Estudo e Objetivo

Este estudo analisa a distribuição espacial da produção agrícola e do crédito no Brasil e nos municípios do Cerrado brasileiro entre 2019 e 2023. Nesse período, examinam-se as variações no crédito rural e seu impacto no Valor Bruto da Produção (VBP¹) agrícola, oferecendo uma visão sobre as relações entre financiamento e produção em uma das regiões mais relevantes para o agronegócio nacional. O objetivo é identificar padrões de concentração e dependência espacial que influenciem o desenvolvimento econômico regional, bem como analisar o impacto do crédito sobre o VBP.

II. Dados e Metodologia

Os dados² utilizados no estudo incluem:

- VBP agrícola das principais culturas cultivadas no Cerrado: soja, milho, algodão e cana-de-açúcar;
- Crédito agrícola concedido por meio de bancos privados;
- Crédito agrícola concedido pelo Banco Nacional de Desenvolvimento Econômico e Social (BNDES); e,
- Crédito agrícola concedido pelos Fundos Constitucionais, tanto para custeio quanto para investimento agrícola.

A metodologia aplicada consistiu em uma combinação de técnicas de análise espacial e econométrica para capturar padrões de concentração e interdependência regional. As principais ferramentas utilizadas foram:

- **Quociente Locacional (QL)** para avaliar a especialização agrícola por cultura, indicando áreas com alta concentração relativa;

¹O valor Bruto da Produção tratado neste relatório refere-se apenas aquele relacionado as culturas de lavoura temporária.

²Todas as variáveis que apresentam valores monetários estão em Reais de 2023, deflacionadas pelo IGP-DI.

- **Índice de Moran Global e Local (LISA)** para identificar clusters de concentração ou dispersão na produção agrícola e no crédito;
- **Modelos econométricos espaciais**, incluindo o Modelo SDEM (Spatial Durbin Error Model), para medir os efeitos diretos e indiretos do crédito sobre o VBP agrícola, considerando a dependência espacial entre os municípios.

III. Principais Resultados Quantitativos

III.I. Quociente Locacional (QL) das Principais Culturas no Cerrado

A análise do Quociente Locacional revelou o nível de especialização para cada cultura agrícola no Cerrado:

- **Algodão:** A alta especialização foi observada em 124 municípios, com um QL médio de 4,04, destacando áreas onde a produção é intensiva. Em contrapartida, 64,2% dos municípios mostraram QL baixo para essa cultura, revelando uma distribuição mais restrita.
- **Cana-de-açúcar:** Apresentou alta especialização em 1.316 municípios (38,7% dos municípios produtores), mostrando uma distribuição variada ao longo da região, com concentrações produtivas em áreas específicas.
- **Milho:** O QL mostrou alta concentração em 2.335 municípios (45,3% dos produtores), com um QL médio de 2,14, revelando uma maior distribuição geográfica do milho em comparação a outras culturas.
- **Soja:** Dos municípios produtores, 1.201 (46,5%) demonstraram alta especialização em soja, com um QL médio de 1,41, ressaltando a soja como uma das culturas mais amplamente distribuídas e essenciais para o Cerrado.

III.II Índice de Moran Local (LISA) para o VBP Agrícola

A análise do LISA para o VBP agrícola destacou a formação de clusters em diferentes áreas para cada cultura:

- **Soja:** formou o maior cluster alto-alto, com 383 municípios em alta produtividade, consolidando-se como a cultura predominante no Cerrado.

- **Milho:** formou clusters alto-alto em 267 municípios, enquanto o cluster baixo-baixo apareceu em 59 municípios, destacando áreas de maior e menor intensidade produtiva.
- **Cana-de-açúcar:** apresentou clusters alto-alto em 278 municípios e clusters baixo-baixo em 207, sugerindo uma divisão entre áreas de alta e baixa produtividade para essa cultura.
- **Algodão:** formou clusters alto-alto em 116 municípios, indicando uma alta concentração produtiva, com ausência de clusters baixo-baixo, o que destaca sua produção concentrada em áreas especializadas.

III.III Índice LISA para o Crédito Agrícola

O LISA para o crédito agrícola apontou padrões de concentração e dispersão que se alinham à especialização agrícola regional:

- **Crédito para Custeio pelos Fundos Constitucionais:** Em 2023, o cluster alto-alto abrangeu 377 municípios, concentrando financiamento para custeio em áreas de alta demanda agrícola. Em contraste, 250 municípios formaram o cluster baixo-baixo, enfrentando dificuldades de acesso ao crédito.
- **Crédito para Investimento pelos Fundos Constitucionais:** Cobriu um número maior de municípios, com 493 no cluster alto-alto e 328 no cluster baixo-baixo, refletindo uma maior extensão do crédito para investimento no Cerrado e a necessidade de melhorias na oferta de crédito em algumas áreas.
- **BNDES e Crédito Privado:** O BNDES mostrou clusters alto-alto em 240 municípios e clusters baixo-baixo em 180. Já o crédito privado, que variou ao longo dos anos, teve uma expansão no cluster alto-alto, de 119 para 170 municípios entre 2020 e 2023, sinalizando o aumento no uso de financiamento privado em áreas produtivas.

IV. Resultados dos Modelos Econométricos Espaciais – SDEM

- O **Modelo SDEM** revelou uma relação positiva e significativa entre o crédito agrícola e o VBP, evidenciando que o crédito alocado em anos anteriores continua

impactando a produção nos anos seguintes, indicando a importância de uma política de crédito agrícola sustentada e de longo prazo.

- Efeitos de transbordamento (spillover) foram observados, indicando que o crédito agrícola em um município tem impacto positivo também na produtividade de municípios vizinhos. Esse efeito reforça a importância de políticas de crédito integradas, maximizando o impacto regional ao promover o desenvolvimento em cadeias produtivas locais.

V. Implicações para Políticas Públicas

V.I. Expansão e Continuidade do Crédito Agrícola:

- Manter e expandir o crédito nas áreas de alta produtividade identificadas pelo LISA, com foco em culturas de grande relevância como soja e milho.
- As políticas de crédito devem considerar o impacto duradouro do financiamento na produtividade agrícola, priorizando financiamentos que promovam estabilidade e crescimento sustentado.

V.II. Incentivo à Modernização e Infraestrutura:

- Direcionar parte do crédito para o desenvolvimento de infraestrutura e adoção de tecnologias agrícolas nas áreas de alta produtividade, especialmente onde o LISA mostrou clusters alto-alto de produção e crédito.
- Essa estratégia pode amplificar o efeito positivo do crédito e melhorar a competitividade das regiões produtivas.

VI. Foco nas Regiões com Menor Acesso a Crédito e Produção:

- As áreas baixo-baixo identificadas no LISA sugerem a necessidade de políticas específicas para inclusão financeira.
- Criar linhas de crédito direcionadas para pequenos e médios produtores nessas regiões pode promover uma distribuição mais equilibrada da produção e reduzir desigualdades regionais.

VII. Fortalecimento dos Fundos Constitucionais e Acesso ao Crédito Privado:

- Ampliar o alcance dos Fundos Constitucionais e incentivar a participação do crédito privado nas regiões com baixo financiamento agrícola.
- Taxas de juros acessíveis e programas de microcrédito podem facilitar o acesso ao financiamento agrícola, principalmente nas áreas onde o acesso ao crédito ainda é restrito.

VIII. Limitações do Estudo e Recomendações para Pesquisas Futuras

Uma das principais limitações deste estudo é a ausência de dados identificados por tomador do crédito e uso em cada tipo de cultura para cada município, o que restringe a análise detalhada das dinâmicas locais e limita a capacidade de avaliar plenamente as especificidades de cada cultura em cada área. Dados identificados permitiriam o uso de metodologias mais sofisticadas e modelos espaciais dinâmicos, que poderiam aprofundar a compreensão das interações entre crédito e produtividade agrícola por tipo de cultura.

Para pesquisas futuras, recomenda-se o acesso e a coleta de dados mais granulares e identificados por cultura e por município. Essa abordagem pode oferecer insights específicos, viabilizando políticas públicas mais eficazes e direcionadas, que atendam às necessidades locais e contribuam para um desenvolvimento regional mais robusto e inclusivo, sobretudo incentivando cada tipo de cultura, a partir da predisposição a ela associada em cada município.

Este sumário executivo compila os principais achados do estudo, com foco em soluções que promovam o crescimento equilibrado do crédito agrícola e sustentem o Cerrado como um polo estratégico para a agricultura brasileira.

Palavras-chave: VBP, Crédito, Cerrado.

Sumário

I. SUMÁRIO EXECUTIVO.....	2
I.I. Introdução ao Estudo e Objetivo	2
II. Dados e Metodologia	2
III. Principais Resultados Quantitativos	3
III.I. Quociente Locacional (QL) das Principais Culturas no Cerrado.....	3
III.II Índice de Moran Local (LISA) para o VBP Agrícola.....	3
III.III Índice LISA para o Crédito Agrícola	4
IV. Resultados dos Modelos Econométricos Espaciais – SDEM	4
V. Implicações para Políticas Públicas	5
V.I. Expansão e Continuidade do Crédito Agrícola:	5
V.II. Incentivo à Modernização e Infraestrutura:.....	5
VI. Foco nas Regiões com Menor Acesso a Crédito e Produção:	5
VII. Fortalecimento dos Fundos Constitucionais e Acesso ao Crédito Privado:.....	6
VIII. Limitações do Estudo e Recomendações para Pesquisas Futuras	6
1. CONSIDERAÇÕES INICIAIS.....	9
2. PROCEDIMENTOS METODOLÓGICOS ADOTADOS.....	12
2.1. Dados e Recorte Temporal	12
2.2. Uso dos Métodos e Importância	13
2.2.1. Quociente Locacional (QL).....	14
2.2.2. Índice de Moran Global	14
2.2.3. Índice de Moran Local (LISA)	15
2.2.4. Modelos econométricos espaciais e o passo a passo com testes de indicação à escolha	16
2.2.5. Ordinary Least Squares (OLS) Estrutura Geral	16
2.2.6. Modelo SLX (Spatial Lag of X)	17
2.2.7. Modelo SAR (Spatial Autoregressive).....	18

2.2.8.	Modelo SEM (Spatial Error Model)	19
2.2.9.	Modelo SDEM (Spatial Durbin Error Model)	20
2.2.10.	Metodologia para Estimativa do Modelo SDEM Quantílico	21
2.3.1.	Testes de escolha e validação do modelo econométrico	22
2.3.1.1.	Aplicação dos Testes LM e LM Robustos em Econometria Espacial para Análise de Modelos OLS, SLX, SAR, SEM e SDEM.	22
2.3.1.2.	Objetivo do teste	23
2.3.1.3.	Modelo OLS e Testes de Autocorrelação Espacial	23
2.3.1.4.	Testes LM Robustos	24
2.3.1.5.	Modelos SAR, SEM e SDEM.....	24
2.3.1.6.	Interpretação dos Resultados	24
2.3.2.1.	Testes de Randomização e Simulação de Monte Carlo.....	25
2.3.2.2.	Testes de randomização do índice de Moran dos resíduos.....	25
2.3.2.3.	Simulação de Monte Carlo	26
3.	REVISÃO DA LITERATURA.....	27
3.1.	Estudos internacionais	27
3.2.	Crédito agrícola no Brasil	31
4.	RESULTADOS E DISCUSSÕES	36
4.1.	PANORAMA DA LAVOURA TEMPORÁRIA NO BRASIL	36
4.1.1.	Distribuição percentual da produção nos municípios brasileiros	36
4.1.2.	Quociente Locacional do algodão, cana-de-açúcar, milho e soja nos municípios brasileiros.	38
4.1.3.	Índice Lisa para VBP e crédito nos municípios brasileiros – 2020-2023.....	41
4.1.4.	Análise Econométrica Espacial – municípios brasileiros	49
4.2.	PANORAMA DA LAVOURA TEMPORÁRIA E DO CRÉDITO NOS MUNICÍPIOS DO CERRADO BRASILEIRO	62
4.2.1.	Valor bruto da produção nos municípios do cerrado	62
4.2.2.	Panorama do crédito à agricultura nos municípios do Cerrado	64
4.2.3.	Razão entre o VBP e variáveis determinadas.....	72
5.	ANÁLISE DO VBP AGRÍCOLA NAS CULTURAS DE ALGODÃO, CANA-DE-AÇÚCAR, MILHO E SOJA NOS MUNICÍPIOS DO CERRADO.....	79
5.1.1.	Distribuição do VBP entre as commodities algodão, cana-de-açúcar, milho e soja no Cerrado brasileiro – média de 2019-2023.	79
5.1.2.	Resultados Espaciais em participação relativa para quatro commodities: algodão, cana-de-açúcar, milho e soja.	80

5.1.3. Quociente Locacional para o VBP agrícola nos municípios do Cerrado: commodities algodão, cana-de-açúcar, milho e soja.	83
5.1.4. Índice LISA para as culturas de algodão, cana-de-açúcar, milho e soja nos municípios do Cerrado brasileiro – 2019-2023.	85
5.1.5. Resultados Econométricos espaciais.....	87
6. CONSIDERAÇÕES FINAIS.....	99
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	102

1. CONSIDERAÇÕES INICIAIS

A agricultura brasileira tem desempenhado um papel fundamental na economia do país, sendo uma das principais responsáveis pelo superávit na balança comercial e pelo fornecimento de alimentos, tanto para o mercado interno, quanto para o externo (Conceição & Conceição, 2014; Moreira *et al.*, 2016; Azevedo *et al.*, 2023; Ferreira *et al.*, 2024). A evolução da produção agrícola no Brasil está fortemente relacionada à concessão de crédito, que permite aos produtores financiar a aquisição de insumos, tecnologias e equipamentos necessários para aumentar a produtividade e a competitividade (Assunção e Bragança, 2019; Assunção *et al.*, 2020; Pellegrina, 2022; Leite *et al.*, 2023). Nesse contexto, o crédito rural, em suas diversas modalidades – custeio, investimento e comercialização – tem sido um dos principais instrumentos de fomento à produção agrícola no país, sendo impulsionadas por instituições financeiras públicas e privadas, bem como pelos Fundos Constitucionais de Financiamento e pelo Banco Nacional de Desenvolvimento Econômico e Social (BNDES) (Souza & Mikio, 2018; Assunção *et al.*, 2020; Silva Filho *et al.*, 2023; Silva Filho *et al.*, 2024).

Ao longo dos anos, o governo brasileiro implementou políticas de crédito rural que visam garantir o acesso dos produtores aos recursos financeiros. Essas políticas têm como objetivo não apenas aumentar a produção agrícola, mas também promover a sustentabilidade econômica das regiões, reduzir as desigualdades regionais e fomentar o desenvolvimento rural (Neves *et al.*, 2020; Assunção & Souza, 2020). Entre as regiões que mais se beneficiaram dessas políticas está o Cerrado brasileiro, que, graças à expansão do crédito, se consolidou como um dos principais polos de produção agrícola

do país (Trabaquini *et al.*, 2017; Spera, 2017; Rausch *et al.*, 2019; de Abreu Campos *et al.*, 2024).

A região do Cerrado brasileiro, conhecida como uma das mais ricas em biodiversidade, também se destaca pela sua importância agrícola. Nos últimos anos, o Cerrado tem se tornado o principal celeiro de culturas como soja, milho, algodão e cana-de-açúcar. Esse crescimento da produção agrícola foi acompanhado por um aumento no crédito concedido aos produtores locais, especialmente por meio dos Fundos Constitucionais de Financiamento, que visam apoiar o desenvolvimento econômico nas regiões menos favorecidas do Brasil (Silva Filho *et al.*, 2024). Entre 2019 e 2023, a participação percentual do Valor Bruto da Produção (VBP) agrícola dos municípios da região do Cerrado brasileiro apresentou crescimento contínuo, passando de 31,50% em 2019 para 32,01%, em 2023, conforme relatado nos dados deste relatório.

Apesar do aumento da importância econômica do Cerrado, a análise da distribuição do crédito agrícola na região revela uma volatilidade significativa no período de 2019 a 2023. Em 2019, os municípios do Cerrado foram responsáveis por 42,08% do crédito total destinado à agricultura no Brasil, mas esse percentual caiu para 36,23% em 2020, refletindo uma redução na captação de recursos por parte dos produtores locais, o que pode denotar uma atuação do mercado creditício postulado sobremaneira nos aspectos da demanda. Nos anos seguintes, houve uma recuperação parcial, mas a participação do Cerrado no crédito agrícola oscilou, evidenciando a necessidade de políticas mais estáveis e direcionadas que garantam o acesso contínuo e eficiente ao crédito.

Além disso, a análise dos dados revela diferenças regionais significativas na concessão de crédito. Enquanto as regiões Sudeste, Sul e Centro-Oeste continuam a concentrar a maior parte do crédito agrícola no Brasil, regiões como o Norte e o Nordeste enfrentam maiores dificuldades de acesso aos recursos financeiros necessários para o desenvolvimento de sua produção agrícola, sendo necessário o fortalecimento dos Fundos Constitucionais de Financiamento para anteder a oferta de crédito, aonde o crédito privado não chega. Esse padrão de distribuição evidencia a existência de uma polarização na economia agrícola brasileira, com as regiões mais ricas e produtivas sendo as mais beneficiadas, enquanto as áreas mais pobres continuam a enfrentar desafios para alcançar um nível de competitividade similar, sendo, portanto, necessário o crédito público

enquanto importante instrumento de fomento (Silva Filho *et al.*, 2023 e Silva Filho *et al.*, 2024).

Assim, o presente relatório de pesquisa visa aprofundar a compreensão sobre a relação entre a distribuição espacial do crédito e a produção agrícola nos municípios do Cerrado brasileiro, utilizando métodos econométricos e análises espaciais. Para isso, foram utilizados dados do VBP agrícola e dos créditos emitidos pelos Fundos Constitucionais de Financiamento e pelo BNDES, além de carteiras de crédito de bancos privados, abrangendo o período de 2019 a 2023. A análise considera, ainda, a utilização de índices como o Quociente Locacional e o Índice de Moran Global e Local (LISA), que permitem identificar a concentração da produção agrícola e a distribuição espacial dos recursos de crédito. Os resultados evidenciam não apenas a importância do crédito para o desenvolvimento da produção agrícola no Cerrado, mas também as disparidades regionais que persistem no acesso a esses recursos.

Dessa forma, a produção agrícola no Cerrado brasileiro não pode ser dissociada das políticas de crédito rural, que têm sido essenciais para o aumento da produção, produtividade e da competitividade dos produtores locais. No entanto, para garantir um desenvolvimento sustentável e equitativo, é fundamental que as políticas de crédito sejam continuamente aprimoradas e ajustadas às necessidades regionais, de modo a promover um crescimento mais equilibrado e inclusivo em todo o território brasileiro.

2. PROCEDIMENTOS METODOLÓGICOS ADOTADOS

Esta seção foi destinada à apresentação dos procedimentos metodológicos adotado, para melhor compreensão dos desdobramentos elencados sequencialmente neste relatório de pesquisa. Os métodos testados foram todos apresentados, 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 relatório.

2.1.Dados e Recorte Temporal

Os modelos de análise espacial, incluindo a econometria espacial, são fundamentais para entender a influência de interações geográficas em variáveis socioeconômicas. Estes modelos abordam a dependência espacial e a heterogeneidade espacial, que são características comuns em dados geoeconômicos, permitindo uma análise mais precisa dos impactos que fatores relacionados às políticas públicas podem ter em uma área específica e em áreas vizinhas. A dependência espacial ocorre quando o valor de uma variável em uma localização é influenciado pelos valores em locais próximos, e a heterogeneidade espacial refere-se à variação espacial nas relações entre variáveis. Autores como Anselin (1988), Rey e Anselin (2007), LeSage e Pace (2009), Arbia (2014) Anselin, Serenini e Amaral (2024), apresentam pioneirismo em econometria espacial, com o desenvolvimento de métodos e testes de eficiência e efetividade para escolher modelos que captam essas interações, aprimorando as análises regionais e contribuindo para a tomada de decisões em políticas públicas.

Na econometria espacial uma série de modelos é amplamente utilizada para capturar interdependências espaciais. Esses modelos permitem analisar como variáveis dependentes são afetadas pelas mesmas variáveis em áreas próximas ou pelas relações de erro espacial, ajudando a revelar padrões de desenvolvimento e desigualdade regional. Nessa perspectiva analítica, Krugman (1991), expandiu essas análises para o campo da geografia econômica, considerando como fatores como proximidade e aglomeração afetam a competitividade e o crescimento regional. Com essas hipóteses acrescentadas à análise regional, a econometria espacial se tornou uma ferramenta essencial em estudos

desta natureza, pois facilita entendimento das complexas relações espaciais à elaboração de políticas mais eficazes para o desenvolvimento sustentável e equilibrado de regiões distintas.

Considerando-se as questões acima colocadas, este estudo utiliza dados do Valor Bruto da Produção (VBP) agrícola de municípios brasileiros, com enfoque específico nos municípios localizados na região do Cerrado, abrangendo o período de 2019 a 2023³, analisando-os pela abordagem de modelos de interações espaciais.

Os dados para análise incluem:

- Crédito total emitido por bancos privados para custeio e investimento agrícola em cada ano do recorte;
- Crédito emitido à agricultura pelo Banco Nacional de Desenvolvimento Econômico e Social (BNDES) nos anos analisados;
- Crédito para custeio e investimento emitido pelos Fundos Constitucionais de Financiamento em cada um dos anos aqui estudados.
- Ocupados formais na lavoura temporária nos municípios analisados, considerando-se os anos de 2022 e de 2023;
- Milímetros de chuva e o seu quarado por município no ano de 2023;
- Dummies de região;
- Valor Bruto da Produção Agrícola (VBP) por município brasileiro.

Esses dados foram escolhidos por serem relevantes para compreender a influência do crédito no VBP agrícola – com uso de controles amplamente utilizados – e dar suporte a uma análise de distribuição espacial.

2.2.Uso dos Métodos e Importância

A análise empírica aplicada a este relatório utiliza uma combinação de métodos quantitativos e espaciais para compreender a distribuição do VBP agrícola e a influência de fatores regionais. Cada método possui uma função específica, e a seguir, cada um será apresentado com sua representação matemática e interpretação.

³Todas as variáveis monetárias estão em reais de 2023.

2.2.1. Quociente Locacional (QL)

O Quociente Locacional é utilizado para medir a concentração relativa do VBP agrícola em um município comparado à média nacional. Ele é crucial para identificar especializações regionais e comparar a intensidade da produção local com o padrão nacional, conforme fórmula representativa, abaixo descrita:

$$QL_1 = \left(\frac{VBP_{p,i} / VBP_j}{VBP_{t,p,i} / VBP_{t,j}} \right) \quad (1)$$

Em que, $VBP_{p,i}$ é o valor bruto da produção do produto no município i ; VBP_j representa o valor bruto da produção de todos os produtos do município i ; $VBP_{t,p,i}$ é definido como o valor bruto da produção total do produto p em todos os municípios brasileiros; $VBP_{t,j}$ é o valor bruto da produção total de todos os produtos e em todos os municípios brasileiros.

Interpretação dos resultados segue os estudos de Crocco *et al.* (2006), Lima (2006), Silva Filho *et al.* (2015), Silva *et al.* (2017) e Oliveira e Piffer (2018):

- $QL > 1$: o município possui concentração de produção agrícola acima da média nacional.
- $QL = 0.50$ a 0.99 : a concentração é relativamente média em relação a nacional.
- $QL < 0.49$: a produção é pouco representativa do produto no município.

O seu uso neste relatório se faz oportuno, haja vista a necessidade de se observar espacialmente as quatro principais culturas aqui tratadas – algodão, cana-de-açúcar, milho e soja – dentro do contexto espacial dos municípios brasileiros, dando-se ênfase àqueles localizados na região do Cerrado.

2.2.2. Índice de Moran Global

O Índice de Moran Global mede a autocorrelação espacial, ajudando a identificar clusters ou padrões de dispersão da produção agrícola no território brasileiro e na região do Cerrado. Ele é essencial para verificar se a distribuição do VBP é aleatória ou apresenta

padrões geográficos significativos, considerando-se a dispersão e a heterogeneidade espacial no território brasileiro, conforme representação matemática, abaixo.

$$I_g = \left(\frac{N \sum_i \sum_j \omega_{1,j}}{\sum (X_1 - \bar{X})^2 \sum_i \sum_j \omega_{1,j}} \right) \quad (2)$$

- $I > 0$: Existe autocorrelação positiva, indicando clusters.
- $I = 0$: Não há autocorrelação, indicando distribuição aleatória.
- $I < 0$: Existe autocorrelação negativa, indicando dispersão.

O seu uso é justificado pelo fato de ser ele um importante índice de análise de concentração e/ou dispersão espacial de uma variável no espaço. Para fins deste estudo, justifica-se o seu uso como um importante componente de medida de correlação dos dados espaciais.

2.2.3. Índice de Moran Local (LISA)

O Índice LISA permite identificar clusters locais, destacando áreas com altas ou baixas concentrações de VBP agrícola e facilitando a criação de políticas direcionadas.

$$L_i = \left(\frac{(X_i - \bar{X}) \sum_j \omega_{ij} (X_j - \bar{X})}{\sum_i (X_i - \bar{X})^2} \right) \quad (3)$$

Os seus resultados neste estudo podem ser interpretados, conforme descrição, abaixo:

- Alto-Alto: municípios de alta produção próximos a outros de alta produção.
- Baixo-Baixo: municípios de baixa produção próximos a outros de baixa produção.
- Alto-Baixo: municípios de alta produção próximos a municípios de baixa produção.
- Baixo-Alto: municípios de baixa produção próximos a municípios de alta produção.

Sua facilidade em representação em mapas geoespaciais faz de seu uso uma importante ferramenta de apresentação visual de resultados, sendo esta, a finalidade do seu uso neste relatório.

2.2.4. Modelos econométricos espaciais e o passo a passo com testes de indicação à escolha

Para capturar a dependência espacial no VBP, modelos econométricos espaciais foram aplicados. Abaixo estão os passos detalhados para a escolha do modelo e os testes aplicados para atender a necessidade metodológica deste relatório. Com isso, parte-se de uma abordagem geral para escolha do modelo, conforme orientação da literatura vigente (Florax e Ray, 1995; Anselin, Serenini e Amaral, 2024). Desta feita, descreve-se cada uma das estruturas econométricas, abaixo pontuadas, escolhendo-se, para a apresentação dos resultados, aquele que se mostrou mais parcimoniosa para o uso das variáveis selecionadas.

2.2.5. Ordinary Least Squares (OLS) Estrutura Geral

Em econometria espacial, o modelo OLS (Ordinary Least Squares, ou Mínimos Quadrados Ordinários) é o modelo econométrico básico utilizado para estabelecer uma relação entre uma variável dependente e um conjunto de variáveis independentes, sem incorporar explicitamente os efeitos espaciais. Embora o OLS seja amplamente utilizado em econometria, ele pode ser limitado em contextos espaciais porque não considera a dependência ou correlação espacial entre unidades de análise (como regiões ou municípios), que são comuns em dados geográficos. A formulação básica do modelo OLS é:

$$Y = X\beta + \epsilon \quad (4)$$

Onde: y é o vetor da variável dependente; X é a matriz das variáveis independentes; β é o vetor dos coeficientes das variáveis independentes; ϵ é o termo de erro, assumido como normalmente distribuído, com média zero e variância constante.

Em contextos de dados geoeconômicos, o uso do modelo OLS sem ajustar para efeitos espaciais pode levar a problemas como: autocorrelação espacial nos erros; se existe dependência espacial entre as unidades de análise, as hipóteses de independência dos erros são violadas, resultando em resíduos autocorrelacionados; estimativas viesadas: ignorar a autocorrelação espacial pode levar a estimativas viesadas e ineficientes para os coeficientes β , uma vez que o efeito de uma unidade sobre as outras não é considerado; e, erros padrão incorretos: a autocorrelação espacial afeta os erros padrão, o que pode influenciar a validade dos testes de significância e das inferências.

Para resolver esses problemas, na perspectiva utilizada na construção deste relatório de pesquisa, recorreu-se a uma abordagem avançada na qual a econometria espacial utiliza extensões do OLS que integram estruturas espaciais, como o modelo SAR (Spatial Autoregressive), o modelo SEM (Spatial Error Model), e o modelo SLX (Spatial Lag of X), cada um incorporando diferentes aspectos da dependência espacial. No entanto, o modelo OLS ainda pode ser útil como ponto de partida para identificar a presença de autocorrelação espacial através de testes como o I de Moran nos resíduos, LM e LM robustos. Caso se detecte dependência espacial, outros modelos espaciais mais sofisticados podem ser aplicados para obter estimativas mais precisas e confiáveis, conforme se seguiu neste relatório. Com isso, estimou-se, também o modelo SLX, conforme descrição abaixo.

2.2.6. Modelo SLX (Spatial Lag of X)

O modelo SLX (Spatial Lag of X), ou *Spatial Lag of X*, é uma extensão dos modelos econométricos espaciais e é usado para capturar os efeitos espaciais indiretos nas variáveis explicativas. Esse modelo considera que as variáveis independentes de uma determinada unidade espacial pode afetar diretamente a variável dependente de unidades espaciais vizinhas, ou seja, incorpora o efeito espacial nas variáveis explicativas (X), mas não na variável dependente.

Especificamente, o modelo SLX inclui uma estrutura de defasagem espacial das variáveis explicativas, o que permite medir como a influência de uma variável em uma área (ou região) se espalha para áreas adjacentes. Isso é feito adicionando às variáveis independentes um termo de defasagem espacial WX , onde W é uma matriz de pesos

espaciais que define a proximidade ou conectividade entre as unidades, e X representa as variáveis explicativas originais. A formulação matemática do modelo SLX é a seguinte:

$$Y = \alpha + \beta X + WX\theta + \epsilon \quad (5)$$

Em que: Y é a variável dependente, X é a matriz de variáveis independentes, β é o vetor de coeficientes das variáveis independentes diretas, W é a matriz de pesos espaciais, θ é o vetor de coeficientes dos efeitos espaciais das variáveis independentes, ϵ é o termo de erro.

Esse modelo é útil quando o interesse é em avaliar a influência das variáveis independentes das áreas vizinhas (indiretos ou efeitos de *spillover*) sobre a variável dependente. É especialmente aplicável em estudos onde se deseja entender como políticas ou condições de uma região podem afetar diretamente regiões próximas, sem que haja uma interação direta entre as variáveis dependentes de uma região e outra. Dada à natureza dos dados utilizados neste estudo, estimou-se o modelo SLX e, em seguida, foi aplicado neste e no OLS os devidos testes de Multiplicadores de Lagrange e Multiplicadores de Lagrange Robustos para escolher o modelo que melhor comporta os dados aqui analisados. Assim, os demais modelos econométricos espaciais foram estimados, para que testes adicionais fossem realizados, conforme descrição abaixo.

2.2.7. Modelo SAR (Spatial Autoregressive)

O modelo SAR (Spatial Autoregressive), ou modelo autorregressivo espacial, é um modelo econométrico espacial que incorpora a dependência espacial diretamente na variável dependente. Isso significa que ele considera que a variável dependente, ou seja, o VBP em uma unidade espacial município brasileiro ou do Cerrado pode ser influenciado pelo valor dessa mesma variável em unidades vizinhas. Matematicamente, o modelo SAR é formulado da seguinte forma:

$$Y = \rho WY + X\beta + \epsilon \quad (6)$$

Onde: Y é o vetor da variável dependente; W é a matriz de pesos espaciais, que define o grau de conectividade entre unidades espaciais (por exemplo, regiões vizinhas);

ρ é o coeficiente de defasagem espacial que mede a intensidade do efeito espacial; X é a matriz de variáveis independentes; β é o vetor de coeficientes das variáveis independentes; ϵ é o termo de erro.

No modelo SAR, o termo ρWY representa a defasagem espacial da variável dependente (valor bruto da produção, neste relatório), capturando como os valores de y nas unidades espaciais vizinhas influenciam o valor de y na unidade de interesse. Esse coeficiente ρ é crucial, pois reflete o grau de dependência espacial: se ρ for significativamente diferente de zero, isso indica que existe uma correlação espacial entre as unidades, ou seja, os valores da variável dependente em uma unidade espacial são influenciados pelos valores das unidades adjacentes.

Esse modelo é útil em contextos em que se espera que o fenômeno estudado tenha um padrão de interação direta entre regiões vizinhas. Por exemplo, em análises de mercado imobiliário de terras agrícolas, onde o valor de uma propriedade pode ser afetado pelos valores de propriedades próximas. Como a nossa variável de interesse aqui pode apresentar transbordamento espacial e interação entre os municípios, o SAR também foi estimado e realizado os testes devidos sobre os seus resíduos para a escolha do modelo mais adequado.

2.2.8. Modelo SEM (Spatial Error Model)

O modelo SEM (Spatial Error Model), ou modelo de erro espacial, é um modelo econométrico espacial que considera a dependência espacial nos termos de erro, em vez da variável dependente ou das variáveis explicativas. No modelo SEM, assume-se que os fatores não observados que afetam a variável dependente em uma unidade espacial também afetam as unidades vizinhas, gerando um efeito espacial indiretamente através do termo de erro. Matematicamente, o modelo SEM é representado como:

$$Y = X\beta + \mu, \mu = \lambda W\mu + \epsilon \quad (7)$$

Em que: y é o vetor da variável dependente; X é a matriz de variáveis independentes; β é o vetor de coeficientes das variáveis independentes; μ é o termo de erro espacialmente autocorrelacionado; W é a matriz de pesos espaciais que define a

conectividade entre unidades espaciais; λ é o coeficiente de autocorrelação espacial dos erros, indicando a intensidade da dependência espacial no termo de erro; ϵ é o termo de erro aleatório, assumido como normalmente distribuído e sem correlação espacial.

No modelo SEM, o termo de erro μ é modelado como uma variável dependente do valor dos erros nas unidades vizinhas, representados pelo termo $\lambda W\mu$. Isso permite capturar a correlação espacial nos fatores não observados, o que é útil quando as influências espaciais se dão através de variáveis omitidas que afetam tanto a unidade de interesse quanto as unidades vizinhas.

Esse modelo é indicado para situações em que se observa dependência espacial residual após controlar as variáveis independentes, sugerindo que existem influências espaciais não observadas que afetam a variável dependente. Por exemplo, em estudos de economia regional, fatores não mensuráveis, como condições culturais ou aspectos ambientais, podem afetar simultaneamente regiões próximas, criando um padrão de correlação espacial nos resíduos do modelo. O SEM ajuda a capturar essa dependência espacial, melhorando a eficiência dos estimadores e reduzindo o viés nos coeficientes estimados das variáveis explicativas. Por esta razão, este modelo foi estimado e realizado testes nos resíduos para a escolha daquele que melhor ajustou-se aos dados.

2.2.9. Modelo SDEM (Spatial Durbin Error Model)

O modelo SDEM (Spatial Durbin Error Model) é uma extensão dos modelos de econometria espacial que combina elementos dos modelos SLX (Spatial Lag of X) e SEM (Spatial Error Model). O SDEM considera tanto os efeitos espaciais nos termos de erro (como o SEM) quanto à defasagem espacial nas variáveis explicativas (como o SLX), capturando assim efeitos indiretos nas variáveis independentes e correlações espaciais residuais. A formulação matemática do modelo SDEM é:

$$Y = \alpha + X\beta + WX\theta + \mu, \mu = \lambda W\mu + \epsilon \quad (8)$$

Em que: y é o vetor da variável dependente; X é a matriz das variáveis independentes; β é o vetor dos coeficientes das variáveis explicativas diretas; W é a matriz de pesos espaciais que define a conectividade entre unidades espaciais; $WX\theta$

representa o termo de defasagem espacial das variáveis independentes, com θ sendo o vetor de coeficientes que mede o impacto espacial das variáveis explicativas nas unidades vizinhas; μ é o termo de erro espacialmente autocorrelacionado; λ é o coeficiente de autocorrelação espacial nos erros, capturando a dependência espacial nos fatores não observados; ϵ é o termo de erro aleatório.

No modelo SDEM, a inclusão de $WX\theta$ permite capturar os efeitos de *spillover* (transbordamento) das variáveis explicativas, ou seja, como uma variável em uma região influencia diretamente a variável dependente em regiões vizinhas. Simultaneamente, a estrutura de erro $\lambda W\mu + \epsilon$ permite modelar a dependência espacial nos erros, representando a influência de fatores não observados que afetam unidades vizinhas de maneira correlacionada.

O SDEM é particularmente útil quando o interesse é avaliar tanto os efeitos espaciais indiretos das variáveis explicativas quanto à dependência espacial residual devido a fatores omitidos. Ele é aplicável em estudos onde as variáveis explicativas em uma região influenciam regiões adjacentes e, ao mesmo tempo, existem variáveis não observáveis com influência espacial. Por exemplo, em uma análise de oferta de crédito, como a aqui abordada, o valor de contrato em uma área pode ser afetado pelas características econômicas das áreas vizinhas ($WX\theta$), e fatores residuais não observados, como aspectos socioeconômicos gerais, podem criar uma correlação espacial nos erros (via $\lambda W\mu$).

2.2.10. Metodologia para Estimativa do Modelo SDEM Quantílico

O modelo de erro espacial distribuído quantílico (SDEM Quantílico) é uma extensão do modelo SDEM tradicional que permite capturar os impactos espaciais de variáveis explicativas e erros, considerando diferentes pontos da distribuição condicional da variável dependente. Essa abordagem é especialmente útil para analisar o Valor Bruto da Produção (VBP) agrícola no Brasil em 2023, uma vez que municípios com diferentes níveis de produção podem responder de forma distinta a fatores econômicos, estruturais e ambientais.

A especificação geral do modelo SDEM Quantílico para o VBP agrícola per capita (y_i) nos municípios é dada por:

$$Q_{\tau}(y_i|X, W) = X_i\beta_{\tau} + \lambda_{\tau}WX_i\theta_{\tau} + \epsilon_{i,\tau} \quad (9)$$

Onde: $Q_{\tau}(y_i|X, W)$ é o quantil τ condicional da variável dependente y_i dado o vetor de variáveis explicativas X e a matriz de pesos espaciais W ; X_i é o vetor de variáveis explicativas para o município i , incluindo crédito agrícola (por tipo, fonte e ano), variáveis climáticas, e variáveis regionais; β_{τ} é o vetor de coeficientes dos efeitos diretos das variáveis explicativas no quantil τ ; WX_i é a interação espacial das variáveis explicativas, modelando os efeitos dos vizinhos; λ_{τ} é o coeficiente que mede a força dos efeitos espaciais no quantil τ ; $\epsilon_{i,\tau}$ são os resíduos associados ao quantil τ .

O modelo SDEM Quantílico permite que os coeficientes β_{τ} e λ_{τ} variem ao longo da distribuição condicional da variável dependente, capturando heterogeneidade nos impactos. Assim, pode-se ter uma análise detalhada dos impactos diretos e espaciais dos créditos agrícolas sobre o VBP, considerando heterogeneidades entre municípios de diferentes níveis de produtividade. Essa abordagem é fundamental para orientar políticas públicas mais eficientes e equitativas, ajustadas às necessidades específicas de cada perfil de município no Brasil.

2.3.1. Testes de escolha e validação do modelo econométrico

Esta subseção se destina a apresentar os testes de escolha e validação dos modelos econométricos estimados para anteder as necessidades deste relatório. Os testes seguem a determinação da literatura para o uso deste método, conforme sugere Anselin, Serenini e Amaral (2024).

2.3.1.1. Aplicação dos Testes LM e LM Robustos em Econometria Espacial para Análise de Modelos OLS, SLX, SAR, SEM e SDEM.

Neste estudo, os testes de multiplicador de Lagrange (LM), criados por Godfrey (1978) e Breusch e Pagan (1979), sendo posteriormente adaptado por Anselin (1988) para a econometria espacial, suas variantes robustas foram aplicadas neste relatório de pesquisa para identificar a presença de autocorrelação espacial nos resíduos de modelos econométricos, especificamente voltados para o impacto do crédito sobre o valor bruto

da produção agrícola nos municípios em análise. Inicia-se a análise com o modelo OLS, aplicando os testes LM e LM robustos para detectar autocorrelação espacial nos resíduos. Em seguida, realiza-se uma estimativa do modelo SLX para verificar dependência espacial nas variáveis explicativas.

2.3.1.2. Objetivo do teste

O objetivo dos testes LM e LM robustos é validar a adequação do modelo OLS para capturar a estrutura dos dados ou, se necessário, indicar uma especificação mais complexa, como o SLX, SAR, SEM ou SDEM, conforme os padrões de autocorrelação espacial. Esses modelos buscam ajustar corretamente a influência do crédito no valor bruto da produção, considerando a possível interdependência espacial entre os dados.

2.3.1.3. Modelo OLS e Testes de Autocorrelação Espacial

A análise começa com a estimativa do modelo OLS e a aplicação dos testes LM e LM robusto para verificar a existência de autocorrelação espacial. Após os testes no modelo OLS, o modelo SLX é estimado para incluir defasagens espaciais nas variáveis explicativas, capturando potenciais efeitos de spillover espacial. Com o SLX, é possível verificar se o padrão espacial resulta das variáveis explicativas.

Assim, a estatística do teste LM foi aplicada ao OLS e ao SLX da seguinte forma:

$$LM_{SAR} = \frac{(e'W_e)^2}{(\sigma^2 e' M_e)} \quad (10)$$

$$LM_{SAR} = \frac{(e'WM_e)^2}{(\sigma^2 e' MW_e)} \quad (11)$$

Onde e representa os resíduos do modelo OLS e do SLX, W é a matriz de pesos espaciais, σ^2 é a variância e M é a matriz de projeção apropriada.

2.3.1.4. Testes LM Robustos

Os testes LM robustos são adaptações que consideram a presença simultânea de dependência espacial nos erros e nas variáveis explicativas. Para isso, são feitas as seguintes adaptações: para o teste LM robusto para SAR, onde este teste é calculado assumindo que não há dependência de erro espacial (SEM) presente, conforme equação abaixo.

$$LM_{SAR} = \frac{(e'W_e)^2}{\sigma^2(e'MW_e) - (e'MWW_e)_e} \quad (12)$$

Outrossim, para o teste LM robusto para SEM, em que este teste verifica a dependência espacial SEM (nos resíduos) assumindo a ausência de dependência SAR (na variável explicada), conforme equação matemática abaixo.

$$LM_{SAR} = \frac{(e'WM_e)^2}{\sigma^2(e'MW_e) - (e'MWW_e)_e} \quad (13)$$

De posse dos resultados, faz a escolha do modelo que melhor trata a autocorrelação espacial na variável dependente (SAR), nos resíduos (SEM) ou no conjunto de variáveis explicativas e nos resíduos (SDEM).

2.3.1.5. Modelos SAR, SEM e SDEM

Com base nos resultados dos testes LM e LM robustos, estende-se a análise aos modelos SAR, SEM e SDEM para captar dependências espaciais nas variáveis (SAR), nos erros (SEM) e em ambas as fontes (SDEM), conforme indicado.

2.3.1.6. Interpretação dos Resultados

Os resultados dos testes LM e LM robustos ajudaram a determinar o modelo adequado para os dados de valor bruto da produção e crédito. As conclusões incluem: Significância nos testes SAR e SEM no OLS: sugere que modelos como SAR, SEM ou SDEM podem capturar adequadamente a dependência espacial; Significância no SLX e

SDEM: indica que a dependência espacial está tanto nas variáveis explicativas quanto nos erros.

2.3.2.1. Testes de Randomização e Simulação de Monte Carlo

Em econometria espacial, os testes de randomização do índice de Moran dos resíduos e a simulação de Monte Carlo são métodos utilizados para avaliar a presença de autocorrelação espacial nos resíduos de um modelo econométrico, mesmo depois das correções anteriormente realizadas. Eles ajudam a verificar se há dependência espacial remanescente após a especificação do modelo, o que é essencial para garantir que as estimativas sejam robustas e as inferências estatísticas válidas.

$$LM = \left(\frac{(\sum_i \sum_j \omega_{ij} \epsilon_i \epsilon_j)^2}{\sigma^2 \sum_i (\sum_j \omega_{ij}^2)} \right) \quad (14)$$

Assim sendo, após a escolha do modelo, o índice de Moran dos resíduos é testado com randomização para confirmar a ausência de autocorrelação nos resíduos. A simulação de Monte Carlo, com 1000 interações, avalia a robustez das estimativas.

2.3.2.2. Testes de randomização do índice de Moran dos resíduos

O Índice de Moran é uma estatística que mede a autocorrelação espacial de uma variável, quantificando o grau de semelhança entre valores de uma variável em unidades geograficamente próximas. Ao aplicar o Índice de Moran aos resíduos de um modelo econométrico, o objetivo é verificar se ainda há um padrão espacial significativo, ou seja, se os resíduos apresentam dependência espacial não capturada pelo modelo.

O Teste de randomização do índice de Moran dos resíduos é realizado da seguinte maneira: calcula-se o índice de Moran para os resíduos observados do modelo ajustado. Em seguida, os valores da variável dependente (ou resíduos) são aleatoriamente redistribuídos entre as unidades espaciais, e o índice de Moran é recalculado para cada redistribuição; esse processo é repetido muitas vezes (geralmente milhares), construindo uma distribuição de referência do índice de Moran sob a hipótese nula de ausência de autocorrelação espacial; ao final, compara-se o índice de Moran observado com essa

distribuição de referência. Se o valor observado é significativamente diferente da média da distribuição aleatória, rejeita-se a hipótese nula de ausência de autocorrelação espacial, indicando que o modelo pode não ter capturado todos os efeitos espaciais relevantes.

2.3.2.3. Simulação de Monte Carlo

A simulação de Monte Carlo é um método estatístico que permite criar distribuições de probabilidade para variáveis estatísticas através de muitas repetições aleatórias. Em econometria espacial, ela é amplamente usada para testar a significância dos coeficientes espaciais e avaliar a robustez das estatísticas de autocorrelação, como o índice de Moran.

Na prática, a simulação de Monte Carlo realiza os seguintes passos: define-se uma hipótese ou modelo específico a ser testado (por exemplo, um modelo espacial sem autocorrelação nos erros); gera-se um grande número de amostras sintéticas ou distribuições possíveis, baseadas nos parâmetros do modelo especificado; calcula-se o índice de Moran (ou outra estatística de interesse) para cada amostra gerada, construindo uma distribuição empírica para a estatística sob a hipótese definida.

Esse método permite construir intervalos de confiança e distribuições de referência para as estatísticas, facilitando a verificação de hipóteses e a análise de significância. Quando aplicado ao índice de Moran dos resíduos, a simulação de Monte Carlo fornece uma avaliação robusta da presença de autocorrelação espacial, permitindo comparar o índice observado com uma distribuição simulada e determinar se a autocorrelação é estatisticamente significativa.

Em resumo, ambos os métodos ajudam a verificar a adequação do modelo ao contexto espacial, identificando possíveis lacunas no controle da dependência espacial e sugerindo a necessidade de ajustar o modelo para capturar os efeitos espaciais de maneira mais precisa.

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

Uma série de relevantes estudos internacionais têm apresentada a importância do crédito destinado à agricultura como um importante mecanismo de incentivo a produção. Esses estudos buscaram analisar em diversos países, como o acesso ao crédito pode ampliar o desempenho do setor agrícola, considerando-se as mais diversas abordagens metodológicas.

Nesse sentido, Saqib *et al.* (2018) procuraram entender os fatores que influenciam o acesso ao crédito agrícola em regiões propensas a inundações no Paquistão. Com metodologia de amostragem em múltiplos estágios e análise de regressão de mínimos quadrados ponderados, o estudo utilizou uma amostra de 168 agricultores em Khyber Pakhtunkhwa, coletando dados primários em 2017. Os resultados mostraram que fatores como educação, tamanho da propriedade e renda mensal têm impacto significativo no acesso ao crédito. Especificamente, agricultores com maior nível de educação tinham 20% mais chance de obter crédito. O estudo contribui ao fornecer recomendações para adaptação de políticas de crédito em áreas de risco. Limitações incluem a restrição geográfica, o que dificulta a generalização dos resultados para outras regiões.

Na mesma perspectiva analítica, mas com uso de método diferente, Chandio *et al.* (2019) estudaram a relação entre crédito agrícola, tamanho das propriedades e eficiência técnica na produção de arroz em Sindh, Paquistão, com dados de 180 produtores. A metodologia utilizou a fronteira estocástica de produção por meio de análise de Máxima Verossimilhança. O estudo revelou uma eficiência técnica média de 97%, com influência significativa do crédito à agricultura. Agricultores que tiveram acesso a crédito mostraram um aumento de 15% na produtividade, sendo, portanto, possível afirmar a importância do crédito à produção e à produtividade agrícola. O estudo contribui ao demonstrar o papel do crédito para melhorar a eficiência agrícola. Como limitação do estudo, incluem a restrição do estudo ao cultivo de arroz, limitando a generalização para outras culturas.

Autores como Mamatzakis e Staikouras (2020) avaliaram o impacto da crise de crédito de 2009 nos investimentos agrícolas na União Europeia. A metodologia incluiu o uso de dados microeconômicos do Farm Accountancy Data Network (FADN) e modelo VAR em painel, abrangendo 14 países membros da UE. O estudo apontou que choques negativos nas taxas de juros e passivos totais reduziram significativamente os investimentos no setor agrícola, especialmente na periferia da zona do euro. Como exemplo, uma redução de 5% nas taxas de juros poderia aumentar o investimento agrícola em até 3%. A contribuição do estudo está na análise detalhada dos efeitos do crédito para recuperação econômica da UE. Uma limitação à interpretação dos seus resultados, não permitindo extensão destes, é o fato de que o foco foi restrito a países da UE, o que limita sua aplicabilidade global, apesar de serem eles países representativos de economias desenvolvidas.

O trabalho de Moss e Suh (2020) buscaram estudar o impacto do Dodd-Frank Act, especificamente os custos de conformidade para bancos menores, na oferta de crédito agrícola nos Estados Unidos. Utilizando um modelo diferencial e análise de dados de 2010 a 2018, a pesquisa se concentrou nos Estados Unidos e usou dados de relatórios bancários. Os resultados mostraram que os custos de conformidade elevaram as despesas operacionais dos bancos, reduzindo a disponibilidade de crédito agrícola, especialmente em bancos comunitários. Um aumento de 10% nos custos regulatórios resultou em uma diminuição de 7% no crédito para o setor agrícola. O estudo contribui para a compreensão das barreiras regulatórias no crédito rural, mas limita-se ao contexto dos EUA e, em especial, a bancos comunitários.

Patel *et al.* (2021) propuseram o KRanTi, um esquema de crédito baseado em blockchain para agricultores no setor de cadeia de suprimentos agroalimentar na Índia. A metodologia envolveu o uso de tecnologia blockchain e IoT sobre rede 5G, com implementação de contratos inteligentes em Ethereum. Os resultados indicaram que o KRanTi aumentou a eficiência e a transparência, com uma redução de 12% no tempo de processamento de crédito. Com isso, afirma-se ser interessante o uso de mecanismos operacionais que facilitem o acesso, bem como o tempo de aquisição de recursos no sistema financeiro por parte dos agricultores. Este estudo contribui ao demonstrar o potencial do blockchain para otimizar o crédito agrícola. Limitações incluem desafios na adoção ampla de tecnologias blockchain devido aos altos custos de infraestrutura.

Mohsin *et al.* (2022) investigaram se a escala de crédito FinTech pode estimular as instituições financeiras a aumentar a proporção de empréstimos agrícolas. Utilizando um modelo de efeitos fixos individuais com dados em painel balanceados de 31 províncias e municípios chineses entre 2009 e 2017, o estudo revelou que o aumento do crédito FinTech eleva a participação de empréstimos agrícolas, embora a uma taxa marginal decrescente. O estudo também identificou que fatores de mercado e o desenvolvimento imobiliário influenciam indiretamente essa proporção por meio do crédito FinTech. As contribuições para a literatura incluem insights sobre a relação entre tecnologia financeira e financiamento agrícola, destacando a importância do crédito FinTech para a revitalização rural. Uma limitação apontada é o possível viés nos dados financeiros, que podem refletir condições específicas do contexto chinês.

Oloukoi (2022) analisou o efeito do crédito de curto prazo no valor agregado agrícola nos países da União Econômica e Monetária da África Ocidental (WAEMU), de 2000 a 2018. O estudo utilizou modelos VAR em painel e ARDL, analisando dados de fontes nacionais de cada um dos países estudados. Os resultados indicaram que o crédito só impulsiona o valor agregado a partir do terceiro ano, com efeito marginal no curto prazo. Um aumento de 5% no crédito de curto prazo mostrou-se eficaz apenas a longo prazo. A contribuição deste estudo está em sugerir políticas de juros baixos para o crédito agrícola. A limitação principal foi a análise restrita ao contexto da WAEMU, limitando a aplicabilidade em outras regiões.

Beaman *et al.* (2023) examinaram o processo de seleção no mercado de crédito agrícola em Mali, utilizando um experimento em duas etapas para avaliar a heterogeneidade nos retornos ao capital entre agricultores que recebem empréstimos versus os que não recebem. O estudo abrangeu 198 vilarejos, onde algumas localidades foram selecionadas para receber microcrédito, enquanto outras receberam subsídios em dinheiro como controle. Os resultados indicaram que os agricultores que tomaram empréstimos apresentaram retornos ao capital significativamente maiores, com impactos claros na produção e nos lucros agrícolas, enquanto aqueles que não pegaram empréstimos não demonstraram retornos significativos. A pesquisa contribui para a compreensão das falhas de mercado em países em desenvolvimento e suas implicações na alocação de capital, sendo uma de suas limitações a incapacidade de desagregar todos os fatores de seleção devido à complexidade do cenário agrícola em Mali.

Sher *et al.* (2023) analisaram o impacto do crédito sem juros na participação no mercado e no progresso tecnológico de pequenos agricultores no Paquistão. Utilizando dados de 637 famílias agrícolas, o estudo indicou que o crédito sem juros aumenta a participação no mercado, melhora os preços de venda e incentiva a adoção de variedades modernas de culturas. A pesquisa destaca o potencial do financiamento sustentável para integrar pequenos agricultores ao mercado e melhorar suas práticas agrícolas, com limitações que incluem a dependência de dados regionais que podem não ser representativos de outras regiões.

Olutumise (2023) investigou o impacto do crédito na intensidade de uso de estratégias de adaptação climática entre agricultores de alimentos no sudoeste da Nigéria, usando o modelo de regressão de Poisson com tratamento endógeno. Com dados de 150 agricultores, o estudo concluiu que o status de crédito impacta significativamente a intensidade de uso de estratégias adaptativas, destacando também fatores como educação e tamanho da propriedade. A pesquisa contribui ao analisar a relação entre crédito e adaptação climática em contextos específicos, sendo uma limitação a falta de abrangência para outras regiões do país.

Salima *et al.* (2023) investigaram o impacto do crédito formal e informal na segurança alimentar das famílias no Malawi, com dados da Pesquisa Integrada de Domicílios (2019-2020). Aplicando o modelo ERS e regressão Tobit, o estudo revelou que o crédito formal está associado a uma melhoria de 25% na segurança alimentar, enquanto o crédito informal a reduziu em 15%. O estudo sugere a expansão do crédito formal para melhorar a segurança alimentar no país. Limitações incluem a dificuldade de generalizar os resultados devido às particularidades socioeconômicas do Malawi.

Anofe *et al.* (2024) avaliaram o impacto do crédito bancário comercial no setor agrícola da Nigéria, de 1986 a 2022, com foco específico nas contribuições de várias subáreas agrícolas para o PIB real. A metodologia incluiu um design de pesquisa ex-post e a técnica de Auto-Regressive Distributed Lag (ARDL) para analisar os dados. Os achados revelaram que o crédito tem um efeito significativo apenas na produção de gado, sem efeitos substanciais em outras áreas como produção de culturas, silvicultura e pesca. A pesquisa destaca a necessidade de uma política mais robusta para incentivar a alocação de crédito a setores subrepresentados, com limitações relacionadas à falta de dados

granulares que poderiam oferecer maior detalhamento das relações entre crédito e produção agrícola.

3.2. Crédito agrícola no Brasil

Esta subseção aborda uma revisão de estudos recentes acerca do crédito e da produção agrícola no Brasil. Os estudos buscam evidências dos impactos do crédito sobre a produção da agricultura nacional sob as mais diversas metodologias analíticas.

O estudo de Trindade e Cruz (2019) examinam o crédito rural agrícola no Brasil, considerando o impacto desse recurso sobre a expansão da produção agrícola entre 2000 e 2010. O estudo utiliza indicadores de concentração, especialização, localização e desigualdade para analisar a distribuição do crédito rural agrícola em nível nacional, com ênfase nas macrorregiões definidas pelo IBGE e com foco no recorte municipal. Os resultados indicam uma alta concentração do crédito nas regiões Sul e Sudeste, enquanto a Região Norte teve uma participação reduzida, aumentando de 0,5% para 0,7% no período. Aproximadamente 84% dos municípios com alta disponibilidade de crédito agrícola estão no Sul e Sudeste, destacando a necessidade de políticas públicas regionalizadas para melhorar o acesso ao crédito no Norte e Nordeste. A contribuição principal do estudo é a análise detalhada da concentração regional do crédito agrícola, que fornece subsídios para o desenvolvimento de políticas de crédito mais inclusivas. Como limitação, o estudo abrange apenas uma década, o que restringe a observação dos efeitos em longo prazo das mudanças na distribuição de crédito.

Carrera *et al.* (2020) avaliam a efetividade da política de crédito rural na promoção da adoção de sistemas de integração lavoura-pecuária no Brasil, com base em uma pesquisa com 175 agricultores no estado de São Paulo. A análise utilizou dados primários de entrevistas e dados secundários sobre políticas de crédito rural, focando no estado de São Paulo. Os resultados apontam que o crédito rural exerce um impacto positivo na adoção desses sistemas, especialmente em áreas com infraestrutura de mercado e assistência técnica adequada. Como contribuição, o estudo identifica fatores que facilitam a adoção de sistemas de produção sustentáveis, apoiando políticas voltadas para a mitigação de emissões. Uma limitação do estudo é a restrição da amostra a São Paulo, o que limita a generalização dos resultados para outras regiões brasileiras.

Zeller e Schiesari (2020) investigam os fatores que determinam a alocação desigual dos recursos do Pronaf entre os municípios brasileiros. Utilizando regressões econométricas e entrevistas com especialistas, o estudo emprega dados de crédito rural do Pronaf e entrevistas abrangendo municípios de todo o Brasil. Os resultados indicam que municípios mais ricos e agricultores com maior conhecimento tendem a receber uma intensidade maior de crédito, enquanto áreas de alto risco recebem menos recursos. O estudo contribui ao apontar melhorias na infraestrutura e na capacitação agrícola como meios para uma alocação mais equitativa dos recursos do Pronaf. No entanto, o foco exclusivo na desigualdade de acesso ao crédito limita a análise de outros aspectos do Pronaf.

Borges e Parré (2022) investigam a relação entre o crédito rural e o produto agropecuário brasileiro entre 1999 e 2018. Utilizando metodologias de Vetores Autorregressivos (VAR), causalidade de Granger e métodos de mínimos quadrados ordinários e generalizados, o estudo avalia o impacto do crédito rural total sobre o PIB agropecuário e estima uma relação ótima de crédito que maximiza esse produto. Os resultados mostram que o crédito rural teve um impacto positivo de 0,20% no produto agropecuário e que a causalidade Granger indica uma relação unidirecional, com o crédito rural precedendo o PIB agropecuário. A contribuição do estudo reside em quantificar essa relação e sugerir um valor ótimo de crédito rural de aproximadamente R\$ 58 bilhões por trimestre para maximizar o produto agropecuário. A limitação está no contexto de racionamento de crédito no país, que pode restringir o alcance pleno dos benefícios do crédito rural para a produção.

Souza *et al.* (2022) analisam o impacto do crédito rural na produção agrícola brasileira no período de 2006 a 2014, enfocando a contribuição desse financiamento para o desenvolvimento agrícola. A metodologia empregada envolve a análise de dados quantitativos das linhas de crédito disponibilizadas ao setor agrícola, com um recorte geográfico que abrange todo o Brasil. Os resultados sugerem que o crédito rural tem um impacto positivo e significativo na produção agrícola, com variações no efeito de acordo com o tipo de cultura financiada e a região do país. O estudo contribui para a literatura ao evidenciar como o crédito rural influencia a produtividade e o crescimento da agricultura brasileira, embora uma das limitações seja a falta de uma análise sobre o impacto do crédito em longo prazo após o período estudado.

Almeida e Cruz (2022) exploram o impacto do crédito rural no desenvolvimento da agricultura brasileira, com foco na relação entre os recursos financeiros disponíveis e o crescimento econômico agrícola. Utilizando uma abordagem empírica baseada em análise quantitativa, o estudo considera um período estendido de dados para avaliar o efeito do crédito em várias dimensões da atividade agrícola, incluindo produtividade e investimentos. Os achados indicam que o crédito rural tem um papel fundamental na expansão agrícola, principalmente em culturas com maior valor agregado. A principal contribuição do estudo é a identificação do crédito como elemento essencial para o fortalecimento da agricultura familiar e comercial, embora a limitação seja a ausência de uma análise comparativa entre diferentes tipos de financiamento rural e seus respectivos impactos.

Santos *et al.* (2023) analisam o papel das políticas de crédito rural na geração de renda agrícola em propriedades familiares no estado de Pernambuco. Com uma análise espacial e de tendências, o estudo utiliza dados do Pronaf e observa a distribuição de tipos de estabelecimentos agrícolas entre 2006 e 2017. Os resultados apontam um enfraquecimento do potencial produtivo em algumas áreas e a relevância do crédito no desenvolvimento de atividades de geração de renda para diversos tipos de estabelecimentos familiares. A contribuição do estudo está em destacar a importância do crédito rural para o desenvolvimento regional. Contudo, a análise focada em Pernambuco limita a extrapolação dos resultados para outras regiões brasileiras.

André e Ramos (2023) analisam o impacto do Fundo Amazônia na redução do desmatamento na Amazônia Legal, empregando um modelo de Vetores Autorregressivos em Panel. Utilizando dados de observação por satélite e microeconômicos, o estudo abrange 760 municípios da Amazônia Legal no Brasil entre 2002 e 2020. Os resultados indicam que os desembolsos do Fundo Amazônia contribuem para a redução das taxas de desmatamento, sendo mais eficazes em projetos geridos por governos estaduais e focados no planejamento do uso da terra e proteção de comunidades locais. Este estudo oferece evidências quantitativas sobre a eficácia do Fundo Amazônia na mitigação do desmatamento, embora existam desafios para distinguir seu impacto das outras políticas ambientais implementadas pelo governo brasileiro.

Silva Filho *et al.* (2024) examinam os impactos do crédito fornecido pelos Fundos Constitucionais de Financiamento sobre a produção agrícola dos municípios das regiões

Norte, Nordeste e Centro-Oeste do Brasil, no período de 2016 a 2019. Utilizando econometria espacial, os autores investigam a existência de efeitos de transbordamento espacial do crédito e controlam variáveis como participação da agricultura na economia municipal, uso de máquinas e volume de chuva, além de adicionar crédito do BNDES para evitar vieses nos coeficientes. Os resultados mostram que os financiamentos têm efeito positivo, embora limitado, sobre a produção agrícola local, sem efeitos de transbordamento para municípios vizinhos. A contribuição do estudo está em fornecer uma análise detalhada dos impactos do crédito nas regiões economicamente menos desenvolvidas, ressaltando a importância do crédito público para a atividade agrícola. A principal limitação reside na abrangência limitada do efeito positivo, que se restringe ao município que recebeu o crédito e ao exercício do financiamento, sem impacto em longo prazo ou nos municípios adjacentes.

Silva Filho *et al.* (2024) exploram o efeito do crédito público concedido por Fundos Constitucionais e pelo BNDES sobre o Valor Bruto da Produção Agrícola (VBP) na região do Matopiba, cobrindo o período de 2016 a 2018. Com o uso de modelos de econometria espacial, observou-se que o crédito dos Fundos apresenta efeito positivo sobre o VBP, com impacto de 0,039% sobre o VBP agrícola de 2019 para cada 1% de aumento no crédito acumulado de 2016 a 2018, enquanto os financiamentos do BNDES têm um impacto inferior. A pesquisa delimita sua área de abrangência à região do Matopiba devido à importância desta para a produção de grãos nacional e aos desafios econômicos locais. Entre as principais contribuições, o estudo destaca o papel do crédito para o desenvolvimento agrícola regional, mas aponta a limitação de que o efeito positivo é marginal e restrito ao próprio município que recebe o crédito, sem transbordamentos para áreas vizinhas.

Silva Filho *et al.* (2024) investigaram os efeitos do crédito agrícola sobre o valor bruto da produção agrícola (VBP) no Nordeste do Brasil, utilizando uma abordagem de econometria espacial. O estudo analisou dados municipais, identificando impactos positivos e significativos do crédito, concedido por meio de Fundos Constitucionais e pelo BNDES, na produção agrícola. Utilizando o Modelo Espacial Durbin de Erro (SDEM), o estudo confirmou que fatores como crédito, precipitação, mecanização e fertilização contribuíram para o aumento do VBP na região. Este estudo contribui para a literatura ao integrar variáveis espaciais no entendimento do impacto do crédito, com

Objetivo 4 da PNDR e a diversificação, agregação de valor e sustentabilidade em cadeias produtivas agrícolas no Cerrado



limitações quanto à aplicação de dados regionais que podem não ser generalizáveis para outras regiões.

4. RESULTADOS E DISCUSSÕES

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

4.1. PANORAMA DA LAVOURA TEMPORÁRIA NO BRASIL

Esta seção apresenta estatísticas descritivas em percentuais, bem como a participação de cada uma das culturas estudadas em valores percentuais por municípios brasileiros, adicionadas do Quociente Locacional (QL) e do índice de Moram Global e local, considerando-se a produção ao largo de todo o território nacional, bem como estimativas de modelos econométricos espaciais.

4.1.1. Distribuição percentual da produção nos municípios brasileiros

O Brasil possui 5.570 municípios, e, ao analisar a distribuição do Valor Bruto da Produção (VBP) agrícola (Figura 1), podem-se identificar quantos municípios cultivam algodão, cana-de-açúcar, milho e soja, assim como o percentual de municípios em cada faixa de contribuição ao VBP agrícola para cada cultura. Esses dados se referem à média entre os anos de 2019 e 2023, período contemplado neste relatório de pesquisa.

Para o algodão, ao todo, 497 municípios cultivam essa cultura no Brasil. Na faixa de até 5% do VBP agrícola, temos 375 municípios, representando 75,5% dos municípios produtores de algodão. Entre 5,1% e 10% do VBP, 43 municípios (8,7%) estão nesta faixa. Na faixa de 10,1% a 25%, há 46 municípios (9,3%). De 25,1% a 50% do VBP agrícola, estão 27 municípios (5,4%). Em faixas mais elevadas, 3 municípios (0,6%) estão entre 50,1% e 75%, e outros 3 municípios (0,6%) têm entre 75,1% e 100% do VBP agrícola dedicado ao algodão. Os dados sugerem que, mesmo que a cultura do algodão seja importante para a produção nacional e para a oferta de fibra ao setor têxtil nacional, bem como ao comércio têxtil, este setor não se apresenta como um grande impulsionador da economia de muitos municípios no país. Sua produção é concentrada em poucos municípios e pouco especializada nesta única cultura.

A cana-de-açúcar é produzida em um total de 3.403 municípios. Destes, 1.688 municípios (49,6%) estão na faixa daqueles que contêm até 5% do VBP agrícola

relacionado à cultura da cana-de-açúcar. Entre 5,1% e 10% do VBP relacionado à venda de cana-de-açúcar, encontram-se 251 municípios (7,4%). Na faixa de 10,1% a 25%, estão 414 municípios (12,2%). Para 25,1% a 50% do VBP agrícola (cana-de-açúcar), há 344 municípios (10,1%). Na faixa de 50,1% a 75%, tem-se 218 municípios (6,4%), e, com percentuais entre 75,1% e 100%, estão 488 municípios (14,3%). Pela plotagem é pertinente destacar a importância dos municípios da Zona da Mata nordestina, bem como parcela substancial de municípios do Estado de São Paulo.

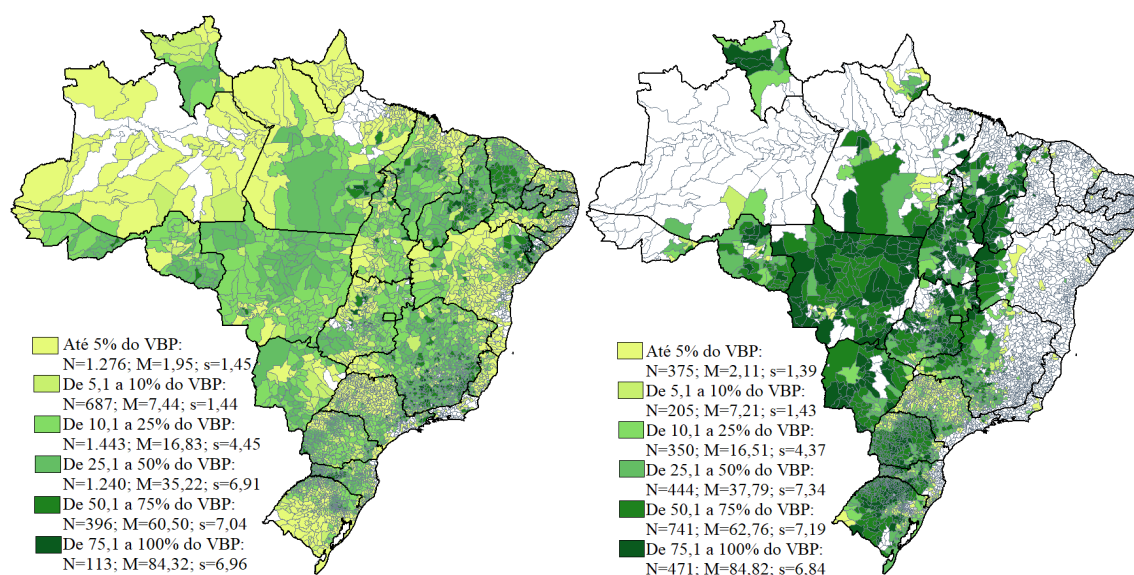
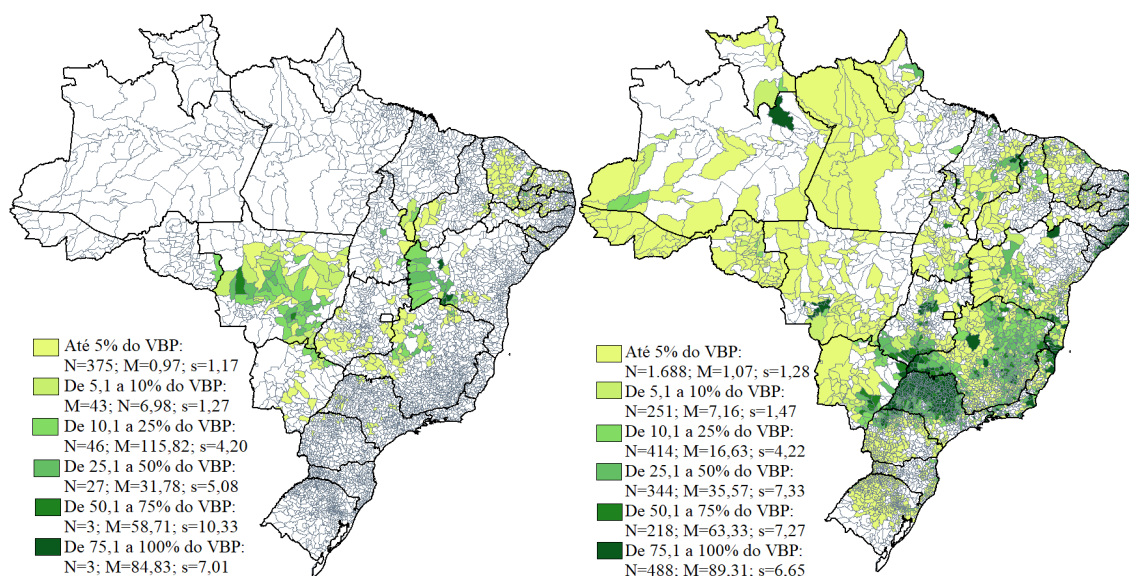


Figura 1: participação percentual de cada cultura no valor bruto da produção nos municípios brasileiros 2019-2023.

Em relação ao milho, 5.155 municípios no Brasil produzem essa cultura, sendo essa a de maior taxa de cobertura nacional, já em muitos dos municípios brasileiros não se produz para comercialização, mas para alimentação de pequenos animais de criação doméstica, sendo o excedente vendido em feiras locais. Na faixa de até 5% do VBP agrícola relacionado à produção e venda de milho, registraram-se 1.276 municípios (24,8%). Entre 5,1% e 10%, 687 municípios (13,3%) se encontram nessa faixa. Na faixa de 10,1% a 25%, há 1.443 municípios (28%). Entre 25,1% e 50%, estão 1.240 municípios (24%). Para 50,1% a 75%, temos 396 municípios (7,7%), e, com percentuais de 75,1% a 100%, há 113 municípios (2,2%). A produção de milho em escala comercial ocorre sobremaneira nas regiões de produção de oleaginosas para comércio internacional, sendo o Centro-oeste, o Matopiba e região Sul as grades áreas produtoras nacionais.

Por fim, a soja é cultivada em um total de 2.586 municípios. Destes, 375 municípios (14,5%) têm até 5% do VBP agrícola proveniente da soja. Na faixa de 5,1% a 10%, encontram-se 205 municípios (7,9%). Entre 10,1% e 25%, estão 350 municípios (13,5%). Na faixa de 25,1% a 50%, tem-se 444 municípios (17,2%). Entre 50,1% e 75%, encontram-se 741 municípios (28,7%), e, com percentuais entre 75,1% e 100%, estão 471 municípios (18,2%). Esta oleaginosa é produzida sobremaneira no Sul, centro-oeste e região do Matopiba no território brasileiro com avanço mais recente para o Norte do País. Dado a sua demanda internacional, esta commodity é produzida nas cinco regiões brasileiras, mas especializadas nas áreas do circuito da produção de oleaginosas com destino ao setor externo.

Esses percentuais detalhados mostram a distribuição do cultivo de cada cultura entre os municípios brasileiros, evidenciando como certas culturas como o milho e a soja, se espalham amplamente em todas as faixas de participação no VBP agrícola, sendo elas fortemente relacionadas ao comércio internacional (Sossa e Duarte, 2019; Pires, 2023), enquanto outras, como o algodão, têm uma concentração menor e em faixas específicas.

4.1.2. Quociente Locacional do algodão, cana-de-açúcar, milho e soja nos municípios brasileiros.

O QL é uma medida de concentração relativa de uma atividade dentro de um território analisado. Aqui, a análise do quociente locacional (QL) das culturas de algodão, cana-de-açúcar, milho e soja nos municípios brasileiros permite avaliar o nível de especialização agrícola nas regiões entre 2019 e 2023 (Figura 2). O QL classifica os municípios com valores entre 0 e 0,49 como de baixa concentração, entre 0,50 e 0,99 como de concentração média, e maior que 1 como de alta concentração em cada cultura. No caso do algodão, foram registrados 124 municípios com QL maior que 1, representando uma alta concentração, com média de QL de 4,04 e desvio padrão de 2,03, o que corresponde a aproximadamente 25% dos municípios que cultivam algodão. Já os municípios com QL médio, entre 0,50 e 0,99, totalizam 282 (aproximadamente 56,7%), com média de QL de 0,75 e desvio padrão de 0,15. Por fim, 319 municípios, ou cerca de 64,2% dos produtores de algodão, possuem QL entre 0 e 0,49, com média de 0,12 e desvio padrão de 0,12. Os dados sugerem que a produção de algodão em larga escala no Brasil é concentrada em poucos municípios do país, ao contrário das demais culturas analisadas que tem um leque de produção em mais territórios.

Para a cana-de-açúcar, a alta especialização ($QL > 1$) foi identificada em 1.316 municípios, representando aproximadamente 38,7% dos municípios produtores de cana. Esses municípios apresentaram média de QL de 4,05 e desvio padrão de 3,43. Já na faixa intermediária de QL, entre 0,50 e 0,99, estão 503 municípios (cerca de 14,8%), com média de 0,77 e desvio padrão de 0,15. Por outro lado, a maior parte dos municípios produtores de cana-de-açúcar, 1.830 (aproximadamente 53,8%), estão na faixa de baixo QL, entre 0 e 0,49, com média de 0,10 e desvio padrão de 0,12, o que evidencia uma baixa concentração dessa cultura em diversas áreas. Destacam-se nessa cultura município da Zona da Mata nordestina e do estado de São Paulo, sobretudo, além de áreas não tradicionais da produção conforme destacou Vedana *et al.* (2020).

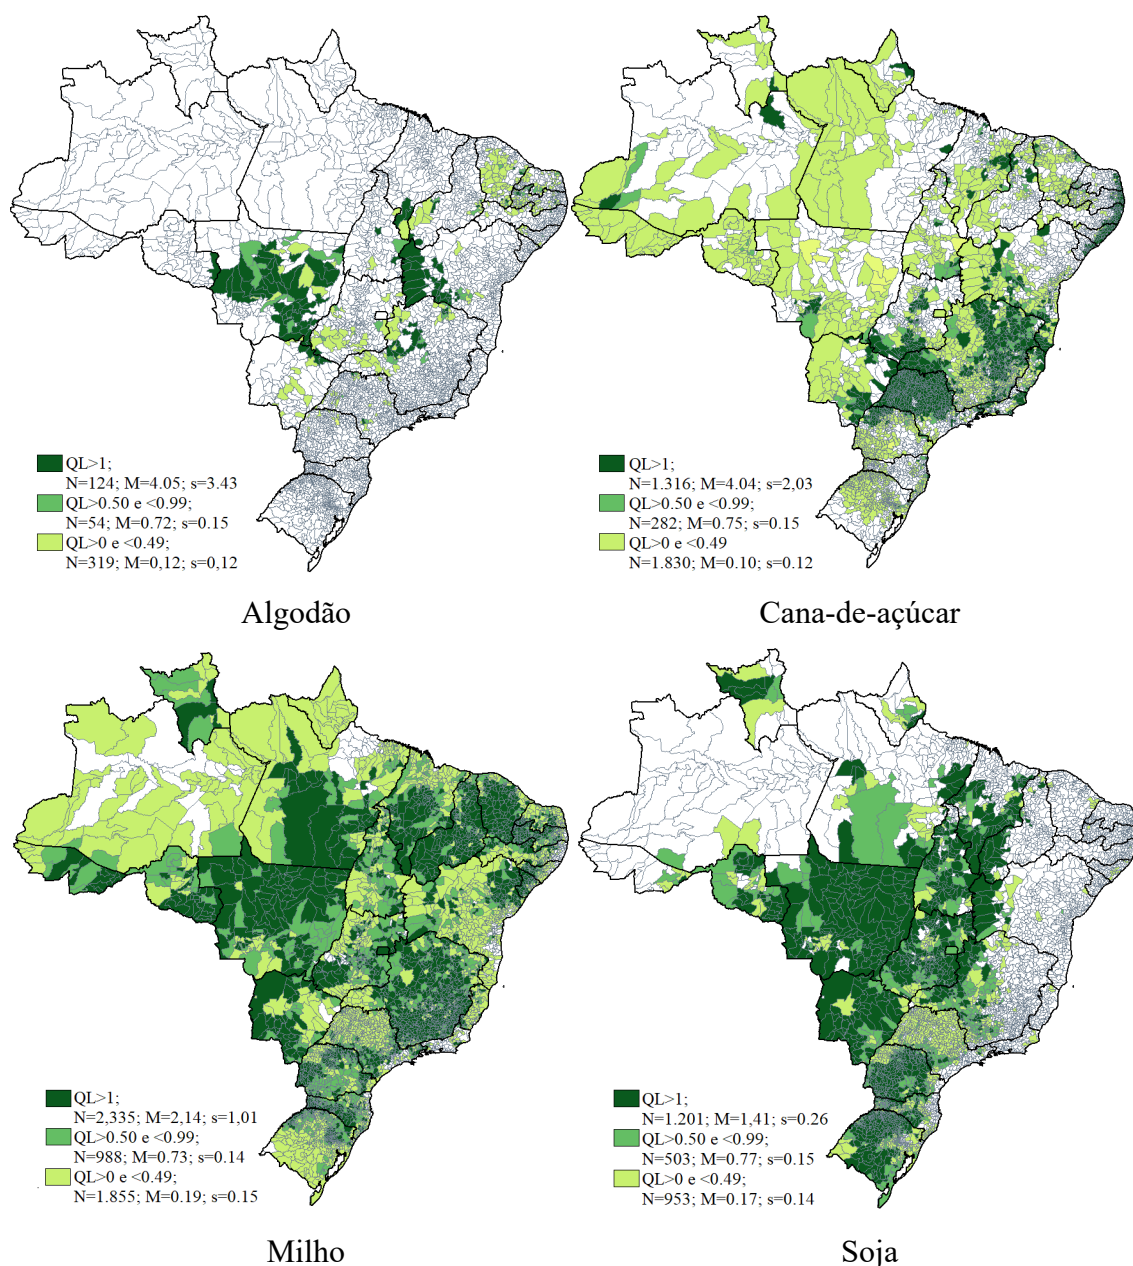


Figura 2: Quociente Locacional das culturas de lavoura temporária nos municípios dos brasileiros – 2019-2023

A cultura do milho apresenta um alto nível de especialização regional, com 2.335 municípios (cerca de 45,3% dos produtores) com QL maior que 1, média de 2,14 e desvio padrão de 1,01. Os municípios com concentração média de milho (QL de 0,50 a 0,99) somam 988, representando aproximadamente 19,2% dos produtores, com média de 0,73 e desvio padrão de 0,145. No entanto, 1.855 municípios (36% dos produtores) apresentam QL baixo, entre 0 e 0,49, com média de 0,19 e desvio padrão de 0,15, indicando que o

milho é amplamente cultivado com intensidades variáveis em diferentes regiões. Assim, mesmo com distribuição geográfica da produção ao largo do território nacional, muito dos municípios produzem em menor escala, não sendo eles especializados nessa cultura.

Por fim, a soja mostra alta concentração em 1.201 municípios (46,5% dos produtores), com QL superior a 1, média de 1,41 e desvio padrão de 0,26, refletindo a especialização regional dessa cultura nos municípios de sua área de produção. Na faixa de QL médio, entre 0,50 e 0,99, encontram-se 988 municípios, ou cerca de 38,2% dos produtores, com média de 0,73 e desvio padrão de 0,14. Já os municípios com baixo QL, maior que 0 a até 0,49, somam 953, correspondendo a 15,3% dos produtores de soja, com média de 0,17 e desvio padrão de 0,14. Esses dados destacam a importância da soja para a economia agrícola em grande parte dos municípios brasileiros, especialmente nas regiões de alta especialização, sobretudo destinadas ao comércio exterior (De Souza Ribeiro e Da Silva Filho 2024).

4.1.3. 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 total nos – 2020-2023; distribuição espacial do crédito total à agricultura – 2020-2023; o valor bruto da produção per capita – 2020-2023; distribuição espacial do crédito per capita à agricultura – 2020-2023; distribuição espacial da razão VBP crédito à agricultura nos – 2020-2023; distribuição espacial da razão VBP ocupados formais na lavoura temporária – 2020-2023.

Conforme Figura 3, abaixo, no ano de 2020, dos 5.570 municípios brasileiros, 2.186 (39,2%) pertenciam ao cluster alto-alto, formado pelo índice LISA para o valor bruto da produção (VBP) agrícola brasileira, com predominância nas regiões Sudeste, Sul e Centro-Oeste, indicando uma maior concentração da produção agrícola nessas áreas. Este agrupamento alto-alto reflete a relevância da produção nessas regiões, que apresentaram um impacto significativo no VBP nacional. Em contraste, o cluster baixo-baixo, composto por 1.072 municípios (19,2%), também identificado pelo índice LISA, destacou-se nas regiões Norte e Nordeste, onde a participação no VBP agrícola era menos expressiva. Esse padrão espacial evidencia uma divisão regional no Brasil, com alta concentração produtiva agrícola em algumas regiões e menor intensidade em outras. Por oportuno, a região Norte é uma vasta área de proteção nacional, apesar das questões climáticas

favoráveis, e, o Nordeste, destaca-se pela alta escassez de chuvas, o que compromete o desenvolvimento de agricultura na maior parte da região, sobretudo na área Semiárida, que depende sobremaneira de transformações estruturais para o desempenho agrícola. Assim, predomina, pois, nesta região, a agricultura de cerqueiro.

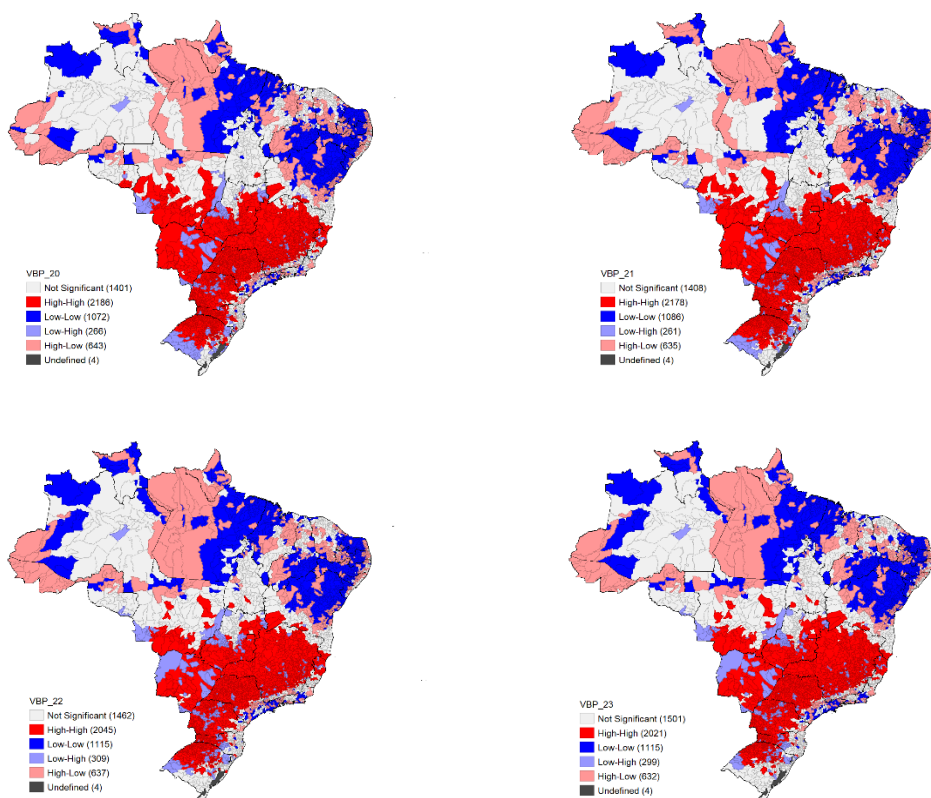


Figura 3: índice LISA para o valor bruto da produção total nos municípios brasileiros – 2020-2023

Nos anos subsequentes, de 2021 a 2022, observou-se um padrão espacial semelhante ao de 2020, mantendo-se a divisão entre as áreas de alta e baixa concentração agrícola. Em 2023, esse cenário persistiu, com 2.021 municípios (36,3%) no cluster alto-alto, concentrados nas regiões Sudeste, Sul e Centro-Oeste, e 1.115 municípios (20%) no cluster baixo-baixo, com maior presença nas regiões Norte e Nordeste. A análise do índice LISA para o VBP agrícola no Brasil evidencia, assim, uma polarização norte-sul que reflete as diferenças regionais na concentração e importância da produção agrícola entre os municípios brasileiros. Essa polarização é resultado de questões edafoclimáticas, bem

como questões institucionais relacionadas ao desenvolvimento das atividades nestas regiões.

O Índice Local de Associação Espacial (LISA) (Figura 4) aplicado à distribuição do crédito total destinado à agricultura nos municípios brasileiros revela padrões de concentração regional significativos entre 2020 e 2023. Em 2020, dos 5.570 municípios brasileiros, 1.249 (22,42%) estavam no cluster alto-alto, indicando áreas com altos níveis de crédito agrícolas rodeadas por outros municípios de alta concentração de crédito, conforme também foi constatado em Trindade e Cruz (2019). Esses municípios de alta concentração estavam predominantemente nas regiões Sul, Sudeste e Centro-Oeste, com destaque especial para o Matopiba, região que se estende pelos estados do Norte e Nordeste e que reflete uma consolidação de investimentos agrícolas estratégicos. Em contrapartida, o cluster baixo-baixo, representando baixa concessão de crédito agrícola, concentrava-se em 817 municípios (14,67%) das regiões Norte e Nordeste, sinalizando um maior desafio de acesso ao crédito nessas áreas.

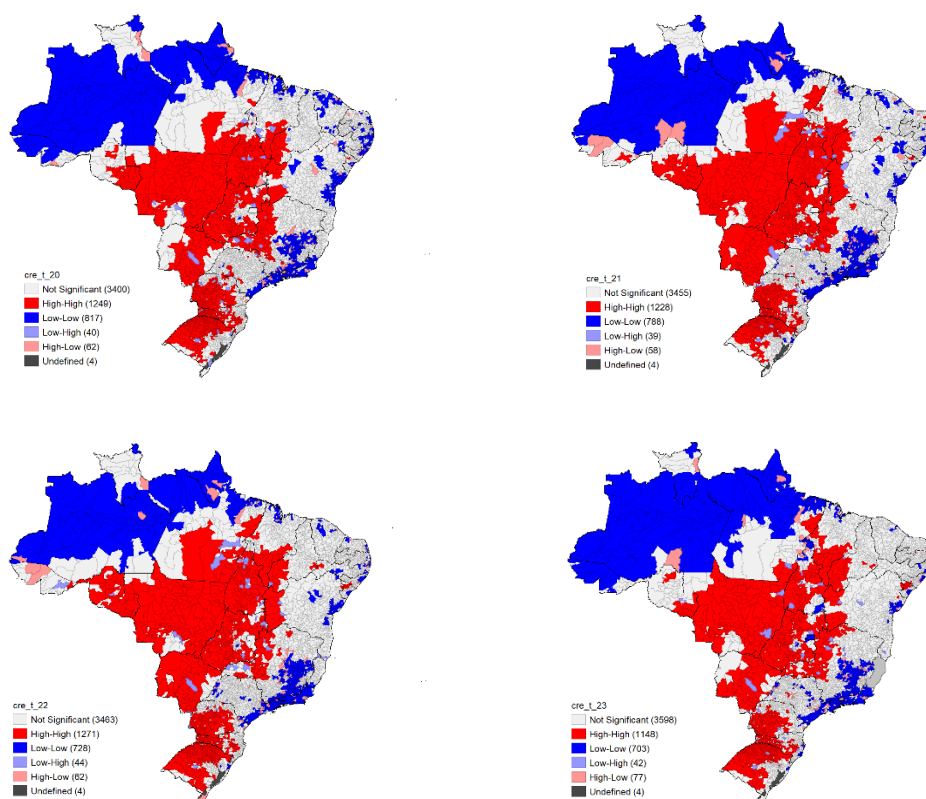


Figura 4: índice LISA da distribuição espacial do crédito total à agricultura nos municípios brasileiros – 2020-2023

Em 2023, a distribuição espacial do crédito agrícola manteve um padrão semelhante, embora com uma leve redução no número de municípios no cluster alto-alto, que passou a incluir 1.148 municípios (20,61%), ainda concentrados nas regiões Sul, Sudeste, Centro-Oeste e no Matopiba, convergindo com Zeller e Schiesari (2020). O cluster baixo-baixo também apresentou uma diminuição, com 703 municípios (12,62%) novamente concentrados no Norte e Nordeste. Esses percentuais mostram uma persistência de disparidades regionais no acesso ao crédito agrícola, com maior disponibilidade nas regiões economicamente mais desenvolvidas e uma contínua dificuldade para municípios menos favorecidos economicamente, reforçando a necessidade de políticas mais equitativas para a concessão de crédito no setor agrícola.

É oportuno destacar que os valores per capita são bastante representativos da dinâmica da produção e dos aspectos demográficos regionais; e, dessa forma, a Figura 5, abaixo trás essa representatividade. Assim, é oportuno destacar que em 2020, de um total de 5.570 municípios brasileiros, 1.575 (28,3%) estavam no cluster alto-alto, conforme o índice LISA para o valor bruto da produção (VBP) agrícola per capita, com maior concentração nas regiões Sudeste, Sul e Centro-Oeste. Esse grupo destaca-se pela expressiva participação no VBP agrícola per capita, refletindo uma alta produtividade média nessas regiões. Em contrapartida, o cluster baixo-baixo, que representou 1.832 municípios (32,9%), foi dominado pelas regiões Norte e Nordeste, evidenciando a menor intensidade da produção agrícola per capita nesses locais. Esse contraste espacial, portanto, marca uma diferença clara entre as regiões brasileiras em termos de produção agrícola per capita.

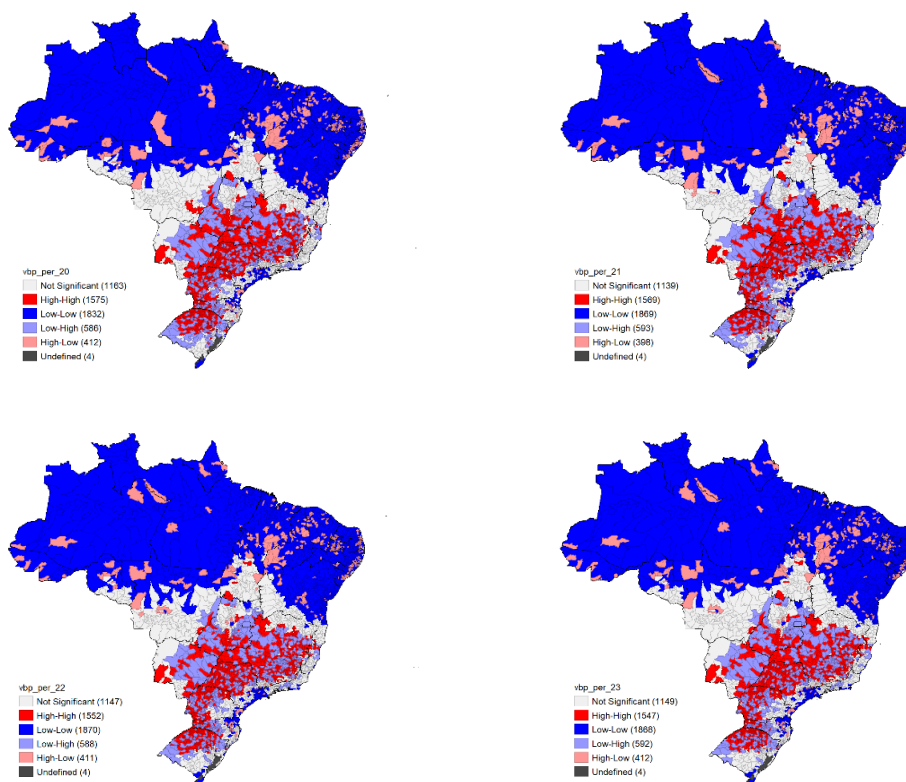


Figura 5: índice LISA para o valor bruto da produção per capita nos municípios brasileiros – 2020-2023

Nos anos de 2021 e 2022, o padrão espacial observado foi semelhante ao de 2020, mantendo a estrutura dos clusters. Em 2023, o índice LISA continuou a apontar uma polarização entre o norte e o sul do Brasil no VBP agrícola per capita, com 1.547 municípios (27,8%) no cluster alto-alto, localizados principalmente nas regiões Sudeste, Sul e Centro-Oeste, e 1.864 municípios (33,5%) no cluster baixo-baixo, concentrados nas regiões Norte e Nordeste. Essa divisão evidencia a continuidade das disparidades regionais na produção agrícola, refletindo uma polarização consistente entre as regiões com alta e baixa produtividade per capita no setor agrícola brasileiro.

Da mesma forma, a Figura 6, abaixo apresenta a distribuição espacial do crédito em valões per capita. Em 2020, dos 5.570 municípios brasileiros, 1.973 (35,4%) estavam no cluster alto-alto, conforme determinado pelo índice LISA para a distribuição espacial do crédito per capita destinado à agricultura, com predominância nas regiões Sudeste, Sul e Centro-Oeste, além dos municípios na área do Matopiba, um importante polo do agronegócio brasileiro, que engloba municípios dos estados do Nordeste e do Norte do

país. Esse agrupamento indica que o crédito per capita à agricultura é mais concentrado nessas áreas, refletindo a importância econômica dessas regiões para o setor agrícola nacional. Em contraste, o cluster baixo-baixo, com 1.956 municípios (35,1%), era composto majoritariamente por municípios das regiões Norte e Nordeste, onde a disponibilidade de crédito per capita para a agricultura é menor, evidenciando um contraste significativo entre as diferentes partes do Brasil em termos de acesso ao crédito agrícola.

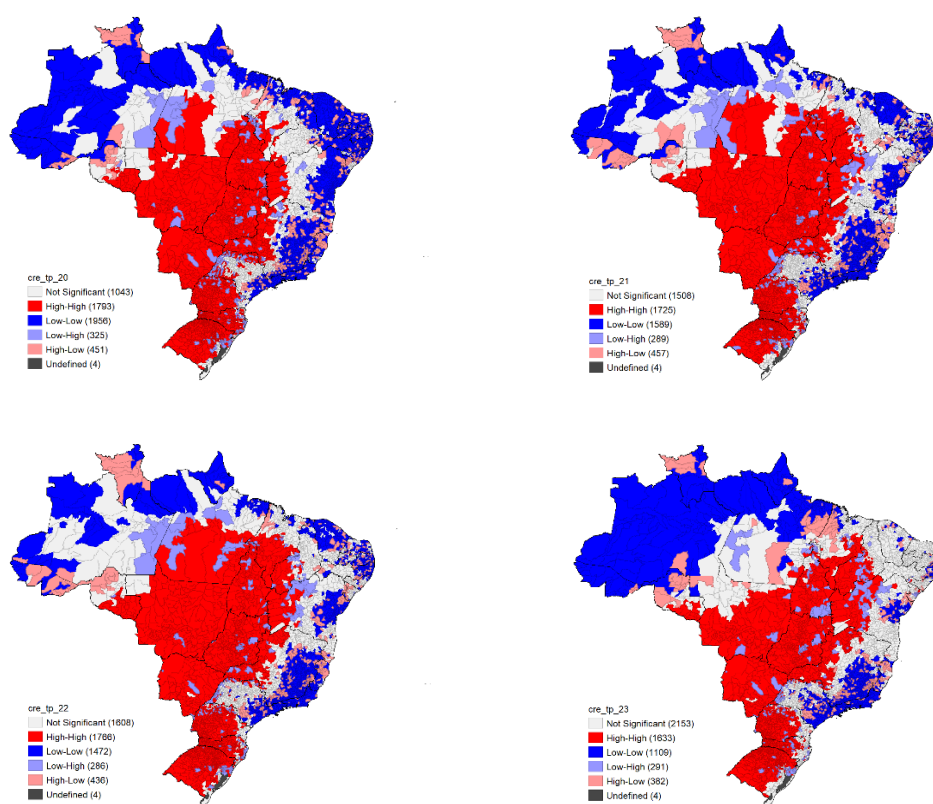


Figura 6: índice LISA da distribuição espacial do crédito per capita à agricultura nos municípios brasileiros – 2020-2023

Nos anos de 2021 e 2022, o padrão espacial permaneceu semelhante ao de 2020, consolidando a divisão regional no acesso ao crédito per capita agrícola. Em 2023, o índice LISA continuou a destacar essa polarização norte-sul, com 1.633 municípios (29,3%) no cluster alto-alto, concentrados nas regiões Sudeste, Sul e Centro-Oeste, enquanto 1.109 municípios (19,9%) estavam no cluster baixo-baixo, incluindo, além das regiões Norte e Nordeste, alguns municípios da faixa litorânea do país. Esse padrão revela

a continuidade das disparidades regionais, onde o crédito per capita agrícola permanece mais acessível no Sul e Sudeste, enquanto o Norte e Nordeste enfrentam maiores limitações no acesso, reforçando a diferença de suporte financeiro entre essas regiões para o setor agrícola.

No que diz respeito à razão VBP/crédito (per capita), a Figura 7, abaixo, apresenta os resultados para o recorte temporal em apreço. Em 2020, dos 5.570 municípios brasileiros, 1051 (18,9%) estavam no cluster alto-alto, conforme determinado pelo índice LISA para a razão entre o valor bruto da produção (VBP) agrícola per capita e a disponibilização do crédito a este setor, com predominância nas regiões Sudeste, Sul e Centro-Oeste. Esse agrupamento sugere que esses municípios possuem uma alta relação entre produção agrícola per capita e crédito. Em contraste, o cluster baixo-baixo, com 1.670 municípios (30%), foi composto majoritariamente por municípios das regiões Norte e Nordeste, onde o VBP agrícola per capita em relação ao crédito é consideravelmente menor, indicando uma menor intensidade produtiva por desembolso nessas regiões.

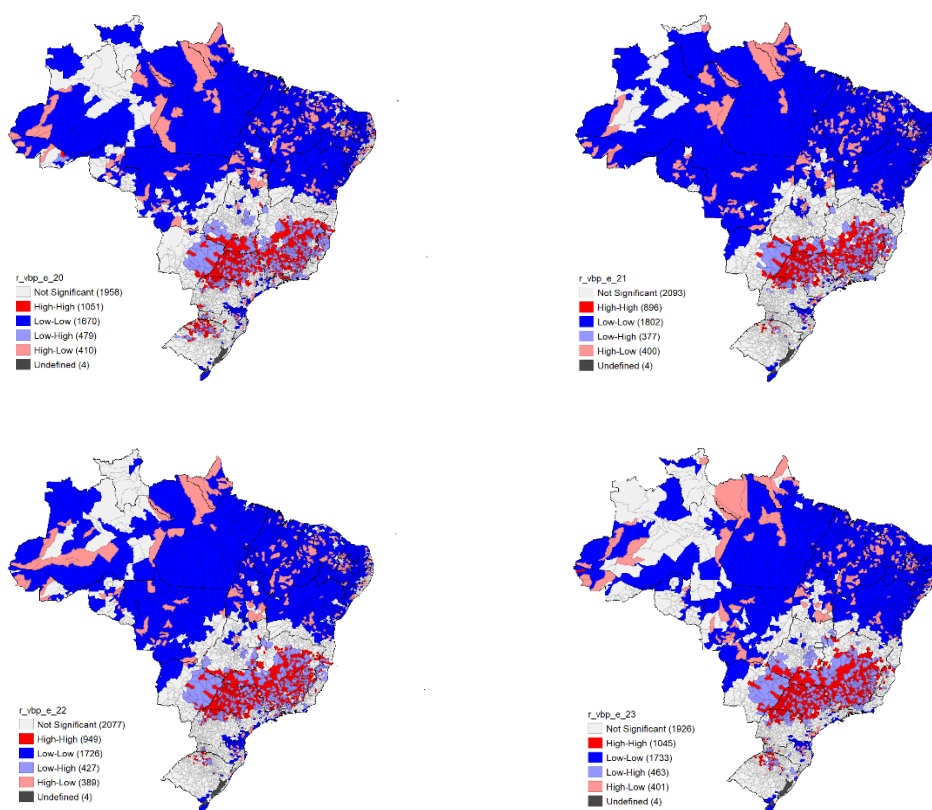


Figura 7: índice LISA da distribuição espacial da razão VBP crédito à agricultura nos municípios brasileiros – 2020-2023

Nos anos de 2021 e 2022, o padrão espacial manteve-se semelhante ao observado em 2020, consolidando as disparidades regionais na razão VBP agrícola per capita sobre o crédito agrícola per capita. Em 2023, o índice LISA continuou a apontar uma clara polarização norte-sul, com 1.045 municípios (18,8%) no cluster alto-alto, concentrados nas regiões Sudeste, Sul e Centro-Oeste, e 1.733 municípios (31,1%) no cluster baixo-baixo, localizados principalmente nas regiões Norte e Nordeste. Essa divisão espacial evidencia uma continuidade nas disparidades regionais, onde os municípios do Sul e Sudeste e centro-oeste apresentam maior produção razão entre a produção agrícola per capita em relação ao crédito, enquanto o Norte e Nordeste demonstram menores índices nesse aspecto, reafirmando as diferenças estruturais na economia agrícola brasileira.

Em relação à razão VBP agrícola e mão de obra contatada formalmente na agricultura, a Figura 8, abaixo, apresenta a clusterização por meio do LISA. Em 2020, dos 5.570 municípios brasileiros, 1.131 (20,3%) estavam no cluster alto-alto, conforme determinado pelo índice LISA para a razão do valor bruto da produção (VBP) agrícola total em relação à mão de obra formalmente ocupada no setor, com predominância nas regiões Sudeste, Sul e Centro-Oeste. Esse agrupamento reflete a alta produtividade e relevância econômica das culturas nessas regiões. Em contraste, o cluster baixo-baixo, que compreendia 1.023 municípios (18,4%), era composto majoritariamente por municípios da região Nordeste, onde o VBP agrícola total é consideravelmente menor em relação ao uso de mão de obra formal ocupada, evidenciando uma produção agrícola menos intensiva em comparação com as demais regiões.

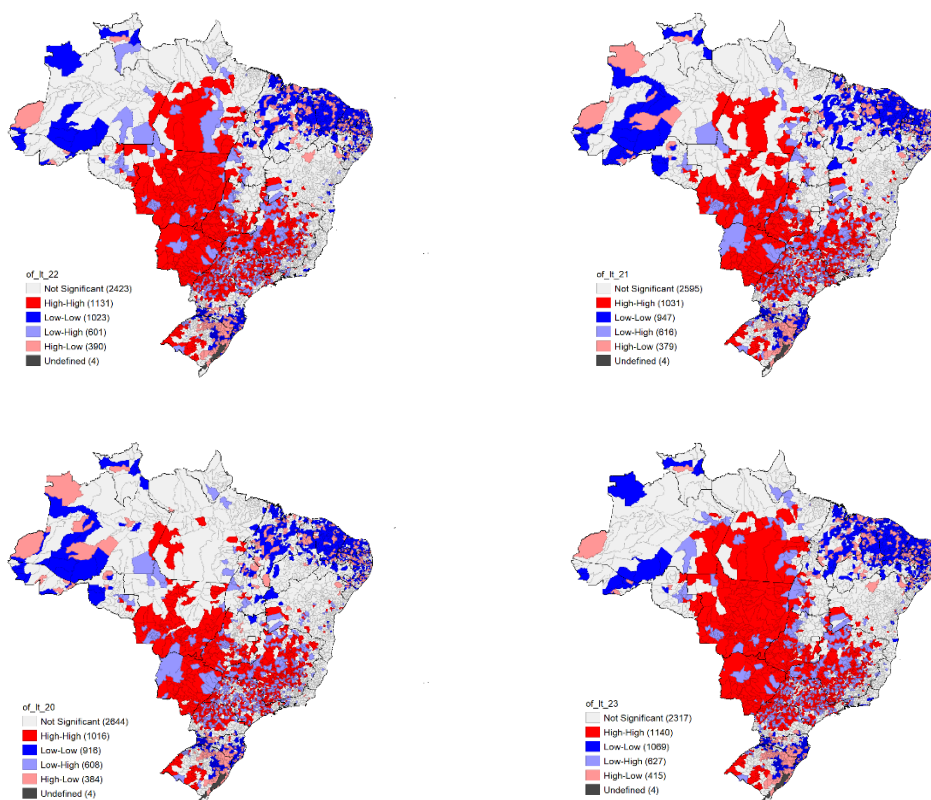


Figura 8: índice LISA da distribuição espacial da razão VBP ocupados formais na lavoura temporária nos municípios brasileiros – 2020-2023

Nos anos de 2021 e 2022, o padrão espacial foi semelhante ao de 2020, mantendo-se a divisão entre as regiões com alta e baixa contribuição para a razão entre o VBP agrícola total e o total de ocupados formais na agricultura. Em 2023, o índice LISA continuou a destacar essa polarização, com 1.140 municípios (20,5%) no cluster alto-alto, concentrados nas regiões Sudeste, Sul e Centro-Oeste, e 1.069 municípios (19,2%) no cluster baixo-baixo, com predominância no Nordeste. Essa clara polarização entre o norte e o sul do país revela a persistência das disparidades estruturais no setor agrícola brasileiro, com as regiões Sul e Sudeste e Centro-oeste mantendo altos níveis entre a razão da produção total e a força de trabalho, enquanto o Nordeste enfrenta desafios para alcançar a mesma participação econômica.

4.1.4. Análise Econométrica Espacial – municípios brasileiros

Esta seção destina-se a apresentação dos resultados econométricos espaciais para a análise dos impactos 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.

4.1.4.1. Testes LM e LM robustos para a escolha do Modelo Espacial – municípios brasileiros

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), 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 partir da análise dos testes LM e LM robustos aplicados aos modelos OLS e SLX na Tabela 1, é evidente que há uma forte presença de autocorrelação espacial nos dados. Para o modelo OLS, o teste LMerr apresentou um valor elevado (193,7) com p-valor menor que 0,000, indicando que o modelo possui problemas significativos relacionados à autocorrelação espacial nos resíduos. O LMlag também foi significativo, com valor de 69,291 e p-valor menor que 0,000. Esses resultados mostram que tanto o erro quanto a variável dependente estão associados espacialmente, reforçando a inadequação do modelo OLS para os dados em questão. Já os testes robustos (RLMerr e RLMlag) sugerem que a dependência espacial nos erros é mais forte, dado que o RLMerr (147,8) foi maior e mais significativo do que o RLMlag (23,385), indicando que um modelo que corrija a autocorrelação nos erros, como o SEM ou SDEM, pode ser mais adequado.

Tabela 1: Teste LM para os modelos OLS e SLX para o VBP per capita da agricultura brasileira – 2023.

OLS			SLX		
LMerr = 193.7	df=1	p-value< 0.000	LMerr = 174.02	df=1	p-value < 0.000
LMlag = 69.291	df=1	p-value < 0.000	LMlag = 183.74	df= 1	p-value < 0.000

RLMerr = 147.8	df=1	p-value < 0.000	RLMerr = 13.694	df = 1	p-value < 0.000
RLMlag = 23.385	df=1	p-value = 0.000	RLMlag = 23.416	df = 1	p-value = 0.000

Source: elaboration by the authors based on the estimation results.

No caso do modelo SLX, os resultados seguem um padrão semelhante, com LMerr (174,02) e LMLag (183,74) ambos significativos. O destaque aqui é o RLMlag, que apresentou um valor de 23,416 com p-valor significativo, indicando que, no modelo SLX, a autocorrelação espacial da variável dependente desempenha um papel importante. Esse resultado reforça a necessidade de um modelo que capture explicitamente as dependências espaciais, sendo o SAR ou SDEM opções a serem consideradas. Entretanto, os valores elevados do LMerr e RLMerr sugerem que a autocorrelação nos erros ainda é um problema, mesmo após a inclusão de termos espaciais no modelo SLX. Com isso, após a estimação dos modelos foram aplicados testes adicionais para a escolha daquele que melhor ajusta os dados, conforme descrição abaixo.

4.1.4.2. Testes de randomização do índice de Moran dos Resíduos e Simulação de Monte Carlo do teste de randomização para a escolha do Modelo Espacial – municípios brasileiros

Na Tabela 2, que apresenta os resultados do índice de Moran aplicado aos resíduos, o modelo OLS apresentou um valor extremamente elevado (13,98), com p-valor significativo, reforçando a inadequação desse modelo devido à forte autocorrelação espacial. O modelo SLX reduziu o índice de Moran para 13,253, mas o p-valor permaneceu significativo, indicando que, embora o SLX capture algumas dependências espaciais por meio das variáveis explicativas espaciais, ele não resolve completamente os problemas de autocorrelação. Por outro lado, modelos como SDEM e SEM apresentaram valores próximos de zero e p-valores não significativos (0,778 e 0,813, respectivamente), sugerindo que esses modelos são capazes de eliminar a autocorrelação espacial nos resíduos de maneira mais eficaz.

Tabela 2: Teste I de Moran sob randomização e Simulação de Monte Carlo do I de Moran para estimativas do VBP per capita da agricultura brasileira – 2023.

Model	OLS Level per_capita	SLX Level per_capita	SAR Level per_capita	SDEM Level per_capita	SEM Level per_capita
Moran's I statistic st dev	13.98	13.253	11.165	-0.744	-0.891

p-value	0.000	0.000	0.000	0.778	0.813
Moran's I Monte Carlo Simulation					
Model	OLS Level per_capita	SLX Level per_capita	SAR Level per_capita	SDEM Level per_capita	SEM Level per_capita
Statistic	0.1114	0.10559	0.08892	-0.0061	-0.0073
p-value	0.00100	0.00100	0.00100	0.76600	0.83600

Source: elaboration by the authors based on the estimation results.

Os resultados da simulação de Monte Carlo corroboram essas observações. Para os modelos SDEM e SEM, os valores estatísticos do índice de Moran (-0,0061 e -0,0073, respectivamente) e seus p-valores elevados (0,766 e 0,836) indicam a ausência de autocorrelação espacial significativa nos resíduos, confirmando a adequação desses modelos. Assim, com base nos dois conjuntos de testes, o SDEM emerge como a escolha mais robusta para a análise, uma vez que captura tanto a dependência espacial nos erros quanto os efeitos de spillover espacial das variáveis explicativas, enquanto o SEM oferece uma alternativa viável para modelar os dados com foco apenas nos erros. Nesse sentido, o SDEM foi escolhido para a apresentação e análise dos resultados, já que respeita devidamente os resultados dos testes sugeridos pela literatura vigente.

4.1.4.3. Spatial Durbin Error Model – SDEM Per capita – municípios brasileiros

Os resultados da Tabela 3, abaixo, referem-se aos impactos do crédito sobre o valor bruto da produção agrícola dos municípios brasileiros no ano de 2023. Utilizou-se a variável dependente defasada (vbp_per_19), conforme sugere Arellano e Bond (1991) Blundell e Bond (1998), para lidar com possível endogeneidade, já que as variáveis referentes ao crédito foram introduzidas de forma defasadas. No modelo SDEM, conforme escolha robusta a partir dos testes aplicados, a análise dos coeficientes significativos revela importantes relações entre os créditos per capitas concedidos à agricultura e o valor bruto da produção per capita em 2023. Como as variáveis estão em logaritmo natural, os coeficientes podem ser interpretados como elasticidades, indicando a variação percentual esperada no VBP per capita para um aumento percentual nas variáveis explicativas.

Para o crédito per capita concedido por bancos privados, destaca-se o impacto positivo e significativo do crédito de custeio concedido em 2023 (cper_cust_23) para o VBP do referido ano, convergindo com Akram *et al.* (2008), Alencar e Araújo (2015) e

Lima *et al.* (2016). Esse resultado evidencia que os recursos destinados ao custeio agrícola têm efeitos imediatos e substanciais na produção per capita, refletindo o papel crucial desse tipo de financiamento na operação agrícola e na aquisição de insumos essenciais. Por outro lado, os créditos para investimento apresentaram efeitos heterogêneos. O crédito de investimento de 2020 (cper_inv_20) mostrou-se negativamente relacionado ao VBP no modelo SDEM, sugerindo que os investimentos realizados nesse período podem ter tido baixa eficiência ou não se traduziram em ganhos produtivos no curto prazo.

Os créditos concedidos por meio dos Fundos Constitucionais também mostraram relações significativas com o VBP per capita. No modelo SDEM, observa-se um impacto negativo associado ao crédito para investimento de 2020 (cper_fun_inv_20), o que pode refletir desafios na alocação desses recursos ou limitações na efetividade dos projetos financiados (como não conclusão dos investimentos ou desvios de finalidades do uso do recurso). Em contrapartida, o crédito de investimento concedido em 2022 (cper_fun_inv_22) apresentou impacto positivo e significativo, indicando que os recursos mais recentes têm gerado retornos produtivos relevantes, especialmente em municípios de maior produtividade. No modelo SDEM(lag), o crédito de custeio concedido em 2023 por meio dos Fundos Constitucionais (cper_fun_cust_23) demonstrou efeito positivo, reforçando a importância do financiamento de curto prazo para a sustentação da produção agrícola, refletindo convergência com Alencar e Araújo (2015) e Lima *et al.* (2016), e firmando a importância desse tipo de crédito à agricultura nacional.

Tabela 3: Impactos dos créditos à agricultura sobre o VBP dos municípios brasileiros – 2023 – pelos modelos OLS, SLX, SAR, SDEM, SEM.

Variáveis	Dependent variable:(vbp_per_23)						
	OLS	SLX	SLX(lag)	SAR	SDEM	SDEM(lag)	SEM
vbp_per_19	0.881*** (0.003)	0.873*** (0.004)	0.025*** (0.006)	0.865*** (0.004)	0.874*** (0.003)	0.024*** (0.006)	0.878*** (0.003)
cper_inv_19	-0.0002 (0.003)	-0.0003 (0.003)	0.001 (0.006)	-0.001 (0.003)	0.0001 (0.003)	0.002 (0.007)	-0.0002 (0.003)
cper_inv_20	-0.005* (0.003)	-0.005 (0.003)	0.013** (0.006)	-0.005* (0.003)	-0.005* (0.003)	0.010 (0.007)	-0.006** (0.003)
cper_inv_21	0.005** (0.003)	0.004* (0.003)	-0.005 (0.006)	0.005** (0.003)	0.004 (0.003)	-0.005 (0.007)	0.005** (0.003)
cper_inv_22	-0.002 (0.002)	-0.002 (0.002)	0.0003 (0.005)	-0.002 (0.002)	-0.002 (0.002)	0.002 (0.006)	-0.002 (0.002)
cper_cust_19	0.0005	0.002	-0.018***	-0.0001	0.002	-0.019***	0.003

	(0.003)	(0.003)	(0.006)	(0.003)	(0.003)	(0.007)	(0.003)
cper_cust_20	-0.0003	-0.001	-0.001	-0.0001	-0.001	-0.001	-0.001
	(0.003)	(0.003)	(0.008)	(0.003)	(0.003)	(0.008)	(0.003)
cper_cust_21	-0.007**	-0.007**	-0.002	-0.007**	-0.006**	0.003	-0.006**
	(0.003)	(0.003)	(0.007)	(0.003)	(0.003)	(0.008)	(0.003)
cper_cust_22	-0.0001	-0.001	0.001	-0.001	-0.001	0.003	-0.0003
	(0.003)	(0.003)	(0.007)	(0.003)	(0.003)	(0.007)	(0.003)
cper_cust_23	0.008***	0.008***	0.016**	0.008***	0.008***	0.010	0.007**
	(0.003)	(0.003)	(0.007)	(0.003)	(0.003)	(0.007)	(0.003)
cper_bnd_19	-0.0003	-0.00003	-0.005	-0.0004	0.0002	-0.006	0.0004
	(0.002)	(0.002)	(0.005)	(0.002)	(0.002)	(0.005)	(0.002)
cper_bnd_20	-0.004	-0.004*	0.003	-0.004*	-0.004*	0.004	-0.004*
	(0.002)	(0.002)	(0.005)	(0.002)	(0.002)	(0.006)	(0.002)
cper_bnd_21	-0.003	-0.003	0.009*	-0.003	-0.003	0.007	-0.004*
	(0.002)	(0.002)	(0.005)	(0.002)	(0.002)	(0.005)	(0.002)
cper_bnd_22	-0.002	-0.002	-0.007	-0.002	-0.002	-0.007	-0.001
	(0.002)	(0.002)	(0.005)	(0.002)	(0.002)	(0.005)	(0.002)
cper_fun_cust_19	-0.007**	-0.006*	-0.013*	-0.008**	-0.005	-0.008	-0.006*
	(0.003)	(0.003)	(0.008)	(0.003)	(0.003)	(0.008)	(0.003)
cper_fun_cust_20	-0.0004	-0.001	0.006	-0.001	-0.002	0.005	-0.001
	(0.004)	(0.004)	(0.009)	(0.004)	(0.004)	(0.010)	(0.004)
cper_fun_cust_21	-0.0004	-0.0002	0.001	-0.001	-0.001	0.001	-0.0004
	(0.004)	(0.004)	(0.008)	(0.004)	(0.004)	(0.009)	(0.004)
cper_fun_cust_22	0.002	0.003	-0.007	0.003	0.003	-0.011	0.003
	(0.003)	(0.003)	(0.007)	(0.003)	(0.003)	(0.007)	(0.003)
cper_fun_cust_23	0.001	-0.004	0.021***	0.0002	-0.004	0.022***	-0.002
	(0.003)	(0.003)	(0.006)	(0.003)	(0.003)	(0.006)	(0.003)
cper_fun_inv_19	0.007	0.004	-0.011	0.007	0.004	-0.015	0.008*
	(0.005)	(0.005)	(0.012)	(0.005)	(0.005)	(0.012)	(0.005)
cper_fun_inv_20	-0.012**	-0.015***	0.020	-0.011**	-0.015***	0.016	-0.014***
	(0.005)	(0.005)	(0.012)	(0.005)	(0.005)	(0.013)	(0.005)
cper_fun_inv_21	0.0001	-0.003	0.008	0.001	-0.002	0.014	-0.00001
	(0.005)	(0.005)	(0.013)	(0.005)	(0.005)	(0.013)	(0.005)
cper_fun_inv_22	0.013***	0.010**	-0.005	0.012***	0.010**	-0.005	0.013***
	(0.004)	(0.005)	(0.009)	(0.004)	(0.004)	(0.010)	(0.004)
o_for_lt_22	-0.005	-0.004	0.015	-0.005	-0.004	0.010	-0.006
	(0.006)	(0.006)	(0.013)	(0.006)	(0.006)	(0.014)	(0.006)
o_for_lt_23	0.006	0.004	-0.014	0.005	0.004	-0.011	0.007
	(0.006)	(0.006)	(0.013)	(0.006)	(0.006)	(0.014)	(0.006)
ml_chuva_23	0.034	0.004	0.022	0.024	0.002	0.001	0.023
	(0.023)	(0.028)	(0.041)	(0.023)	(0.027)	(0.042)	(0.024)
ml_chuva2_23	-0.004**	-0.0005	-0.003	-0.003	-0.001	-0.001	-0.003
	(0.002)	(0.003)	(0.004)	(0.002)	(0.003)	(0.004)	(0.002)
d_no	0.048***	-0.090	0.157	0.061***	-0.060	0.117	0.046**
	(0.018)	(0.098)	(0.100)	(0.018)	(0.093)	(0.096)	(0.022)

d_ne	0.012 (0.016)	-0.210** (0.089)	0.214** (0.091)	0.027* (0.016)	-0.194** (0.085)	0.194** (0.088)	0.016 (0.020)
d_se	0.086*** (0.010)	-0.017 (0.066)	0.107 (0.067)	0.080*** (0.010)	-0.020 (0.063)	0.114* (0.065)	0.087*** (0.012)
d_co	-0.029 (0.022)	0.055 (0.085)	-0.064 (0.091)	-0.028 (0.021)	0.037 (0.081)	-0.046 (0.088)	-0.024 (0.026)
Constant	-0.091 (0.074)	-0.064 (0.136)		-0.097 (0.073)	0.013 (0.147)		-0.056 (0.074)
Observations	5,570	5,570		5,570	5,570		5,570
R ²	0.958	0.959					
Adjusted R ²	0.958	0.958					
Residual Std. Error	0.212 (df=5538)	0.211 (df= 5507)					
F Statistic	4,060.026*** (df=31; 5538)	2,060.022*** (df=62; 5507)					
Log Likelihood				778.662	876.624		831.356
sigma ²				0.044	0.042		0.043
Akaike Inf. Crit.				-1,489.325	-1,423.248		-1,594.713
Wald Test				69.3*** (df=1)	166.4*** (df=1)		186.9*** (df=1)
LR Test				68.3*** (df=1)	155.9*** (df=1)		173.7*** (df=1)

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

Fatores climáticos também desempenham um papel relevante que podem afetar a produção agrícola ao redor do mundo, conforme sugerem Singhal *et al.* (2022) e Abid *et al.* (2022). Os estudo citados convergem conforme evidenciado pelo coeficiente de ml_chuva2_23, que apresentou relação negativa no modelo SDEM. Esse resultado indica que o excesso de chuvas no ano de 2023 prejudicou a produtividade agrícola, possivelmente devido a danos nas culturas e impactos adversos no manejo do solo, especialmente em regiões onde práticas agrícolas são mais intensivas, conforme (Conab, 2023 e Inmet, 2023).

As diferenças regionais também são evidentes, sendo assim, foram incorporadas Dummies de região, já que a literatura mostra essas diferenças regionais na produção agrícola e em sua produtividade (Moreira *et al.*, 2007; Felema *et al.*, 2013, dentre outros). Com isso, no modelo SDEM, a dummy para a região Nordeste (d_ne) apresentou coeficiente negativo e significativo, destacando que o VBP per capita nessa região é, em média, inferior ao da região Sul, categoria de referência, conforme convergência a literatura acima citada. Esse resultado reflete as desigualdades estruturais, como menor acesso a crédito, infraestrutura precária e menor intensidade tecnológica na produção agrícola. Já a dummy para a região Sudeste (d_se), no modelo SDEM(lag), apresentou coeficiente positivo e significativo, indicando que municípios dessa região, em

comparação ao Sul, possuem maior VBP per capita, refletindo sua maior capacidade produtiva e acesso a recursos.

Esses resultados destacam a importância de considerar tanto o tipo quanto o período de concessão dos créditos agrícolas, bem como as características regionais e climáticas, para compreender os determinantes do valor bruto da produção per capita. A elasticidade dos impactos sugere que políticas direcionadas e bem estruturadas, especialmente em regiões mais vulneráveis, podem gerar ganhos significativos para a produção agrícola brasileira. Outrossim, políticas de incentivos específicas para cada região também devem ser consideradas, dada a heterogeneidade elevada intrar-região e inter-região brasileira.

4.1.4.4. Spatial Durbin Error Model – SDEM Quantílico Per capita – municípios brasileiros

A Tabela apresentada contém os resultados do modelo SDEM e SDEM (lag) para o valor bruto da produção per capita (VBP) em 2023, considerando diferentes quantis da distribuição, desde o 1º decil até o 99º percentil. O modelo avalia o impacto de variáveis explicativas relacionadas ao crédito agrícola (custeio e investimento), empregos formais no setor agrícola, características climáticas e regionais. Todos os coeficientes foram estimados em logaritmos, permitindo a interpretação em termos de elasticidades, ou seja, o percentual de variação no VBP per capita para uma variação percentual em cada variável explicativa. A análise a seguir aborda os coeficientes estatisticamente significativos, destacando suas implicações nos diferentes níveis da distribuição.

Os resultados indicam que o crédito recente para custeio em 2023 (*cper_cust_23*) tem impacto positivo significativo em todos os quantis analisados. Isso pode ser resultado do que mostra a literatura acerca do crescimento da participação do setor privado no financiamento da agricultura nacional, apesar de o setor público ainda ser o maior financiador do agronegócio brasileiro (Silva e Souza, 2019; Souza *et al.*, 2020). Por exemplo, no 1º quartil, um aumento de 1% no crédito de custeio resulta em um aumento de 0,5% no VBP per capita. Esse impacto diminui em quantis superiores, como o 3º quartil, onde o mesmo aumento no crédito gera um crescimento de 0,2% no VBP, sugerindo retornos marginais decrescentes em municípios mais produtivos. No modelo SDEM (lag), o crédito para custeio de 2023 também apresenta efeitos positivos e

significativos nos municípios vizinhos, com impacto de 1,1% no VBP per capita no 3º quartil para cada aumento de 1% no crédito nos municípios adjacentes. Esses resultados evidenciam que o crédito recente tem efeitos diretos e spillovers positivos no desempenho agrícola. De acordo com o MAPA (2022) cresceu acentuadamente o crédito concedido com recursos livres ao setor rural brasileiro no ano de 2021. Isso pode justificar, em parte, o efeito do crédito agrícola sobre o VBP.

Por outro lado, os créditos para custeio concedidos em anos anteriores, como *cper_cust_19* e *cper_cust_21*, apresentam coeficientes negativos significativos em quantis médios e superiores. Por exemplo, na mediana, um aumento de 1% no crédito de custeio de 2019 está associado a uma redução de 0,3% no VBP per capita. Esses resultados podem refletir retornos decrescentes ou ineficiências na aplicação de recursos em médio prazo. De forma similar, no modelo SDEM (lag), o crédito defasado de 2022 para custeio (*cper_cust_22_lag*) apresenta impactos negativos significativos nos quantis superiores, como o 3º quartil, onde um aumento de 1% no crédito reduz o VBP em 0,9% nos municípios vizinhos.

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

Variáveis	Dependent variable: <i>vbp_per_23</i>					
	(1ºDecil)	(1ºQuartil)	(Mediana)	(3ºquartil)	(90ºPercentil)	(99ºPercentil)
<i>vbp_per_19</i>	0.831*** (0.005)	0.871*** (0.002)	0.896*** (0.002)	0.918*** (0.002)	0.934*** (0.003)	0.914*** (0.027)
<i>cper_inv_19</i>	-0.001 (0.003)	-0.002 (0.001)	-0.001 (0.001)	-0.003** (0.001)	-0.002 (0.002)	0.002 (0.022)
<i>cper_inv_20</i>	0.004 (0.003)	0.0001 (0.002)	-0.002 (0.001)	-0.001 (0.001)	-0.003 (0.002)	-0.0002 (0.017)
<i>cper_inv_21</i>	0.001 (0.003)	0.0004 (0.001)	0.00003 (0.001)	0.0004 (0.001)	0.003* (0.002)	0.023 (0.015)
<i>cper_inv_22</i>	-0.003 (0.003)	-0.001 (0.001)	-0.0002 (0.001)	-0.001 (0.001)	-0.003 (0.002)	-0.008 (0.017)
<i>cper_cust_19</i>	-0.002 (0.003)	-0.003*** (0.001)	-0.003* (0.001)	-0.003** (0.001)	-0.002 (0.002)	0.005 (0.022)
<i>cper_cust_20</i>	0.001 (0.003)	-0.001 (0.002)	-0.001 (0.002)	-0.001 (0.002)	-0.004 (0.002)	-0.015 (0.026)
<i>cper_cust_21</i>	-0.002 (0.003)	-0.001 (0.001)	-0.003** (0.002)	-0.003* (0.002)	-0.002 (0.002)	-0.022 (0.019)
<i>cper_cust_22</i>	0.0001	0.001	0.001	0.002	0.003	-0.009

	(0.003)	(0.001)	(0.001)	(0.001)	(0.002)	(0.021)
cper_cust_23	0.007***	0.005***	0.004***	0.002*	0.003	0.009
	(0.003)	(0.001)	(0.001)	(0.001)	(0.002)	(0.020)
cper_bnd_19	-0.002	-0.002**	-0.001*	-0.0001	-0.001	0.019
	(0.002)	(0.001)	(0.001)	(0.001)	(0.001)	(0.014)
cper_bnd_20	-0.005**	-0.002**	-0.001	-0.001	-0.0005	-0.016
	(0.002)	(0.001)	(0.001)	(0.001)	(0.002)	(0.017)
cper_bnd_21	-0.001	-0.002	-0.001	-0.002**	-0.003**	-0.017
	(0.002)	(0.001)	(0.001)	(0.001)	(0.001)	(0.014)
cper_bnd_22	0.001	-0.0005	-0.001**	-0.001	-0.003**	-0.010
	(0.002)	(0.001)	(0.001)	(0.001)	(0.001)	(0.014)
cper_fun_cust_19	-0.004	-0.003**	-0.003**	-0.002	-0.007**	-0.011
	(0.003)	(0.001)	(0.001)	(0.001)	(0.003)	(0.030)
cper_fun_cust_20	-0.001	0.00002	-0.002	-0.001	-0.0003	-0.019
	(0.003)	(0.002)	(0.001)	(0.002)	(0.004)	(0.038)
cper_fun_cust_21	-0.003	-0.001	0.001	-0.001	-0.005	0.020
	(0.004)	(0.002)	(0.001)	(0.002)	(0.004)	(0.032)
cper_fun_cust_22	0.005	0.003*	0.002*	0.004***	0.007***	0.022
	(0.004)	(0.002)	(0.001)	(0.001)	(0.003)	(0.028)
cper_fun_cust_23	-0.003	-0.001	0.001	0.001	0.001	-0.004
	(0.003)	(0.001)	(0.001)	(0.001)	(0.002)	(0.032)
cper_fun_inv_19	0.001	-0.002	-0.0004	-0.002	-0.007	0.014
	(0.005)	(0.002)	(0.002)	(0.002)	(0.005)	(0.058)
cper_fun_inv_20	-0.003	-0.007***	-0.004**	-0.001	0.002	-0.032
	(0.005)	(0.002)	(0.002)	(0.002)	(0.005)	(0.058)
cper_fun_inv_21	-0.007	-0.002	-0.002	-0.001	-0.0002	0.037
	(0.005)	(0.002)	(0.002)	(0.002)	(0.005)	(0.052)
cper_fun_inv_22	0.005	0.005***	0.002	0.002	0.006*	-0.024
	(0.004)	(0.002)	(0.002)	(0.002)	(0.004)	(0.029)
o_for_lt_22	-0.006**	-0.006***	-0.001	0.0003	-0.008*	0.024
	(0.003)	(0.002)	(0.002)	(0.002)	(0.004)	(0.037)
o_for_lt_23	0.007***	0.006***	0.002	-0.001	0.006	-0.028
	(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***	0.011***	0.008***	0.008***	0.014**	0.036
	(0.005)	(0.002)	(0.002)	(0.002)	(0.006)	(0.045)
cper_fun_inv_19_lag	-0.0003	-0.001	-0.004	0.00003	-0.0003	0.057

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

Os créditos concedidos pelo BNDES mostram padrões mistos. No modelo SDEM, o crédito do BNDES em 2022 (cper_bnd_22) apresenta coeficientes negativos e significativos na mediana e no 90º percentil, com impactos de -0,1% e -0,3% no VBP per capita, respectivamente, para cada aumento de 1% no crédito. No modelo SDEM (lag), o crédito do BNDES de 2019 (cper_bnd_19_lag) também apresenta coeficientes negativos significativos no 1º quartil, onde uma elevação de 1% no crédito reduz o VBP em 0,4% nos municípios adjacentes. Esses resultados sugerem limitações na eficácia dos financiamentos concedidos pelo BNDES, especialmente em áreas mais produtivas e seus entornos.

O crédito dos Fundos Constitucionais de Financiamento para custeio em 2022 (cper_fun_cust_22) tem impacto positivo significativo no modelo SDEM, especialmente

no 3º quartil e no 90º percentil. No 3º quartil, um aumento de 1% no crédito está associado a um crescimento de 0,4% no VBP per capita. Esses resultados convergem com os de Saqib *et al.* (2018) e Chandio *et al.* (2019), onde mostra que o tamanho da propriedade, a escolaridade e a renda mensal respondem positivamente pelo volume de crédito no Paquistão. Assim, os impactos da concessão do crédito para investimento por meio dos Fundos Constitucionais acabam impactando de forma mais acentuada os municípios de elevados VBPs. Contudo, no modelo SDEM (lag), os efeitos espaciais defasados desses créditos em 2022 são negativos e significativos em quantis superiores, como o 3º quartil, onde um aumento de 1% no crédito reduz o VBP em 0,9% nos municípios vizinhos. Esses resultados apontam para uma possível concentração de recursos que beneficia áreas específicas, mas pode prejudicar a produtividade em localidades próximas.

Os empregos formais no setor agrícola em 2023 (*o_for_lt_23*) apresentam impacto positivo significativo nos quantis inferiores, como o 1º decil, onde um aumento de 1% nos empregos formais está associado a um crescimento de 0,7% no VBP per capita. No entanto, para o ano de 2022 (*o_for_lt_22*), os coeficientes são negativos nos mesmos quantis, sugerindo que os benefícios da formalização são mais evidentes no curto prazo.

As variáveis climáticas, representadas por *ml_chuva_23* e *ml_chuva2_23*, revelaram que o efeito das chuvas é pronunciado no 1º Quartil. Neste, um coeficiente positivo de 0.073** para *ml_chuva_23* indica que um aumento de 1% na quantidade de chuvas está associado a um crescimento de 7,3% no VBP, sugerindo que chuvas adicionais beneficiam regiões com alta produção agrícola. Contudo, o termo quadrático *ml_chuva2_23* apresentou coeficiente negativo e significativo, indicando que um excesso de chuva passa a ter um efeito negativo, reduzindo a produtividade agrícola à medida que o VBP aumenta.

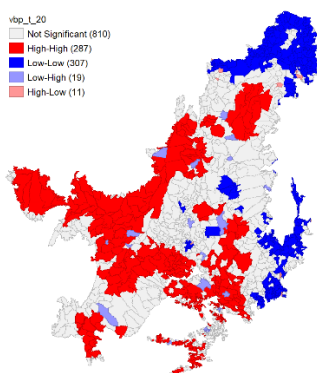
Em resumo, os resultados destacam a relevância do crédito recente, especialmente para custeio, em impulsionar a produção agrícola per capita em 2023, com efeitos diretos e spillovers positivos nos municípios vizinhos. Por outro lado, os créditos mais antigos e os financiamentos do BNDES mostram retornos decrescentes ou negativos em determinadas circunstâncias, indicando a necessidade de monitoramento e ajustes nas políticas de crédito. Além disso, os efeitos espaciais defasados reforçam a importância de considerar externalidades entre municípios ao planejar estratégias de financiamento agrícola.

4.2.PANORAMA DA LAVOURA TEMPORÁRIA E DO CRÉDITO NOS MUNICÍPIOS DO CERRADO BRASILEIRO

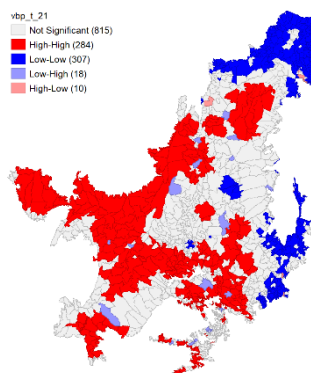
Esta seção visa abordar questões relacionadas à lavoura temporária e ao crédito nos municípios do Cerrado brasileiro, destacando as culturas do algodão, cana-de-açúcar, milho e soja.

4.2.1. Valor bruto da produção nos municípios do cerrado

Esta subseção apresenta o índice LISA para o valor bruto da produção (VBP) das culturas de lavoura temporária nos municípios do Cerrado brasileiro (Figura 9). No ano de 2020 o resultado assumido pelo índice revelou que 287 municípios estavam agrupados no cluster alto-alto, indicando regiões com altos valores de VBP em proximidade com outras áreas também de alto desempenho. Nesse mesmo ano, 307 municípios integraram o cluster baixo-baixo, evidenciando áreas com menor VBP localizadas próximas a outras de desempenho similarmente baixo. Esse padrão de agrupamento espacial demonstra uma concentração geográfica de produtividade agrícola, refletindo possíveis diferenças regionais em condições de cultivo, infraestrutura ou investimentos que influenciam o desempenho agrícola local e regional.



VBP_2020



VBP_2021

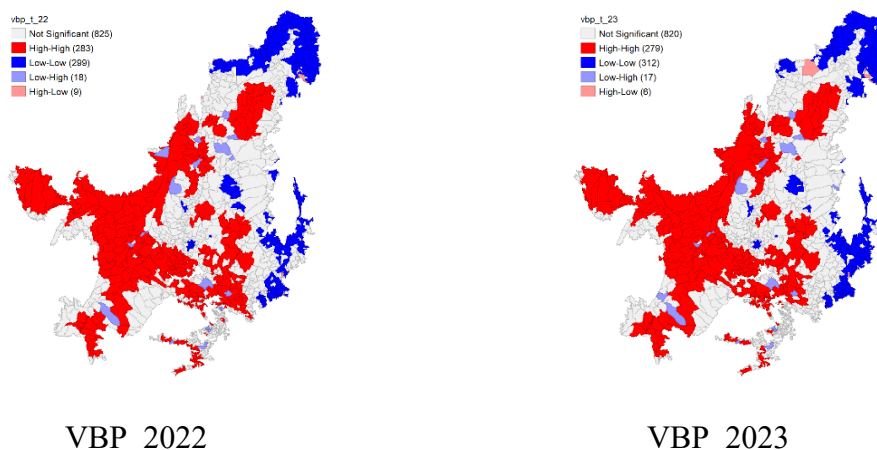


Figura 9: índice LISA para o valor bruto da produção das culturas de lavoura temporária nos municípios do cerrado brasileiro – 2020-2023

Nos anos subsequentes, 2021 e 2022, o padrão espacial observado em 2020 foi amplamente mantido, com pequenas variações, culminando em 2023, quando o cluster alto-alto compreendia 279 municípios e o cluster baixo-baixo, 312 municípios. Comparando-se os dados de 2020 e 2023, houve uma leve diminuição de aproximadamente 2,8% no número de municípios no cluster alto-alto, enquanto o cluster baixo-baixo aumentou cerca de 1,6%. Essas variações percentuais indicam uma leve ampliação das áreas de menor produtividade e uma contração das áreas de alta produtividade, sugerindo possíveis mudanças nas dinâmicas produtivas da região do Cerrado, que podem estar associadas a variáveis como condições climáticas, acesso a crédito e tecnologias agrícolas, por exemplo.

Abaixo, o Gráfico 1 ajuda a compreender a importância relativa da região do Cerrado na dinâmica produtiva agrícola nacional. Entre 2019 e 2023, a participação percentual do Valor Bruto da Produção (VBP) agrícola dos municípios da região do Cerrado brasileiro em relação aos demais municípios do país apresentou um crescimento gradual. Em 2019, a participação do VBP do Cerrado foi de 31,50%, valor que se manteve estável em 2020. Já em 2021, houve um pequeno aumento, com o percentual passando para 31,78%, indicando um ligeiro crescimento da contribuição do Cerrado na produção agrícola nacional. Em 2022, essa participação continuou a subir, alcançando 31,91%.

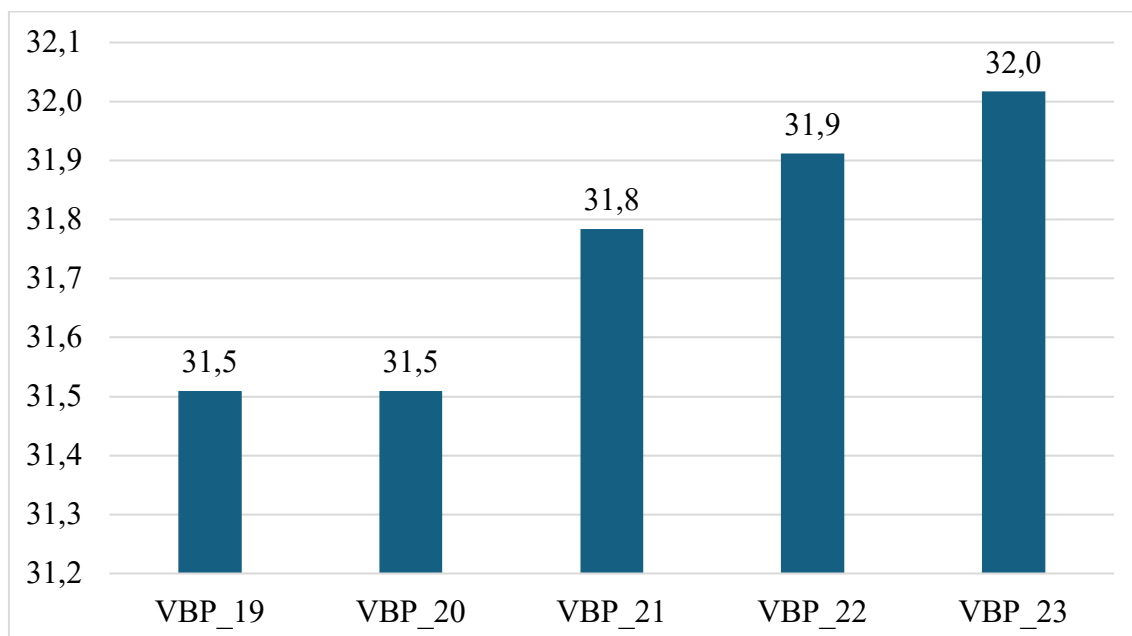


Gráfico 1: participação percentual do Valor Bruto da Produção do Cerrado sobre o total do Brasil – 2019-2023

Em 2023, a participação do VBP do Cerrado chegou a 32,01%, consolidando um crescimento acumulado de 1,62% ao longo do período analisado. A taxa de crescimento anual foi moderada, mas constante, refletindo um aumento gradual da importância dos municípios do Cerrado na produção agrícola do Brasil. Esses dados indicam que, ao longo dos cinco anos, o Cerrado vem expandindo sua participação relativa no VBP agrícola nacional, reforçando sua posição como uma das principais regiões em destaque na área agrícola do país.

4.2.2. Panorama do crédito à agricultura nos municípios do Cerrado

No que diz respeito ao crédito concedido à agricultura na região do Cerrado brasileiro, o Gráfico abaixo apresenta a participação relativa dos municípios desta região no que concerne ao total de recursos destinados ao setor nos anos em apreço. Assim, entre 2019 e 2023, a participação percentual dos municípios da região do Cerrado no total do crédito adquirido pelas atividades agrícolas no Brasil apresentou variações consideráveis. Em 2019, os municípios do Cerrado foram responsáveis por 42,08% do crédito total destinado à agricultura, destacando-se como uma das principais regiões beneficiadas. No ano seguinte, em 2020, houve uma queda significativa, com a participação caindo para

36,23%, refletindo uma redução na captação de crédito agrícola pelos municípios do Cerrado. Em 2021, a participação se recuperou para 39,47%, mostrando um aumento na aquisição de crédito, embora ainda abaixo dos níveis de 2019.




Gráfico 2: Participação percentual do crédito à agricultura nos municípios do Cerrado em relação ao total do Brasil - 2019-2023

Em 2022, a participação voltou a cair, atingindo 34,65%, marcando o ponto mais baixo no período analisado. No entanto, em 2023, houve uma nova recuperação, com a participação subindo para 38,82%. Ao longo dos cinco anos, a taxa de crescimento da participação dos municípios do Cerrado foi volátil, com oscilações de queda e recuperação. Entre 2019 e 2023, observa-se uma redução acumulada de 7,74% na participação percentual, o que indica uma diminuição relativa na captação de crédito agrícola pelos municípios do Cerrado em comparação com o restante do país, que não foi refletida na sua participação no VBP, conforme o Gráfico plotado para este fim.

A análise do índice LISA para o crédito total destinado à agricultura nos municípios do Cerrado encontra-se na Figura 10, abaixo. Por ela, percebe-se que entre 2020 e 2023, evidencia uma distribuição espacial com padrões distintos de concentração. Em 2020, observa-se que 425 municípios estavam agrupados no cluster alto-alto, indicando uma elevada concessão de crédito agrícola em áreas circundadas por outras regiões com alta disponibilidade de crédito. Por outro lado, 358 municípios situavam-se

no cluster baixo-baixo, representando áreas com baixa concessão de crédito e rodeadas por outras regiões com características semelhantes. Esse padrão de concentração espacial sugere uma divisão relevante na distribuição do crédito agrícola, refletindo a desigualdade de acesso aos recursos financeiros na região do Cerrado.

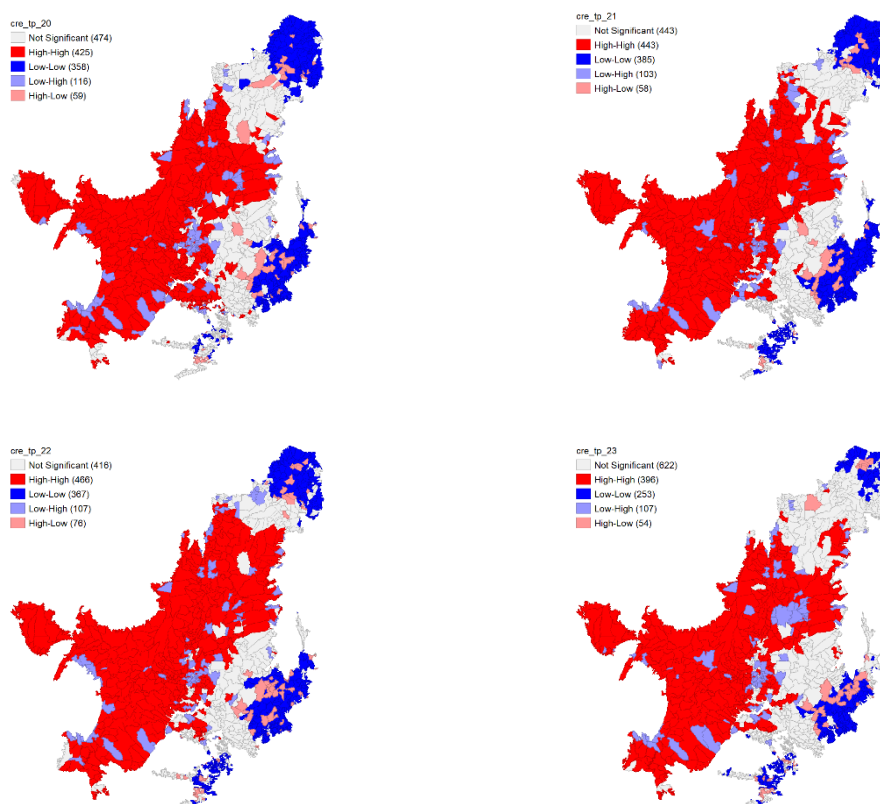


Figura 10: índice LISA para o crédito total à agricultura concedido aos municípios do Cerrado – 2020-2023.

Nos anos subsequentes de 2021 e 2022, a distribuição espacial do crédito agrícola manteve-se semelhante àquela observada em 2020, com a estrutura dos clusters alto-alto e baixo-baixo se apresentando semelhantes ao longo do tempo. Em 2023, houve uma leve alteração nos agrupamentos, com 396 municípios posicionados no cluster alto-alto e 253 municípios no cluster baixo-baixo. Essa mudança reflete uma variação percentual ao longo dos anos: o cluster alto-alto teve uma redução de 6,82%, passando de 425 municípios em 2020 para 396 em 2023, o que sugere uma ligeira desconcentração do crédito agrícola nas áreas anteriormente mais favorecidas. Já o cluster baixo-baixo apresentou uma redução ainda mais acentuada, de 29,33%, caindo de 358 municípios em

2020 para 253 em 2023. Essa diminuição pode indicar que parte dos municípios menos favorecidos no início do período conseguiram melhorar o acesso ao crédito agrícola, possivelmente em função de políticas de crédito mais abrangentes ou de investimentos que estimularam o desenvolvimento dessas regiões do Cerrado.

O Gráfico 3, abaixo, faz uma separação entre crédito destinado a investimento e crédito destinado ao custeio à agricultura brasileira, considerando-se o total de crédito emitido ao longo dos anos. Entre 2019 e 2023, o crédito concedido para custeio e para investimento apresentou comportamentos distintos. Em 2019, o crédito para custeio foi de 39,96%, ligeiramente superior ao crédito para investimento, que foi de 39,28%. No ano seguinte, em 2020, ambos os créditos diminuíram, com o crédito para custeio reduzindo-se para 39,43% (uma queda de -0,53 pontos percentuais) e o crédito para investimento caindo para 38,27% (uma redução de -1,01 pontos percentuais). Em 2021, o crédito para custeio teve um leve aumento para 39,70% (+0,27 pontos percentuais), enquanto o crédito para investimento apresentou um crescimento mais significativo, alcançando 41,08% (+2,81 pontos percentuais). Já em 2022, o crédito para custeio sofreu uma queda acentuada, descendo para 37,72% (-1,98 pontos percentuais), ao passo que o crédito para investimento continuou sua trajetória ascendente, atingindo 46,64% (+5,56 pontos percentuais). Em 2023, o crédito para custeio teve um leve aumento para 41,8% (+4,08 pontos percentuais), enquanto o crédito para investimento continuou sua trajetória ascendente, atingindo 46,7% (+0,06 pontos percentuais).




Gráfico 3: Participação percentual do crédito total para custeio e investimento destinado aos municípios do Cerrado brasileiro – 2019-2023.

Em 2023, observou-se uma recuperação notável no crédito para custeio, que aumentou para 41,83% (+4,11 pontos percentuais), superando novamente o crescimento do crédito para investimento, que se estabilizou em 46,69% (+0,05 pontos percentuais). Ao comparar os dois tipos de créditos ao longo dos anos, percebe-se, no entanto, que o crédito para investimento demonstrou um crescimento mais consistente e robusto, especialmente a partir de 2020, indicando um foco crescente em investimentos. Por outro lado, o crédito para custeio apresentou maior volatilidade, com oscilações moderadas e uma recuperação expressiva em 2023, refletindo possivelmente ajustes nas prioridades de financiamento ao longo do período analisado.

O Gráfico 4, abaixo, considera somente o crédito concedido por meio dos Fundos Constitucionais aos municípios da região do cerrado brasileiro, comparativamente aos demais municípios brasileiros que também adquirem créditos à agricultura por meio deste instrumento de financiamento. Entre 2019 e 2023, os créditos concedidos por meio dos Fundos Constitucionais de Financiamento nos municípios da região do Cerrado brasileiro para custeio e investimento apresentaram variações significativas. Em 2019, o crédito para custeio foi superior, atingindo 61,35%, enquanto o crédito para investimento ficou em 57,32%. No ano seguinte, em 2020, ambos os créditos diminuíram, mas o crédito para custeio apresentou uma queda mais acentuada, caindo para 52,46%, enquanto o crédito para investimento ficou em 56,47%. Em 2021, o crédito para custeio continuou a cair, atingindo 45,98%, enquanto o crédito para investimento cresceu para 58,01%. Em 2022, houve uma recuperação no crédito para custeio, que subiu para 51,34%, enquanto o crédito para investimento permaneceu praticamente estável, em 57,95%.





Gráfico 4: Participação percentual do crédito dos Fundos Constitucionais destinado aos municípios do Cerrado brasileiro – 2019-2023.

Em 2023, o crédito para custeio registrou uma recuperação mais expressiva, alcançando 57,42%, enquanto o crédito para investimento apresentou uma leve queda para 57,16%. Ao analisar a taxa de crescimento, observa-se que o crédito para custeio teve uma queda acumulada entre 2019 e 2021, mas a partir de 2022 começou a recuperar-se, com um crescimento de 24,84% entre 2021 e 2023. Por outro lado, o crédito para investimento se manteve mais estável ao longo do período, apresentando uma leve redução de 0,28% entre 2022 e 2023. Esses números indicam uma volatilidade maior nos créditos para custeio, com uma recuperação mais acentuada nos últimos anos, enquanto o crédito para investimento teve um comportamento mais constante nos municípios da região do Cerrado.

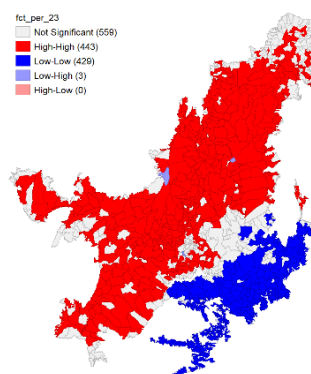
A Figura abaixo apresenta o índice LISA para cada fonte de crédito concedida a agricultura nos municípios do cerrado brasileiro, e são apresentadas por meio da média dos anos de 2019 a 2023. A análise do índice LISA para o crédito total concedido pelo BNDES à agricultura nos municípios do Cerrado brasileiro em 2023 revela um padrão de concentração espacial bem definido. O cluster alto-alto, que indica municípios com alto crédito agrícolas situados próximos a outros municípios com alta disponibilidade de crédito, concentra-se em 240 municípios. Já o cluster baixo-baixo, onde os municípios com baixo volume de crédito estão próximos a outras localidades com características

semelhantes, compreende 180 municípios. Esse padrão sugere uma distribuição geográfica onde algumas regiões conseguem acessar maiores volumes de financiamento do BNDES, enquanto outras apresentam limitações nesse aspecto, refletindo possíveis disparidades em termos de infraestrutura, demanda agrícola ou acesso ao sistema bancário.

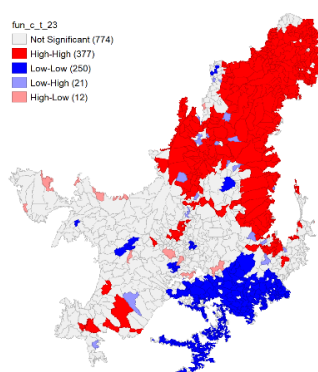
Quando analisado o crédito total concedido pelos Fundos Constitucionais de Financiamento, o índice LISA (Figura 11) mostra uma amplitude significativamente maior de municípios incluídos nos clusters de concentração. O cluster alto-alto abrange 443 municípios, indicando uma extensa área com alta concessão de crédito que se estende entre municípios vizinhos. Por outro lado, o cluster baixo-baixo reúne 429 municípios, demonstrando também uma forte presença de áreas com menor disponibilidade de crédito. Essa distribuição sugere que os Fundos Constitucionais têm uma capilaridade maior em comparação com o BNDES, possibilitando uma maior abrangência de apoio financeiro, ainda que com diferenciações claras entre áreas com alto e baixo acesso a crédito.



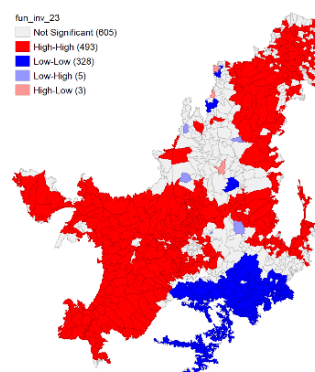
Créditos BNDES 2023



Créditos Fundos 2023



Fundos custeios 2023



Fundos investimentos 2023

Figura 11: índice LISA para o crédito total do BNDES e crédito total dos fundos, crédito dos fundos para custeio e para investimento – 2023.

No que se refere ao crédito dos Fundos direcionado especificamente para custeio agrícola, o índice LISA indica uma concentração relevante no cluster alto-alto, que inclui 377 municípios, sinalizando uma robusta oferta de financiamento para custeio em determinadas áreas, sobretudo concentrada nos municípios localizados na região do Matopiba (mais a leste da Figura). Por outro lado, o cluster baixo-baixo, composto por 250 municípios, reflete regiões onde o crédito para custeio é mais restrito (mais a oeste – municípios do Mato Grosso – sobretudo). Esse padrão pode refletir diferenças na estrutura produtiva dos municípios ou nas necessidades específicas de financiamento de custeio, apontando para um perfil de financiamento que parece mais centralizado em algumas regiões que demandam maior suporte para despesas operacionais na agricultura.

A análise do crédito dos Fundos para investimento na agricultura também revela uma ampla concentração de municípios no cluster alto-alto, com 493 localidades incluídas, enquanto o cluster baixo-baixo agrega 328 municípios. Esse padrão sugere que o crédito para investimento, ao contrário do custeio, possui uma capilaridade ainda maior, chegando a um número elevado de municípios com alta oferta de financiamento. Esse dado indica uma política de incentivo à modernização e expansão das capacidades produtivas agrícolas de forma geograficamente distribuída (sobretudo nos municípios do Mato Grosso e Mato Grosso do Sul), embora ainda existam áreas significativas com menor acesso ao crédito para investimento, o que pode limitar o desenvolvimento agrícola nessas regiões.

4.2.3. Razão entre o VBP e variáveis determinadas

Os resultados apresentados na Figura 12 destacam a evolução da relação entre o Valor Bruto da Produção (VBP) agrícola e o total de crédito concedido à agricultura nos municípios do Cerrado brasileiro. Em 2020, foi observada uma concentração de 223 municípios no cluster alto-alto, indicando uma alta proporção de VBP agrícola em relação ao crédito agrícola. No mesmo ano, 347 municípios foram classificados no cluster baixo-baixo, caracterizando uma baixa relação entre esses dois indicadores. Esses resultados refletem uma variabilidade na dependência do crédito agrícola para a geração de VBP, sugerindo que alguns municípios podem estar conseguindo resultados produtivos significativos com um menor volume de crédito.

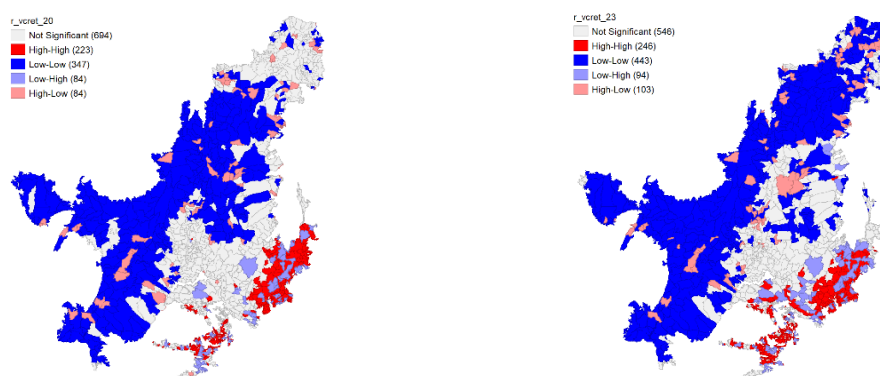


Figura 12: índice LISA univariado para a razão VBP crédito total concedido à agricultura, 2020/2023.

Em 2023, nota-se um crescimento no número de municípios no cluster alto-alto, que aumentou para 243, enquanto o cluster baixo-baixo passou a incluir 443 municípios. Essa mudança evidencia uma ampliação na disparidade entre os municípios quanto ao uso eficiente do crédito agrícola para alavancar a produção. O aumento no cluster baixo-baixo sugere que mais municípios enfrentaram dificuldades em traduzir o crédito em ganhos expressivos de VBP, o que pode indicar desafios estruturais, limitações na adoção de tecnologias agrícolas ou restrições financeiras. Por outro lado, a permanência e o aumento de municípios no cluster alto-alto reforçam a relevância do crédito para aqueles que conseguem otimizar o uso dos recursos financeiros no setor agrícola.

A Figura 13 abaixo apresenta a análise do índice LISA univariado para a razão entre o Valor Bruto da Produção (VBP) agrícola e o crédito concedido à agricultura pelo BNDES nos municípios do Cerrado brasileiro. A Figura apresentada evidencia padrões espaciais de concentração entre os anos de 2020 e 2023. Em 2020, o cluster alto-alto, que agrupa municípios com alta relação entre VBP agrícola e crédito do BNDES, era composto por 115 municípios. Esse grupo reflete uma maior capacidade desses municípios de transformar o crédito em resultados produtivos expressivos. Em 2023, o número de municípios no cluster alto-alto aumentou para 138, o que representa uma variação positiva de aproximadamente 20%. Por outro lado, 192 municípios se classificaram no cluster baixo-baixo em 2020, indicando uma baixa relação entre o VBP agrícola e o crédito recebido. Esse grupo reduziu para 181 municípios em 2023, representando uma variação negativa de cerca de 5,7%.

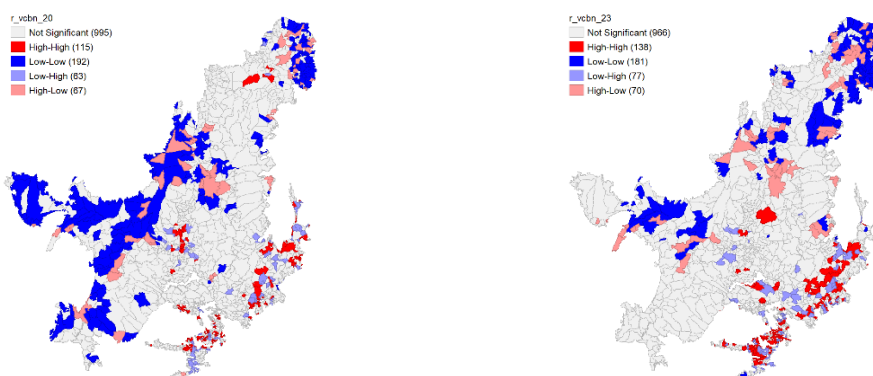


Figura 13: índice LISA univariado para a razão VBP crédito concedido à agricultura pelo BNDES, 2020/2023.

O crescimento do cluster alto-alto em 2023 sugere um aumento no número de localidades com alta relação entre o VBP agrícola e o crédito do BNDES, o que pode refletir melhorias na eficiência do uso do crédito em certos municípios ou maior acesso a financiamento produtivo. A leve redução no cluster baixo-baixo para 181 municípios pode indicar uma pequena melhora na capacidade de conversão do crédito em resultados produtivos, embora esses municípios ainda mantenham uma baixa relação entre VBP e crédito. Essas mudanças percentuais nos clusters ao longo do período analisado destacam as variações na eficiência e no impacto dos recursos do BNDES na produção agrícola

entre os municípios do Cerrado, com indícios de melhorias em alguns municípios quanto à utilização de crédito para impulsionar a produção.

A Figura 14, abaixo, apresenta a análise do índice LISA univariado para a razão entre o Valor Bruto da Produção (VBP) agrícola e o crédito de custeio à agricultura concedido pelas carteiras de bancos privados, ao longo dos anos de 2020 e 2023. Os resultados revelam importantes mudanças nos padrões espaciais de concentração entre os municípios do Cerrado brasileiro. Em 2020, o cluster alto-alto, que identifica municípios com alta relação entre o VBP agrícola e o crédito de custeio privado, era composto por 119 municípios. Esse grupo reflete localidades que conseguiram alavancar a produção agrícola com o crédito de custeio oferecido pelo setor bancário privado. No mesmo ano, o cluster baixo-baixo incluía 179 municípios, indicando uma menor dependência ou dificuldade em usar eficientemente esses recursos privados para impulsionar a produção agrícola.

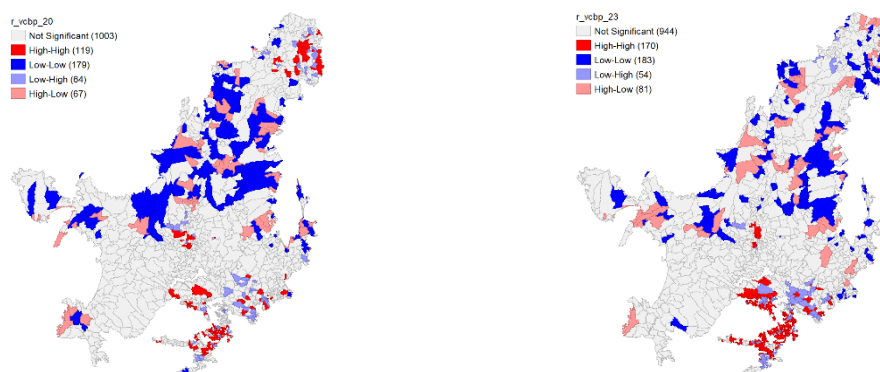


Figura 14: índice LISA univariado para a razão VBP crédito para custeio à agricultura, 2020/2023.

Em 2023, o cluster alto-alto experimentou um aumento expressivo, alcançando 170 municípios, o que representa um crescimento de aproximadamente 42,9% em relação a 2020. Esse incremento pode indicar uma melhoria na capacidade desses municípios de converter o crédito privado de custeio em resultados produtivos ou um aumento no acesso a esses financiamentos. Por outro lado, o cluster baixo-baixo registrou uma leve variação, subindo para 183 municípios, uma alteração de cerca de 2,2%. Essa relativa estabilidade sugere que, embora muitos municípios permaneçam com baixa relação entre o VBP e o crédito de custeio privado, uma parte significativa das localidades aprimorou o uso desses

recursos, apontando para uma maior eficiência no uso do crédito privado para custeio em várias regiões do Cerrado.

A Figura 15, abaixo, apresenta a análise do índice LISA univariado para a razão entre o Valor Bruto da Produção (VBP) agrícola e o crédito para investimento à agricultura, concedido pelas carteiras de bancos privados. Os principais achados revelam importantes transformações nos padrões de concentração espacial entre os municípios do Cerrado brasileiro no que diz respeito a esta análise. Em 2020, o cluster alto-alto, que indica municípios com uma alta relação entre o VBP agrícola e o crédito privado de investimento, era composto por 177 municípios. Esse agrupamento reflete uma maior capacidade desses municípios de transformar o crédito de investimento privado em resultados produtivos expressivos. Em contrapartida, 254 municípios foram classificados no cluster baixo-baixo, sugerindo uma relação menos eficaz entre o crédito de investimento e a produção agrícola, possivelmente devido a dificuldades na utilização otimizada desses recursos financeiros.

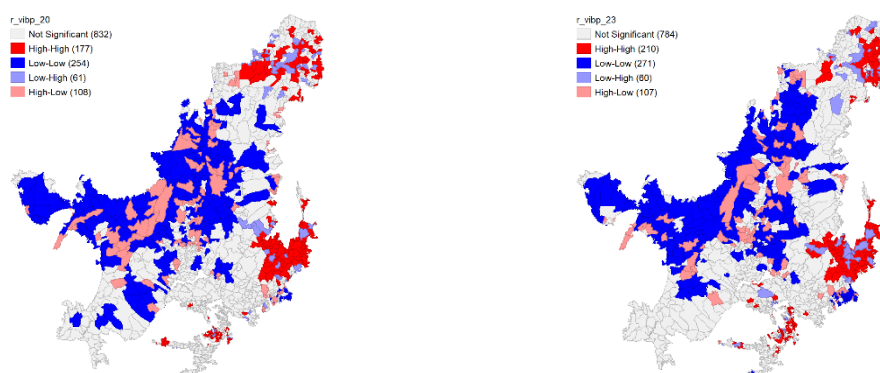


Figura 15: índice LISA univariado para a razão VBP crédito para investimento à agricultura, 2020/2023.

Em 2023, observou-se um aumento significativo no número de municípios do cluster alto-alto, que passou a incluir 210 municípios, representando uma variação positiva de aproximadamente 18,6% em relação a 2020. Esse crescimento no cluster alto-alto pode indicar uma maior eficácia dos municípios em converter o crédito de investimento privado em produção agrícola ou um aumento no acesso a esses financiamentos. Por outro lado, o cluster baixo-baixo também registrou um aumento, totalizando 271 municípios em 2023, o que representa uma variação de cerca de 6,7%.

Esse leve crescimento no cluster baixo-baixo sugere que alguns municípios ainda enfrentam desafios na transformação do crédito privado de investimento em ganhos de produção, embora a expansão do cluster alto-alto indique avanços significativos em várias localidades do Cerrado no uso do crédito privado para investimentos agrícolas.

A Figura 16, abaixo, apresenta os dados plotados acerca da análise do índice LISA univariado para a razão entre o Valor Bruto da Produção (VBP) agrícola e o crédito para custeio à agricultura, por meio dos Fundos Constitucionais de financiamentos. Os resultados apresentam mudanças significativas nos padrões de concentração espacial entre os municípios do Cerrado brasileiro entre os anos de 2020 e 2023. Em 2020, o cluster alto-alto, que indica municípios com uma alta relação entre o VBP agrícola e o crédito para custeio, registrou 237 municípios, mostrando uma concentração de localidades que conseguem transformar o crédito dos Fundos Constitucionais em resultados produtivos expressivos. Por outro lado, o cluster baixo-baixo incluía 458 municípios, sinalizando uma baixa relação entre o VBP agrícola e o crédito de custeio, o que pode refletir desafios na eficiência ou menor dependência desses recursos para alavancar a produção agrícola.

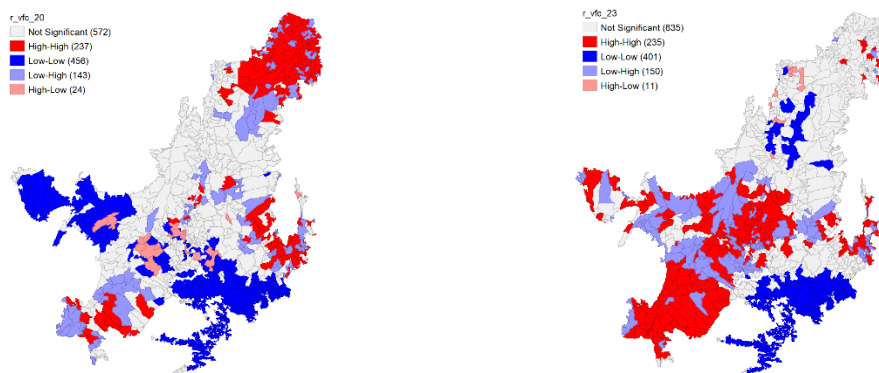


Figura 16: índice LISA univariado para a razão VBP crédito para custeio concedido pelos Fundos Constitucionais à agricultura, 2020/2023.

Em 2023, o cluster alto-alto teve uma leve redução, passando para 235 municípios, representando uma variação negativa de aproximadamente 0,8%. Esse decréscimo pode indicar pequenas mudanças na eficiência do uso do crédito para custeio pelos municípios anteriormente classificados no cluster alto-alto. Já o cluster baixo-baixo apresentou uma diminuição mais expressiva, passando de 458 para 401 municípios, uma variação

negativa de cerca de 12,4%. Essa redução pode refletir uma melhoria na capacidade de alguns municípios em traduzir o crédito dos Fundos Constitucionais em produção agrícola, deslocando-os para categorias de maior eficiência na utilização do custeio. Essas alterações sugerem avanços na eficiência do uso do crédito para custeio nas regiões do Cerrado, evidenciando um cenário de melhorias no impacto dos recursos dos Fundos Constitucionais sobre a produção agrícola.

A Figura 17, abaixo, plota a análise do índice LISA univariado para a razão entre o Valor Bruto da Produção (VBP) agrícola e o crédito para investimento à agricultura, concedido pelos Fundos Constitucionais. Os resultados mostram uma dinâmica de alteração nos clusters espaciais entre os municípios do Cerrado brasileiro entre 2020 e 2023. Em 2020, o cluster alto-alto, composto por municípios com uma alta relação entre o VBP agrícola e o crédito para investimento, registrou 321 municípios. Esses municípios destacaram-se pela capacidade de converter o crédito de investimento dos Fundos Constitucionais em resultados produtivos expressivos. Em contraste, o cluster baixo-baixo contava com 402 municípios, indicando uma relação menos eficaz entre o crédito de investimento e o VBP agrícola, possivelmente devido a dificuldades na otimização dos recursos ou menor dependência do crédito de investimento para elevar a produção.

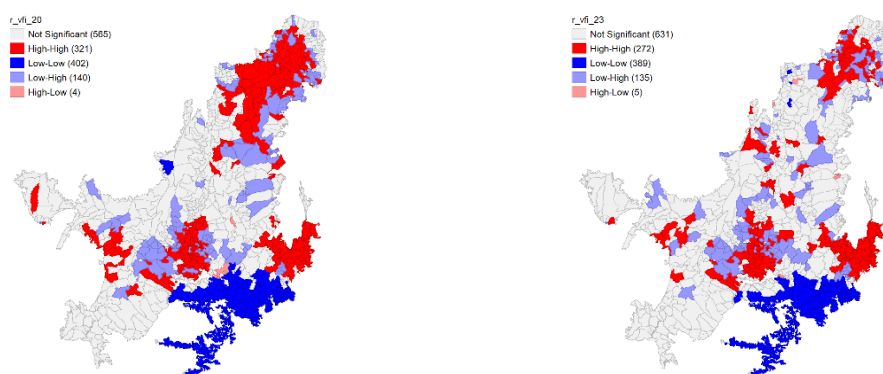


Figura 17: índice LISA univariado para a razão VBP crédito para investimento concedido pelos Fundos Constitucionais à agricultura, 2020/2023.

Em 2023, o número de municípios no cluster alto-alto diminuiu para 272, representando uma variação negativa de aproximadamente 15,3%. Essa redução pode indicar uma ligeira queda na capacidade de alguns municípios de transformar o crédito dos Fundos Constitucionais em aumento de produção agrícola ou uma mudança nos

padrões de acesso e uso desse crédito. Paralelamente, o cluster baixo-baixo também apresentou uma diminuição, passando de 402 para 389 municípios, o que representa uma variação negativa de cerca de 3,2%. Essa redução, ainda que menos acentuada, pode sugerir que alguns municípios do cluster baixo-baixo conseguiram aprimorar a utilização do crédito de investimento, movendo-se para classificações mais eficientes. Essas mudanças percentuais apontam para uma redistribuição na eficácia do uso do crédito para investimento, destacando melhorias e desafios no impacto dos Fundos Constitucionais sobre a produção agrícola em diferentes localidades do Cerrado.

5. ANÁLISE DO VBP AGRÍCOLA NAS CULTURAS DE ALGODÃO, CANA-DE-AÇÚCAR, MILHO E SOJA NOS MUNICÍPIOS DO CERRADO

Esta seção destina-se a apresentar uma abordagem sobre as principais culturas analisadas neste relatório de pesquisa, dando ênfase ao algodão, a cana-de-açúcar, milho e soja produzida em municípios do Cerrado brasileiro.

5.1.1. Distribuição do VBP entre as commodities algodão, cana-de-açúcar, milho e soja no Cerrado brasileiro – média de 2019-2023.

O Gráfico 5, abaixo, apresenta o total do VBP para as culturas selecionadas nesta avaliação para os municípios do Cerrado brasileiro. Assim, entre os anos de 2019 e 2023, o Valor Bruto da Produção (VBP) agrícola dos municípios do Cerrado brasileiro atingiu R\$ 394,575,140,118,36. Nesse contexto, as culturas de soja, algodão, milho e cana-de-açúcar foram fundamentais para a economia agrícola da região, desempenhando um papel essencial na geração de renda e na consolidação do agronegócio nacional. A soja destacou-se como a principal cultura, refletindo a importância desse produto tanto para o mercado interno quanto para a exportação. O algodão, por sua vez, fortaleceu a indústria têxtil e consolidou-se como um produto estratégico no Cerrado. Já o milho e a cana-de-açúcar contribuíram para a diversificação produtiva, trazendo maior resiliência ao setor agrícola e promovendo a sustentabilidade econômica dos municípios.




Gráfico 5: valor bruto da produção nos municípios do cerrado brasileiro nas culturas de cana-de-açúcar, milho, soja e algodão -2019-2023.

Ao longo desses anos, a soja representou, em média, aproximadamente 45,36% do VBP agrícola do Cerrado, seguida pelo algodão com 26,09%, o milho com 16,16% e a cana-de-açúcar com 12,42%. Esses percentuais evidenciam a concentração da produção agrícola em torno dessas culturas, destacando a relevância delas tanto na economia regional quanto no abastecimento nacional. A preponderância dessas commodities demonstra o papel estratégico do Cerrado na produção agrícola do país, com impacto direto no fornecimento de insumos para o mercado interno e nas exportações. Assim, o Cerrado consolida-se como um polo agrícola fundamental, com produção diversificada e de grande importância para o agronegócio brasileiro.

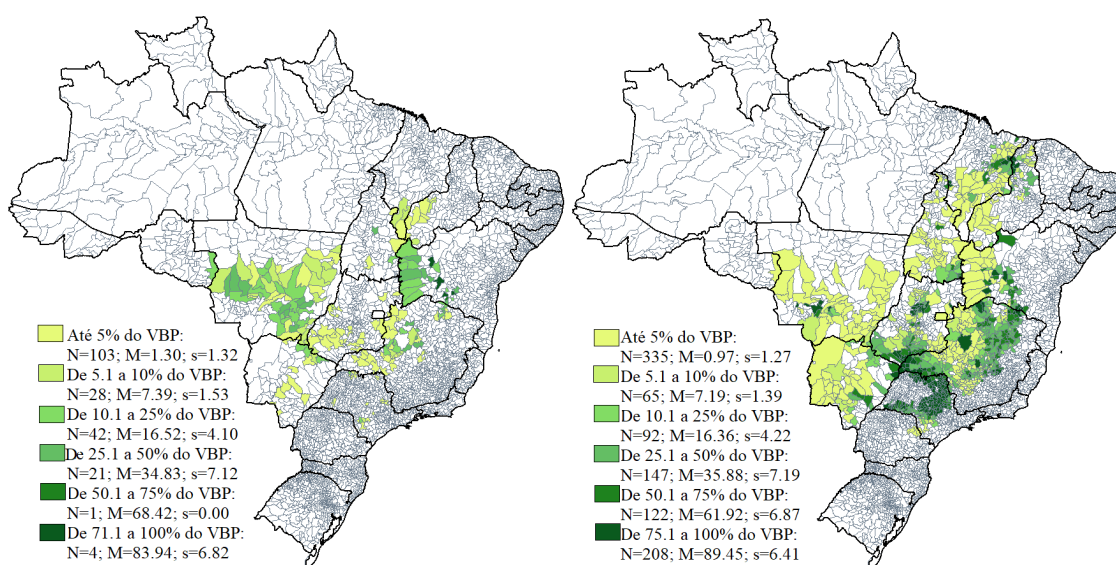
5.1.2. Resultados Espaciais em participação relativa para quatro commodities: algodão, cana-de-açúcar, milho e soja.

A cultura do algodão nos municípios do Cerrado brasileiro mostra uma significativa variabilidade na participação percentual do Valor Bruto da Produção (VBP) (Figura 18). Observa-se que a maioria dos municípios ($N^4=103$) possui uma participação de até 5% do VBP, com média de 1.30 e desvio padrão de 1.32. Esse grupo representa a

⁴N refere-se ao número de municípios em cada faixa apresentada na figura; M reporta-se à média do valor da variável em análise e; s, denomina-se o desvio padrão.

maioria das localidades com menor envolvimento na produção de algodão. À medida que a participação do VBP aumenta, o número de municípios reduz, com destaque para o grupo entre 25.1 e 50% do VBP, que conta com 21 municípios, média de 34.83 e desvio padrão de 7.12. O pequeno grupo de municípios onde o algodão representa entre 75.1 a 100% do VBP (N=4) apresenta uma média de 83.94 e desvio padrão de 6.82, indicando maior especialização nessas áreas.

A produção de cana-de-açúcar se distribui de forma mais ampla entre os municípios do Cerrado, com um total significativo de 208 municípios onde a cultura representa de 75.1 a 100% do VBP, com média de 89.45 e desvio padrão de 6.41. Em contraste, há 335 municípios nos quais a participação da cana-de-açúcar no VBP é de até 5%, com média de 0.97 e desvio padrão de 1.27, evidenciando uma distribuição variada. Os municípios com participação intermediária, entre 25.1 e 50% do VBP, totalizam 147, com uma média de 35.88 e desvio padrão de 7.19, o que indica uma contribuição relevante e estável da cultura da cana-de-açúcar nesses locais.



% do Algodão no VBP – 2019-2023

% da Cana-de-açúcar no VBP – 2019-2023

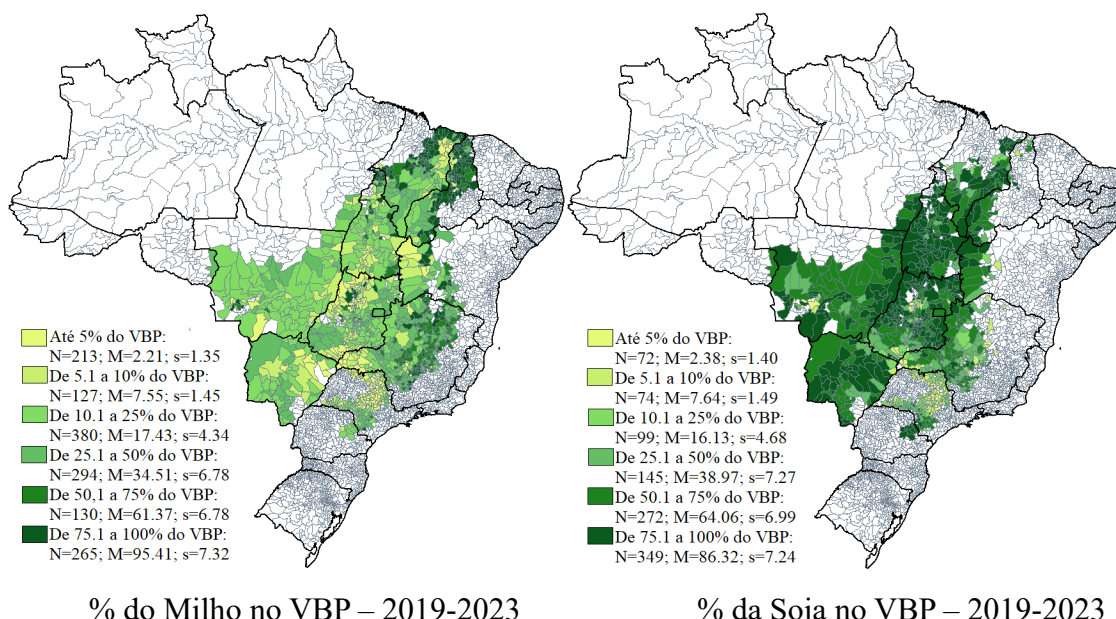


Figura 18: participação percentual das culturas de lavoura temporária selecionadas no VBP total nos municípios do cerrado brasileiro – 2019-2023

A participação do milho no VBP dos municípios do Cerrado também apresenta uma distribuição ampla, com a maior concentração de municípios (N=380) na faixa de 10.1 a 25% do VBP, média de 17.43 e desvio padrão de 4.34. A cultura do milho é altamente relevante em 265 municípios, onde a participação no VBP está entre 75.1 e 100%, com média de 95.41 e desvio padrão de 7.32, sugerindo uma elevada especialização nesses locais. Por outro lado, 213 municípios têm uma participação de até 5% do VBP na produção de milho, com média de 2.21 e desvio padrão de 1.35, o que indica uma presença limitada desta cultura em algumas áreas do Cerrado.

A soja se destaca como a cultura com maior número de municípios onde sua participação no VBP é expressiva. Em 349 municípios, a soja representa entre 75.1 e 100% do VBP, com média de 86.32 e desvio padrão de 7.24, evidenciando sua importância econômica no Cerrado brasileiro. A faixa entre 50.1 e 75% do VBP também conta com um número substancial de municípios (N=272), com média de 64.06 e desvio padrão de 6.99, indicando uma forte dependência desta cultura. Em contraste, em apenas 72 municípios a soja tem participação de até 5% no VBP, com média de 2.38 e desvio padrão de 1.40, mostrando que essa cultura é menos significativa em uma pequena parcela das localidades.

5.1.3. Quociente Locacional para o VBP agrícola nos municípios do Cerrado: commodities algodão, cana-de-açúcar, milho e soja.

Esta subseção apresenta o QL para as culturas selecionadas que operam nos municípios do Cerrado brasileiro. A Figura 19 apresenta os dados em análise individualizada de cada cultura. Assim, a análise do quociente locacional (QL) do VBP da cultura do algodão nos municípios do Cerrado brasileiro revela que uma pequena fração dos municípios apresenta especialização nesta cultura. Dos municípios analisados, 75 (aproximadamente 5,2%) possuem QL maior que 1, com média de 1.88 e desvio padrão de 0.65, indicando uma concentração relevante do algodão nessas localidades. Em contrapartida, 90 municípios (cerca de 6,3%) possuem QL entre 0 e 0.49, com média de 0.17 e desvio padrão de 0.15, evidenciando uma baixa presença do algodão nessas regiões. Já os municípios com QL entre 0.50 e 0.99 (N=34, ou 2,4% do total) possuem média de 0.74 e desvio padrão de 0.13, representando uma presença intermediária da cultura do algodão.

Para a cana-de-açúcar, observa-se uma predominância maior em termos de especialização dentro do Cerrado brasileiro. Dos municípios analisados, 778 (54,3%) têm um QL superior a 1, indicando uma média de 5.67 e desvio padrão de 2.25, o que demonstra uma forte concentração da produção de cana-de-açúcar. Em comparação, os municípios com QL entre 0 e 0.49 representam 11,4% do total, com média de 0.15 e desvio padrão de 0.14, sugerindo uma participação pouco expressiva. Já os municípios com QL entre 0.50 e 0.99, totalizando 58 (ou 4% dos municípios), apresentam média de 0.72 e desvio padrão de 0.14, caracterizando uma contribuição moderada para o VBP de cana-de-açúcar.

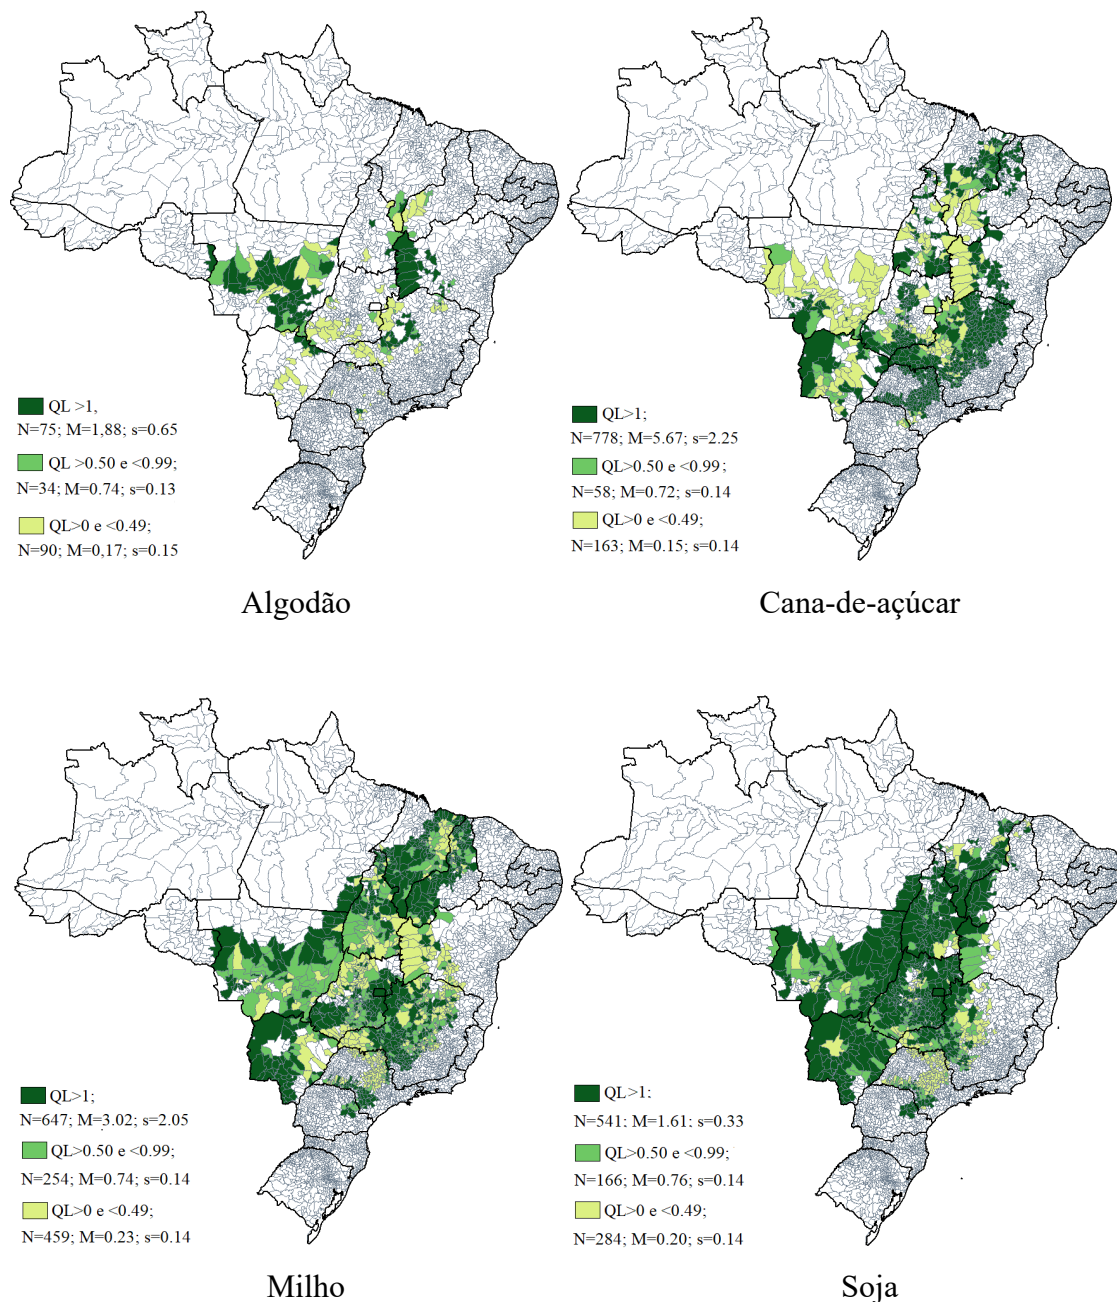


Figura 19: Quociente Locacional das culturas de lavoura temporária nos municípios do cerrado brasileiro – 2019-2023

A cultura do milho no Cerrado brasileiro também exibe uma significativa concentração, com 647 municípios (45,1% do total) apresentando QL superior a 1, média de 3.02 e desvio padrão de 2.05, sinalizando uma importante especialização na produção de milho. Municípios com QL entre 0.50 e 0.99 representam 17,7% do total (N=254), com média de 0.74 e desvio padrão de 0.14, demonstrando uma participação intermediária

no VBP de milho. Por outro lado, 459 municípios (32% do total) possuem QL entre 0 e 0.49, com média de 0.23 e desvio padrão de 0.14, indicando uma presença mais dispersa e de menor importância do milho nesses locais.

A soja apresenta uma elevada especialização em diversos municípios do Cerrado brasileiro, com 541 municípios (37,7%) possuindo QL superior a 1, média de 1.61 e desvio padrão de 0.33, refletindo sua expressiva participação na produção agrícola da região. Outros 166 municípios (11,6%) estão na faixa de QL entre 0.50 e 0.99, com média de 0.76 e desvio padrão de 0.14, o que sugere uma importância moderada da soja no VBP local. Finalmente, há 284 municípios (19,8%) com QL entre 0 e 0.49, média de 0.20 e desvio padrão de 0.14, onde a soja tem menor relevância econômica, indicando uma distribuição mais variada da especialização nessa cultura.

5.1.4. Índice LISA para as culturas de algodão, cana-de-açúcar, milho e soja nos municípios do Cerrado brasileiro – 2019-2023.

A análise do índice LISA para as principais culturas agrícolas dos municípios do Cerrado brasileiro, entre 2019 e 2023, revela padrões distintos de concentração espacial para cada uma das culturas de algodão, cana-de-açúcar, milho e soja (Figura 20). O cultivo de algodão, por exemplo, destaca-se por apresentar uma formação de cluster alto-alto com 116 municípios, evidenciando uma forte concentração de produção em regiões específicas. A ausência de aglomeração no cluster baixo-baixo indica que os municípios com baixa produção de algodão estão mais dispersos e não apresentam áreas de baixa intensidade agrupadas. Esse comportamento pode estar relacionado ao perfil especializado e de alto investimento requerido pelo cultivo do algodão, o que concentra sua produção em locais de maior capacidade produtiva.

A cana-de-açúcar, em contraste, apresenta um padrão de aglomeração mais difuso, com um cluster alto-alto englobando 278 municípios, indicando uma maior distribuição espacial de áreas com alta produção. Além disso, a presença de um cluster baixo-baixo formado por 207 municípios revela uma coexistência de áreas com baixa e alta produção de cana-de-açúcar no Cerrado. Esse padrão pode ser explicado pela natureza do cultivo da cana, que se adapta a diferentes contextos produtivos e níveis tecnológicos, possibilitando que municípios com diferentes níveis de produtividade estejam próximos uns dos outros.

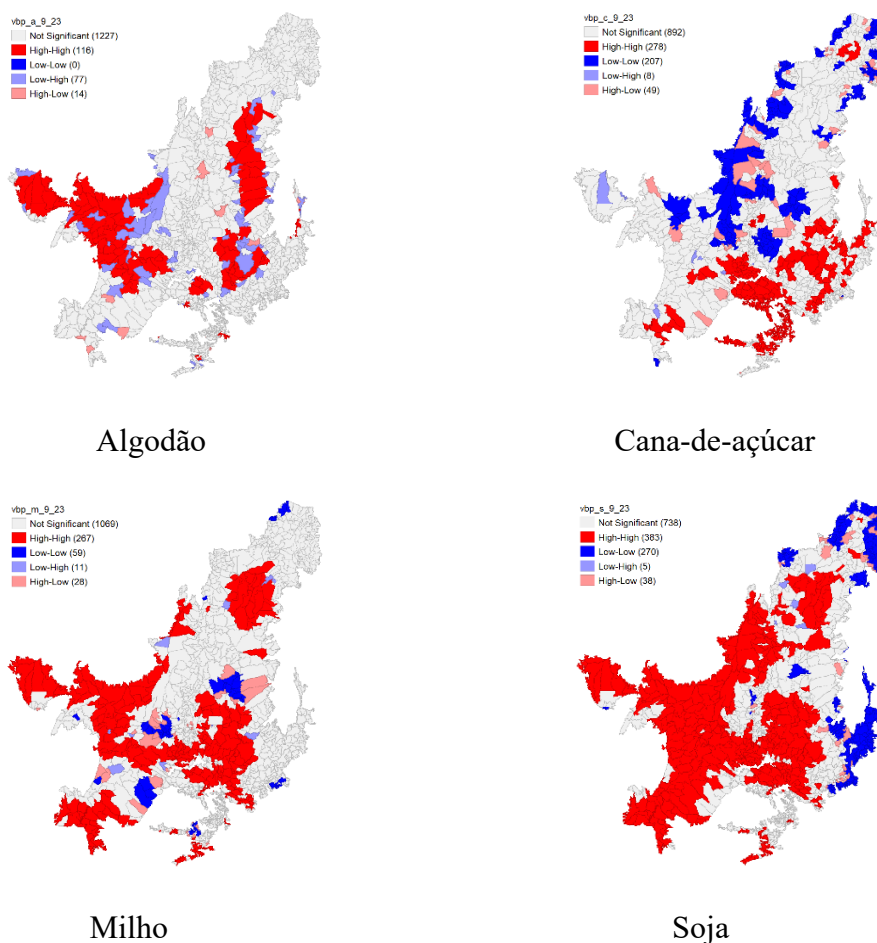


Figura 20: índice LISA para as culturas de algodão, cana-de-açúcar, milho e soja nos municípios do Cerrado brasileiro – 2019-2023.

No caso do milho, o índice LISA revela um cluster alto-alto com 267 municípios, mostrando uma significativa concentração de áreas de alta produção. O cluster baixo-baixo, por outro lado, conta com 59 municípios, apontando uma menor dispersão de áreas de baixa produtividade. Esse comportamento sugere que o milho é cultivado de maneira intensiva em regiões específicas do Cerrado, onde há melhores condições agronômicas ou maior infraestrutura de suporte, enquanto as áreas de menor produção estão mais isoladas e menos frequentes. Esse cenário é comum em regiões onde o milho possui um papel estratégico na rotação de culturas, principalmente com a soja.

A soja, por sua vez, apresenta o maior cluster alto-alto entre as culturas analisadas, abrangendo 383 municípios, evidenciando sua predominância e expansão no Cerrado brasileiro. O cluster baixo-baixo, formado por 270 municípios, revela a existência de um expressivo número de áreas com baixa produção, indicando que a soja é amplamente

cultivada, mas com intensidades produtivas bastante variadas ao longo da região. Esse padrão pode ser atribuído à versatilidade da soja e ao seu papel de destaque no mercado de exportação, que incentiva sua produção em diversos municípios, mesmo onde as condições de produtividade sejam limitadas. A distribuição espacial da soja, portanto, mostra sua importância econômica e a dependência do Cerrado em relação a essa commodity, além de sugerir que essa cultura é cultivada de forma heterogênea quanto à intensidade de produção.

5.1.5. Resultados Econométricos espaciais

Esta seção foi destinada a apresentação dos resultados econométrico espaciais. Aqui, busca-se evidências empíricas acerca dos impactos do crédito à agricultura sobre o valor bruto da produção nos municípios do Cerrado brasileiro em 2023.

5.1.5.1. Testes LM e LM robustos para a escolha do Modelo Espacial – Municípios do cerrado brasileiro

A Tabela 4 apresenta os testes LM (Lagrange Multiplier) para os modelos OLS e SLX aplicados ao Valor Bruto da Produção (VBP) agrícola per capita nos municípios do Cerrado brasileiro em 2023, conforme sugerem Florax e Rey (1995), LeSage e Pace (2009), Debarsy e Ertur (2010). Para o modelo OLS, os testes LMerr e LMlag indicaram significância estatística ($p\text{-valor} < 0.001$), sugerindo a presença de autocorrelação espacial. No entanto, ao analisar os testes robustos, observa-se que RLMerr é significativo ($p\text{-valor} < 0.001$), mas RLMlag não é ($p\text{-valor} = 0.244$), indicando que a autocorrelação espacial está mais relacionada ao erro do que ao lag espacial.

Tabela 4: Teste LM para os modelos OLS e SLX para o VBP per capita da agricultura nos municípios do cerrado brasileiro

OLS			SLX		
LMerr = 43.716	df=1	p-value < 0.000	LMerr = 38.669	df=1	p-value < 0.0000
LMlag = 10.712	df=1	p-value < 0.001	LMlag = 39.593	df = 1	p-value < 0.000
RLMerr = 34.362	df=1	p-value < 0.000	RLMerr = 0.20464	df = 1	p-value < 0.651
RLMlag = 1.3586	df=1	p-value = 0.244	RLMlag = 1.1277	df = 1	p-value = 0.288

Fonte: elaboração dos autores com dados da pesquisa, 2024.

Para o modelo SLX, os testes LMerr e LMlag também foram significativos, mas os robustos RLMerr e RLMlag não apresentaram significância (p-valores de 0.651 e 0.288, respectivamente), sugerindo que a inclusão de variáveis espaciais no modelo SLX já corrigiu a dependência espacial presente. Com base nos resultados, o modelo SLX parece ser uma escolha mais adequada que o OLS, pois a inclusão de covariáveis espaciais atenua a autocorrelação espacial nos resíduos, eliminando a necessidade de ajustes adicionais para capturar essa dependência. Porém, seguiu-se com as estimações dos modelos se, abaixo, na Tabela 5 estão os resultados dos testes do I de Moran dos resíduos e a simulação de Monte Carlo do I de Moran dos resíduos.

5.1.5.2. Testes de randomização do índice de Moran dos Resíduos e Simulação de Monte Carlo do teste de randomização para a escolha do Modelo Espacial – Municípios do cerrado brasileiro

Na Tabela 5, são apresentados os resultados do teste de Moran's I e da simulação de Monte Carlo para diferentes modelos espaciais (OLS, SLX, SAR, SDEM e SEM) aplicados ao VBP agrícola per capita. Para os modelos OLS, SLX e SAR, o teste de Moran's I apresenta valores elevados e significativos (p-valor < 0.001), indicando a presença de autocorrelação espacial nos resíduos. Em contraste, os modelos SDEM e SEM apresentam Moran's I próximo de zero, com p-valores altos (0.470 e 0.491, respectivamente), sugerindo que esses modelos são eficazes na eliminação da autocorrelação espacial residual.

Tabela 5: Teste I de Moran sob randomização e Simulação de Monte Carlo I de Moran para estimativas do VBP per capita da agricultura nos municípios do Cerrado brasileiro – 2023

Model	OLS per_capita	SLX per_capita	SAR per_capita	SDEM per_capita	SEM per_capita
Moran's I statistic st dev	6.735	6.336	5.622	0.073	0.023
p-value	0.000	0.000	0.000	0.470	0.491
Moran's I Monte Carlo Simulation					
Model	OLS per_capita	SLX per_capita	SAR per_capita	SDEM per_capita	SEM per_capita
Statistic	0.1179	0.11088	0.0991	0.00059	-0.0003
p-value	0.00100	0.00100	0.00100	0.50000	0.46100

Fonte: elaboração dos autores com dados da pesquisa, 2024.

A simulação de Monte Carlo corrobora esses achados, indicando que os modelos SDEM e SEM possuem estatísticas de Moran próximas de zero e p-valores não significativos, reforçando sua adequação para capturar a dependência espacial nos dados. Entre esses, o SDEM apresenta melhor ajuste geral devido à sua flexibilidade em modelar interações espaciais tanto nos erros quanto nos lags das covariáveis.

Com base nos resultados das Tabelas 4 e 5, o modelo SDEM se destaca como a melhor escolha para ajustar o VBP agrícola per capita nos municípios do Cerrado em 2023. Ele é eficaz em eliminar a autocorrelação espacial residual (como indicado pelo Moran's I) e captura de forma mais abrangente as interações espaciais. Embora o modelo SEM também elimine a autocorrelação, o SDEM é preferido devido à sua capacidade de lidar simultaneamente com efeitos espaciais em erros e variáveis explicativas.

Portanto, o modelo SDEM não apenas ajusta adequadamente os dados, mas também fornece uma estrutura analítica mais completa para capturar a complexidade das interações espaciais na dinâmica do VBP agrícola nos municípios do Cerrado brasileiro em 2023. Assim, este foi o modelo escolhido para esta análise, respeitando os resultados dos testes realizados.

5.1.5.3. Spatial Durbin Error Model – SDEM Per capita – Municípios do Cerrado brasileiro

A Tabela 6 apresenta os resultados dos modelos SDEM e o seu lag, que avaliam o impacto do crédito agrícola no Valor Bruto da Produção (VBP) per capita em 2023, considerando os municípios do Cerrado brasileiro. O modelo SDEM captura os efeitos diretos das variáveis explicativas e considera as interações espaciais nos erros, enquanto o seu lag incorpora efeitos espaciais no lag das variáveis independentes, conforme também foi constatado em Santos *et al.* (2023). A variável dependente e todas as independentes estão expressas em logaritmo natural, permitindo interpretar os coeficientes como elasticidades. As variáveis explicativas incluem diferentes tipos de crédito (investimento, custeio e fundos constitucionais), concedidos entre 2019 e 2023, além de fatores regionais e ambientais, como precipitação e características estruturais dos municípios.

A análise dos coeficientes significativos no modelo SDEM revela impactos importantes dos créditos para investimento e custeio. O crédito per capita concedido por bancos privados para investimento em 2019 (cper_inv_19) apresentou um coeficiente positivo e significativo de 0.015, indicando que um aumento de 1% nesse crédito está associado a um crescimento médio de 0.015% no VBP per capita em 2023. Esse impacto demonstra a persistência dos efeitos de longo prazo do crédito para investimento na produtividade agrícola, especialmente em municípios que possivelmente alocaram esses recursos em infraestrutura ou melhorias tecnológicas. De forma similar, o crédito para investimento concedido em 2021 (cper_inv_21) também mostrou um coeficiente significativo de 0.014, reforçando que os investimentos recentes continuam influenciando positivamente a produtividade agrícola nos municípios do Cerrado. Os resultados convergem com Costa *et al.* (2022), que defendem que os créditos de longo prazo contribuem para melhorias em infraestrutura agrícola e tecnologias. Segundo o estudo, municípios com menor produtividade inicial tendem a apresentar maiores ganhos proporcionais quando expostos a investimentos estruturais.

Tabela 6: Impactos dos créditos à agricultura sobre o VBP dos municípios do Cerrado brasileiro – 2023 – pelos modelos OLS, SAR, SEM, SLX e SDEM.

Variáveis	Dependent variable: vbp_per_23						
	OLS	SAR	SEM	SLX	SLX(lag)	SDEM	SDEM(lag)
vbp_per_19	0.880*** (0.007)	0.873*** (0.007)	0.879*** (0.007)	0.880*** (0.007)	0.013 (0.013)	0.879*** (0.007)	0.011 (0.013)
cper_inv_19	0.016*** (0.005)	0.015*** (0.005)	0.015*** (0.005)	0.016*** (0.005)	0.003 (0.011)	0.015*** (0.005)	-0.001 (0.012)
cper_inv_20	-0.013*** (0.005)	-0.012** (0.005)	-0.014*** (0.005)	-0.012** (0.005)	0.007 (0.010)	-0.011** (0.005)	0.007 (0.010)
cper_inv_21	0.015*** (0.005)	0.016*** (0.004)	0.015*** (0.004)	0.014*** (0.005)	-0.001 (0.010)	0.014*** (0.004)	-0.001 (0.010)
cper_inv_22	-0.002 (0.004)	-0.002 (0.004)	-0.001 (0.004)	-0.003 (0.004)	-0.003 (0.009)	-0.002 (0.004)	-0.001 (0.009)
cper_cust_19	0.002 (0.005)	0.002 (0.005)	0.004 (0.005)	0.003 (0.005)	-0.015 (0.011)	0.003 (0.005)	-0.013 (0.011)
cper_cust_20	-0.007 (0.005)	-0.007 (0.005)	-0.008 (0.005)	-0.006 (0.006)	0.003 (0.012)	-0.007 (0.005)	0.003 (0.012)
cper_cust_21	-0.008 (0.005)	-0.008* (0.005)	-0.007 (0.005)	-0.008 (0.005)	-0.004 (0.012)	-0.007 (0.005)	-0.001 (0.012)
cper_cust_22	-0.003 (0.005)	-0.003 (0.005)	-0.003 (0.004)	-0.003 (0.005)	0.004 (0.010)	-0.004 (0.005)	0.004 (0.010)
cper_cust_23	0.009* (0.005)	0.008* (0.005)	0.009* (0.005)	0.010** (0.005)	0.007 (0.010)	0.010** (0.005)	0.004 (0.010)

	(0.005)	(0.005)	(0.005)	(0.005)	(0.011)	(0.005)	(0.011)
cper_bnd_19	0.006	0.006	0.008*	0.003	-0.023**	0.003	-0.021**
	(0.004)	(0.004)	(0.004)	(0.005)	(0.009)	(0.005)	(0.010)
cper_bnd_20	-0.010**	-0.011**	-0.011**	-0.010**	0.014	-0.009**	0.015
	(0.005)	(0.005)	(0.004)	(0.005)	(0.011)	(0.005)	(0.011)
cper_bnd_21	-0.008*	-0.008*	-0.010**	-0.007	0.015	-0.008*	0.015
	(0.004)	(0.004)	(0.004)	(0.004)	(0.009)	(0.004)	(0.010)
cper_bnd_22	-0.006*	-0.006	-0.006	-0.006	-0.005	-0.006	-0.005
	(0.004)	(0.004)	(0.004)	(0.004)	(0.008)	(0.004)	(0.009)
cper_fun_cust_19	-0.009	-0.010	-0.009	-0.008	-0.005	-0.007	0.004
	(0.006)	(0.006)	(0.006)	(0.006)	(0.013)	(0.006)	(0.013)
cper_fun_cust_20	-0.002	-0.003	-0.002	-0.002	0.015	-0.002	0.010
	(0.008)	(0.007)	(0.007)	(0.008)	(0.018)	(0.008)	(0.018)
cper_fun_cust_21	0.014*	0.014*	0.013*	0.013*	-0.007	0.012	-0.010
	(0.008)	(0.008)	(0.007)	(0.008)	(0.016)	(0.008)	(0.017)
cper_fun_cust_22	-0.002	-0.001	0.001	0.001	-0.015	0.001	-0.017
	(0.006)	(0.006)	(0.006)	(0.006)	(0.012)	(0.006)	(0.012)
cper_fun_cust_23	-0.003	-0.003	-0.006	-0.008	0.015	-0.008	0.014
	(0.005)	(0.005)	(0.005)	(0.006)	(0.011)	(0.006)	(0.011)
cper_fun_inv_19	0.009	0.009	0.012	0.006	-0.042**	0.005	-0.047***
	(0.008)	(0.008)	(0.008)	(0.008)	(0.017)	(0.008)	(0.018)
cper_fun_inv_20	-0.026***	-0.025***	-0.028***	-0.027***	0.023	-0.027***	0.021
	(0.008)	(0.008)	(0.008)	(0.008)	(0.019)	(0.008)	(0.020)
cper_fun_inv_21	-0.003	-0.002	-0.003	-0.004	0.021	-0.003	0.028
	(0.009)	(0.009)	(0.009)	(0.010)	(0.022)	(0.009)	(0.023)
cper_fun_inv_22	0.023***	0.022***	0.021***	0.018**	0.010	0.019**	0.013
	(0.008)	(0.007)	(0.007)	(0.008)	(0.016)	(0.008)	(0.017)
o_for_lt_22	0.002	0.003	0.003	0.006	0.018	0.007	0.012
	(0.012)	(0.012)	(0.011)	(0.012)	(0.024)	(0.011)	(0.025)
o_for_lt_23	-0.004	-0.004	-0.003	-0.008	-0.021	-0.009	-0.015
	(0.012)	(0.012)	(0.011)	(0.012)	(0.024)	(0.012)	(0.025)
ml_chuva_23	0.033	0.021	0.017	0.019	0.151	0.017	0.043
	(0.060)	(0.059)	(0.061)	(0.068)	(0.131)	(0.064)	(0.137)
ml_chuva2_23	-0.003	-0.002	-0.002	-0.003	-0.010	-0.003	-0.002
	(0.005)	(0.005)	(0.005)	(0.006)	(0.011)	(0.006)	(0.011)
d_no	-0.035	-0.045	-0.030	-0.015	-0.032	-0.152	0.103
	(0.083)	(0.081)	(0.104)	(0.450)	(0.470)	(0.405)	(0.429)
d_ne	-0.164**	-0.162**	-0.155	-0.057	-0.132	-0.190	0.005
	(0.079)	(0.078)	(0.101)	(0.448)	(0.466)	(0.402)	(0.424)
d_se	-0.047	-0.072	-0.046	0.034	-0.091	-0.119	0.070
	(0.075)	(0.074)	(0.096)	(0.437)	(0.453)	(0.392)	(0.413)
d_co	-0.134*	-0.147*	-0.129	0.124	-0.258	-0.039	-0.115
	(0.081)	(0.080)	(0.102)	(0.444)	(0.463)	(0.399)	(0.422)
Constant	0.021	0.019	0.080	-0.416		-0.070	
	(0.204)	(0.201)	(0.214)	(0.403)		(0.461)	
Observations	1,434	1,434	1,434	1,434		1,434	

R ²	0.944		0.945
Adjusted R ²	0.942		0.942
Log Likelihood	78.341	95.784	112.638
sigma ²	0.052	0.050	0.049
Akaike Inf. Crit.	-88.682	-123.569	-95.275
Residual Std. Error	0.233(df=1402)		0.232(df= 371)
F Statistic	755.232*** (df=31; 1402)		379.793*** (df=62; 1371)
Wald Test (df = 1)	10.891***	55.372***	50.989*** (df=1)
LR Test (df = 1)	10.701***	45.588***	41.234*** (df=1)

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

O crédito para custeio concedido por bancos privados em 2023 (cper_cust_23) apresentou um coeficiente positivo significativo de 0.010. Isso reflete o impacto direto e imediato do crédito para custeio no VBP agrícola, que é utilizado para financiar despesas operacionais e insumos necessários para a produção agrícola no curto prazo. Essa elasticidade demonstra que o crédito de custeio é um fator essencial para sustentar a produção em municípios com maior atividade agrícola, o que converge com Silva e Pereira (2021), que defendem que créditos para custeio aplicados em regiões emergentes maximizam o retorno devido à menor saturação do uso de recursos financeiros no setor agrícola. Por outro lado, o crédito concedido pelo BNDES para agricultura em 2021 (cper_bnd_21) apresentou um coeficiente negativo e significativo de -0.008. Esse resultado pode estar relacionado a desafios na alocação eficiente dos recursos ou à concentração de crédito em áreas que já possuem limitações estruturais, como baixa infraestrutura ou capacidade técnica, conforme sugere Fonseca *et al.* (2020). O estudo sugere que o impacto limitado do crédito do BNDES está relacionado a problemas de alocação em áreas com menor capacidade técnica e estrutural, além da priorização de grandes produtores que já têm acesso a financiamento privado.

No modelo SDEM(lag), os efeitos espaciais também evidenciam padrões relevantes. O crédito para investimento concedido em 2022 (cper_inv_22) apresentou um coeficiente negativo e significativo de -0.053, indicando externalidades negativas sobre os municípios vizinhos. Esse efeito pode refletir competição por recursos, desequilíbrios regionais ou limitações na capacidade de absorção em áreas adjacentes. Por outro lado, o crédito para custeio concedido em 2022 (cper_cust_22) mostrou um coeficiente positivo significativo de 0.130, destacando que esse tipo de crédito não apenas beneficia os

municípios receptores, mas também tem um efeito positivo em áreas próximas, possivelmente devido ao fortalecimento das cadeias produtivas regionais. No entanto, novamente o crédito do BNDES em 2021 (*cper_bnd_21*) apresentou um impacto negativo significativo de -0.021, reiterando a necessidade de uma maior atenção na política de alocação desses recursos para minimizar efeitos adversos entre municípios.

Esses resultados mostram que os impactos dos créditos agrícolas variam conforme o tipo, o tempo de concessão e os efeitos espaciais. Créditos para custeio têm efeitos imediatos e positivos, especialmente nos municípios com maior capacidade produtiva, enquanto os créditos para investimento demonstram efeitos persistentes, mas podem gerar desigualdades regionais quando não bem alocados. O modelo SDEM(lag) destaca a importância de considerar os impactos espaciais dos créditos, evidenciando que estratégias regionais mais equilibradas e integradas são essenciais para maximizar os benefícios dos recursos destinados à agricultura no Cerrado brasileiro.

5.1.5.4. Spatial Durbin Error Model – SDEM Quantílico Per capita

A Tabela apresenta os resultados do modelo SDEM Quantílico, com foco nos municípios do Cerrado Brasileiro, avaliando os impactos do crédito agrícola e de outras variáveis explicativas no valor bruto da produção per capita (VBP) em 2023. A variável dependente, em logaritmo natural, permite interpretar os coeficientes como elasticidades, ou seja, variações percentuais no VBP em resposta a variações percentuais nas variáveis explicativas. A análise inclui os coeficientes estatisticamente significativos em diferentes quantis da distribuição do VBP e considera tanto os efeitos diretos quanto os efeitos nos municípios vizinhos (SDEM lag).

No 1º decil, o crédito para investimento em 2019 (*cper_inv_19*) apresentou um coeficiente positivo e significativo, indicando que um aumento de 1% nesse crédito resultou em um crescimento de 0,013% no VBP per capita dos municípios menos produtivos do Cerrado. Este impacto destaca a relevância dos investimentos de longo prazo em regiões de baixa produtividade. Contudo, esse efeito desaparece nos quantis superiores, sugerindo que o impacto do crédito de 2019 foi mais relevante para os municípios com menor VBP. O crédito para custeio em 2023 (*cper_cust_23*) também foi significativo no 1º decil, com uma elasticidade de 0,009%, e no 1º quartil, com 0,005%.

Isso evidencia que os créditos recentes para custeio têm contribuído diretamente para o aumento da produtividade agrícola em municípios menos desenvolvidos do Cerrado.

No modelo SDEM lag, os efeitos dos créditos para custeio de 2023 (cper_cust_23_lag) não foram estatisticamente significativos, o que sugere que os impactos positivos desses créditos são limitados ao município beneficiado, sem gerar externalidades espaciais nos municípios vizinhos.

Os créditos concedidos pelo BNDES apresentaram resultados mistos. O crédito de custeio em 2020 (cper_bnd_20) mostrou coeficientes negativos e significativos no 1º decil, 1º quartil e mediana, com elasticidades de -0,012%, -0,005% e -0,004%, respectivamente. Esses resultados indicam que, embora o crédito do BNDES tenha sido disponibilizado, ele pode ter sido alocado de maneira ineficiente ou aplicado em regiões onde os retornos foram limitados. Nos municípios vizinhos, no entanto, o modelo SDEM lag não encontrou significância para esse crédito, sugerindo que os efeitos negativos estão concentrados diretamente nos municípios beneficiados.

Entre os Fundos Constitucionais de Financiamento, o crédito para custeio em 2021 (cper_fun_cust_21) teve efeitos positivos e significativos no 1º quartil (0,008%) e na mediana (0,009%), destacando seu papel relevante para a produtividade em municípios com desempenho agrícola intermediário. Já o crédito para investimento em 2022 (cper_fun_inv_22) foi significativo em praticamente todos os quantis analisados, com efeitos notáveis no 3º quartil (0,013%). Isso indica que os investimentos recentes foram especialmente eficazes em áreas mais produtivas, convergindo com Oliveira *et al.* (2023). No modelo SDEM lag, os efeitos nos municípios vizinhos também foram positivos e significativos no 3º quartil, com elasticidade de 0,016%, evidenciando externalidades produtivas positivas.

Tabela 7: SDEM Quantílico espacial para o valor bruto da produção nos municípios do Cerrado brasileiro em função do crédito à agricultura.

Variáveis	Dependent variable: vbp_per_23					
	(1ºDecil)	(1ºQuartil)	(Mediana)	(3ºQuartil)	(90ºPercentil)	(99ºPercentil)
vbp_per_19	0.861*** (0.009)	0.895*** (0.005)	0.916*** (0.003)	0.929*** (0.004)	0.936*** (0.007)	0.867*** (0.042)
cper_inv_19	0.013** (0.006)	0.005 (0.003)	0.003 (0.002)	0.004 (0.003)	0.009 (0.006)	-0.003 (0.040)
cper_inv_20	-0.005 (0.007)	-0.002 (0.003)	-0.003 (0.002)	-0.001 (0.003)	-0.005 (0.005)	-0.010 (0.035)

cper_inv_21	0.003 (0.006)	0.001 (0.002)	0.001 (0.002)	0.003 (0.003)	0.006 (0.004)	0.023 (0.034)
cper_inv_22	-0.0001 (0.005)	0.002 (0.002)	-0.001 (0.002)	-0.004* (0.002)	-0.003 (0.004)	0.001 (0.025)
cper_cust_19	-0.002 (0.006)	-0.004 (0.002)	0.0004 (0.002)	-0.002 (0.003)	-0.008* (0.005)	0.045 (0.045)
cper_cust_20	0.006 (0.007)	-0.001 (0.003)	-0.0005 (0.003)	-0.001 (0.003)	-0.006 (0.004)	-0.038 (0.053)
cper_cust_21	-0.010 (0.007)	-0.0003 (0.003)	-0.004** (0.002)	-0.004 (0.003)	-0.004 (0.006)	-0.005 (0.040)
cper_cust_22	-0.008 (0.005)	-0.001 (0.002)	0.0001 (0.002)	-0.0002 (0.003)	0.001 (0.004)	-0.015 (0.027)
cper_cust_23	0.009* (0.005)	0.005* (0.003)	0.001 (0.002)	0.004 (0.003)	0.006 (0.005)	0.012 (0.036)
cper_bnd_19	-0.004 (0.005)	-0.004 (0.002)	-0.001 (0.002)	0.0003 (0.002)	0.0001 (0.004)	0.015 (0.033)
cper_bnd_20	-0.012** (0.006)	-0.005** (0.002)	-0.004** (0.002)	-0.001 (0.002)	-0.0002 (0.005)	-0.016 (0.037)
cper_bnd_21	0.002 (0.005)	-0.0003 (0.002)	-0.003 (0.002)	-0.007*** (0.002)	-0.004 (0.004)	-0.040* (0.023)
cper_bnd_22	0.001 (0.004)	-0.001 (0.002)	-0.003** (0.001)	0.001 (0.002)	-0.005 (0.004)	-0.019 (0.023)
cper_fun_cust_19	-0.001 (0.006)	-0.007** (0.003)	-0.005** (0.002)	-0.005 (0.003)	-0.001 (0.009)	-0.005 (0.035)
cper_fun_cust_20	-0.006 (0.009)	-0.006* (0.003)	0.0002 (0.002)	-0.001 (0.005)	-0.003 (0.013)	-0.004 (0.037)
cper_fun_cust_21	0.006 (0.010)	0.008** (0.004)	0.009*** (0.003)	0.007 (0.004)	0.004 (0.012)	0.013 (0.036)
cper_fun_cust_22	0.007 (0.009)	0.005 (0.003)	0.002 (0.002)	0.006* (0.003)	0.008 (0.008)	0.018 (0.036)
cper_fun_cust_23	-0.005 (0.008)	-0.002 (0.003)	-0.004** (0.002)	-0.005 (0.003)	-0.002 (0.008)	-0.013 (0.032)
cper_fun_inv_19	-0.003 (0.012)	-0.001 (0.005)	-0.007* (0.003)	-0.006 (0.004)	-0.011 (0.012)	0.033 (0.069)
cper_fun_inv_20	-0.005 (0.013)	-0.011** (0.005)	-0.010*** (0.003)	-0.006 (0.004)	-0.008 (0.011)	-0.126* (0.067)
cper_fun_inv_21	-0.017 (0.011)	-0.008 (0.006)	0.002 (0.003)	-0.008 (0.005)	-0.0004 (0.011)	0.062 (0.071)
cper_fun_inv_22	0.019** (0.010)	0.011* (0.006)	0.009*** (0.003)	0.013*** (0.004)	0.015 (0.012)	0.029 (0.060)
o_for_lt_22	-0.009 (0.010)	-0.004 (0.004)	-0.007 (0.005)	-0.0001 (0.004)	0.002 (0.010)	0.007 (0.083)
o_for_lt_23	0.011 (0.010)	0.002 (0.004)	0.008 (0.005)	-0.0002 (0.004)	-0.006 (0.010)	-0.011 (0.083)
ml_chuva_23	0.237 (0.357)	0.012 (0.127)	0.054 (0.048)	0.058 (0.116)	0.085 (0.060)	0.197 (4.277)

ml_chuva2_23	-0.019 (0.027)	-0.002 (0.010)	-0.006* (0.004)	-0.008 (0.009)	-0.007 (0.005)	-0.018 (0.328)
d_no	-0.145 (6.021)	-0.070 (1.459)	-0.032 (1.580)	0.079 (1.655)	0.619 (16.927)	0.535 (74.241)
d_ne	-0.228 (6.022)	-0.052 (1.459)	0.042 (1.581)	0.048 (1.655)	0.536 (16.925)	0.580 (74.212)
d_se	-0.199 (6.019)	-0.060 (1.458)	0.041 (1.579)	0.147 (1.654)	0.637 (16.926)	0.989 (74.230)
d_co	-0.142 (6.019)	-0.036 (1.459)	0.103 (1.580)	0.188 (1.655)	0.614 (16.926)	1.109 (74.249)
vbp_per_19_lag	0.008 (0.015)	-0.002 (0.006)	-0.009* (0.005)	-0.013** (0.006)	-0.007 (0.012)	0.001 (0.103)
cper_inv_19_lag	0.004 (0.014)	0.006 (0.005)	0.007 (0.004)	0.001 (0.006)	-0.017 (0.011)	-0.012 (0.070)
cper_inv_20_lag	0.014 (0.013)	0.006 (0.005)	0.006 (0.004)	-0.0002 (0.005)	0.009 (0.008)	0.079 (0.059)
cper_inv_21_lag	0.008 (0.012)	0.00003 (0.005)	-0.001 (0.004)	-0.003 (0.005)	0.001 (0.008)	-0.025 (0.050)
cper_inv_22_lag	-0.005 (0.008)	-0.003 (0.005)	-0.003 (0.003)	0.002 (0.005)	-0.004 (0.009)	-0.007 (0.059)
cper_cust_19_lag	-0.017* (0.010)	-0.004 (0.004)	-0.001 (0.004)	0.002 (0.005)	0.013 (0.011)	-0.042 (0.062)
cper_cust_20_lag	0.005 (0.012)	0.001 (0.005)	-0.001 (0.005)	-0.005 (0.006)	-0.010 (0.014)	-0.077 (0.091)
cper_cust_21_lag	-0.011 (0.013)	-0.011** (0.005)	-0.008* (0.004)	-0.005 (0.006)	0.003 (0.009)	0.090 (0.089)
cper_cust_22_lag	0.004 (0.012)	0.012** (0.005)	0.005 (0.004)	0.008 (0.005)	0.002 (0.010)	-0.018 (0.059)
cper_cust_23_lag	0.008 (0.010)	-0.002 (0.005)	0.004 (0.004)	0.003 (0.006)	0.007 (0.012)	0.034 (0.070)
cper_bnd_19_lag	-0.020** (0.010)	-0.014*** (0.004)	-0.011*** (0.004)	-0.010** (0.004)	-0.014* (0.008)	-0.001 (0.052)
cper_bnd_20_lag	0.010 (0.011)	0.012*** (0.004)	0.014*** (0.003)	0.012*** (0.005)	0.013 (0.010)	-0.004 (0.050)
cper_bnd_21_lag	-0.001 (0.010)	-0.004 (0.005)	-0.003 (0.003)	0.003 (0.005)	-0.001 (0.010)	0.047 (0.053)
cper_bnd_22_lag	-0.005 (0.008)	-0.001 (0.003)	-0.002 (0.003)	-0.007* (0.004)	0.002 (0.008)	-0.008 (0.047)
cper_fun_cust_19_lag	-0.021 (0.015)	-0.011 (0.007)	-0.002 (0.005)	0.002 (0.007)	0.003 (0.016)	0.095 (0.067)
cper_fun_cust_20_lag	0.041** (0.018)	0.012 (0.009)	0.001 (0.006)	-0.0004 (0.010)	0.008 (0.019)	-0.027 (0.089)
cper_fun_cust_21_lag	-0.001 (0.018)	0.010 (0.008)	0.009* (0.005)	0.001 (0.008)	-0.012 (0.019)	-0.064 (0.097)
cper_fun_cust_22_lag	-0.014 (0.015)	-0.010* (0.006)	-0.011** (0.005)	-0.014** (0.006)	-0.021* (0.013)	-0.110 (0.071)

cper_fun_cust_23_lag	0.003 (0.012)	0.001 (0.006)	-0.001 (0.004)	0.003 (0.005)	0.008 (0.013)	0.097 (0.063)
cper_fun_inv_19_lag	-0.043* (0.023)	-0.012 (0.010)	-0.002 (0.007)	-0.013 (0.011)	0.006 (0.023)	-0.052 (0.105)
cper_fun_inv_20_lag	0.032 (0.026)	0.006 (0.010)	-0.005 (0.009)	0.001 (0.010)	-0.001 (0.020)	0.051 (0.107)
cper_fun_inv_21_lag	-0.023 (0.029)	0.006 (0.012)	0.002 (0.009)	0.012 (0.010)	0.010 (0.025)	0.027 (0.119)
cper_fun_inv_22_lag	0.028 (0.025)	0.009 (0.008)	0.014** (0.007)	0.016** (0.007)	0.005 (0.018)	-0.011 (0.090)
o_for_lt_22_lag	0.029 (0.023)	0.020* (0.011)	0.011 (0.008)	0.010 (0.010)	-0.003 (0.020)	0.004 (0.136)
o_for_lt_23_lag	-0.033 (0.023)	-0.021* (0.011)	-0.013 (0.008)	-0.014 (0.010)	0.007 (0.021)	0.015 (0.150)
ml_chuva_23_lag	0.163 (0.302)	0.013 (0.163)	0.015 (0.053)	0.040 (0.076)	0.132 (0.124)	-2.086 (3.935)
ml_chuva2_23_lag	-0.012 (0.023)	0.001 (0.012)	0.002 (0.004)	0.0002 (0.006)	-0.010 (0.010)	0.143 (0.303)
d_no_lag	0.119 (5.967)	-0.029 (1.450)	-0.038 (1.581)	-0.121 (1.652)	-0.941 (16.693)	-0.073 (74.162)
d_ne_lag	0.148 (5.968)	-0.101 (1.450)	-0.159 (1.581)	-0.139 (1.652)	-1.002 (16.689)	-0.787 (74.125)
d_se_lag	0.205 (5.968)	-0.013 (1.450)	-0.091 (1.580)	-0.178 (1.652)	-1.060 (16.692)	-1.050 (74.167)
d_co_lag	0.156 (5.967)	-0.056 (1.451)	-0.173 (1.581)	-0.263 (1.652)	-1.072 (16.691)	-1.204 (74.215)
Constant	-1.272** (0.632)	-0.042 (0.505)	-0.231 (0.154)	-0.269 (0.190)	-0.207 (0.830)	7.555 (9.198)
Observations	1,434	1,434	1,434	1,434	1,434	1,434

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

As variáveis climáticas e de emprego tiveram menos relevância estatística, apesar da literatura mostrar sua devida importância das variáveis climáticas para justificar ganhos e perdas da produção agrícola (Almeida *et al.*, 2022). A chuva ao quadrado (ml_chuva2_23) foi significativa apenas na mediana, mas com efeito pequeno (-0,006%), indicando que níveis excessivos de chuva podem ter impactado negativamente a produtividade em municípios com desempenho mediano. Já os empregos formais na lavoura temporária em 2022 (o_for_lt_22) não apresentaram significância no modelo direto, mas foram significativos no modelo SDEM lag para o 1º quartil, com elasticidade de 0,020%. Isso sugere que a formalização do trabalho em municípios vizinhos pode gerar efeitos positivos na produção local.

Entre as variáveis regionais, as dummies das regiões Norte, Nordeste e Sudeste não apresentaram significância estatística, tanto no modelo direto quanto no SDEM lag, indicando que as diferenças regionais não influenciaram significativamente os resultados quando controladas pelas demais variáveis.

Em resumo, os resultados mostram que os créditos recentes para custeio e investimento desempenharam papel crucial no aumento do VBP per capita em municípios do Cerrado, com impactos mais evidentes em municípios menos produtivos. Além disso, os Fundos Constitucionais de Financiamento emergem como instrumentos particularmente eficazes, especialmente para investimentos. Contudo, créditos antigos, como os do BNDES, mostraram retornos decrescentes ou negativos, apontando para ineficiências na alocação ou aplicação. Os efeitos espaciais observados no modelo SDEM lag reforçam a importância de políticas que considerem externalidades positivas entre municípios, sobretudo em áreas de maior produtividade. Esses achados destacam a necessidade de um planejamento cuidadoso para maximizar os retornos dos investimentos agrícolas na região do Cerrado.

6. CONSIDERAÇÕES FINAIS

A agricultura tem um papel central na economia brasileira, representando uma das principais fontes de superávit comercial e ocupação rural. No Cerrado brasileiro, a expansão das principais culturas — soja, milho, algodão e cana-de-açúcar — está estreitamente relacionada ao acesso ao crédito rural, que possibilita investimentos em tecnologia, insumos e infraestrutura, essenciais para aumentar a produtividade e a competitividade no setor. O presente estudo investigou a distribuição espacial da produção agrícola e do crédito nos municípios do Cerrado, focando em identificar padrões de concentração e dependência espacial, para avaliar o papel do crédito rural no desenvolvimento econômico dessa região.

O principal objetivo do estudo foi avaliar como a concessão de crédito rural influencia o Valor Bruto da Produção (VBP) agrícola nos municípios do Cerrado, em um contexto de análise espacial que abrange também o Brasil como um todo. O recorte temporal cobre os anos de 2019 a 2023, período que contempla variáveis críticas para o crescimento da produção agrícola e o crédito concedido pelos Fundos Constitucionais de Financiamento, o Banco Nacional de Desenvolvimento Econômico e Social (BNDES) e bancos privados. Os dados de VBP agrícola para as principais culturas de exportação e informações detalhadas sobre o crédito agrícola concedido foram essenciais para a análise, permitindo observar a correlação entre a alocação de crédito e a produtividade agrícola nas diversas regiões e identificar padrões locais e regionais de concentração.

Para alcançar o objetivo proposto, o estudo utilizou uma combinação de métodos de análise espacial e econométrica. Primeiramente, o Quociente Locacional (QL) foi aplicado para mensurar a especialização agrícola nos municípios do Cerrado em relação à média nacional. Esse índice ajuda a identificar áreas onde determinadas culturas são mais intensivamente cultivadas, permitindo comparações regionais sobre a concentração relativa do VBP agrícola. Em seguida, foi empregado o Índice de Moran Global para verificar a autocorrelação espacial dos dados, indicando a presença de clusters e padrões espaciais relevantes. O Índice Local de Associação Espacial (LISA) foi utilizado para mapear clusters específicos de alta ou baixa produtividade, proporcionando uma visão detalhada sobre as áreas de alta e baixa produção agrícola. Por fim, foram aplicados modelos econométricos espaciais, como o Spatial Autoregressive Model (SAR) e o

Spatial Durbin Error Model (SDEM), para capturar a dependência espacial no VBP, avaliando como o crédito rural e outras variáveis influenciam a produtividade agrícola dos municípios vizinhos.

A análise revelou diferenças marcantes entre o Brasil e o Cerrado, evidenciando a concentração da produção agrícola e do crédito em regiões específicas. No Brasil, as regiões Sudeste, Sul e Centro-Oeste emergiram como polos de alta concentração para as principais culturas — soja, milho, algodão e cana-de-açúcar — beneficiando-se de melhor infraestrutura, acesso a tecnologias e crédito mais acessível. Estes fatores conferem às regiões maiores, resiliência e capacidade produtiva, consolidando-as como áreas estratégicas para o agronegócio nacional.

Para o Cerrado, o estudo destacou que a região se consolidou como uma das áreas mais relevantes para a produção agrícola no Brasil, especialmente no caso da soja, que registrou o maior cluster alto-alto entre as culturas analisadas, envolvendo 383 municípios. Esse padrão de concentração reflete a especialização da região e sua importância para o mercado de exportação. A soja, além de ser cultivada extensivamente, também apresenta alta intensidade produtiva, o que torna o Cerrado um polo essencial para a agricultura brasileira. O milho e a cana-de-açúcar mostraram padrões de concentração semelhantes, com clusters alto-alto que englobaram 267 e 278 municípios, respectivamente. Essas áreas de alta produtividade são essenciais para manter a competitividade do setor agrícola na região.

A cultura do algodão, embora menos difundida, apresentou um cluster de alta produtividade em 116 municípios do Cerrado. Esse resultado sugere que o cultivo do algodão está concentrado em áreas específicas da região, onde as condições locais, aliadas ao acesso ao crédito e à tecnologia, permitem um desenvolvimento econômico robusto. A ausência de aglomeração no cluster baixo-baixo indica que municípios com baixa produção de algodão estão dispersos, reforçando a especialização em localidades com maior capacidade de produção.

Os modelos econométricos espaciais reforçaram a importância do crédito rural para o desempenho agrícola da região. A análise econométrica, utilizando os modelos SAR e SDEM, indicou que o acesso ao crédito rural está positivamente correlacionado com o VBP dos municípios do Cerrado, com um impacto mais expressivo quando o crédito é disponibilizado de forma contínua ao longo dos anos. Este efeito foi identificado

principalmente em investimentos que se mantiveram ao longo do período de análise, o que sugere que o impacto do crédito é acumulativo, influenciando o desenvolvimento agrícola mesmo nos anos subsequentes. Adicionalmente, os modelos espaciais apontaram a presença de efeitos de transbordamento, isto é, o crédito concedido a um município tende a beneficiar a produtividade dos municípios vizinhos, ainda que de maneira indireta. Esse resultado revela que o crédito rural tem um efeito multiplicador na economia local, promovendo o desenvolvimento em cadeias produtivas que beneficiam diversas localidades ao redor.

Os resultados trazem implicações importantes para a formulação de políticas públicas voltadas ao desenvolvimento agrícola regional. Primeiramente, as áreas de alta concentração produtiva identificadas pelos clusters alto-alto indicam que políticas de crédito mais direcionadas para o Cerrado podem amplificar o crescimento agrícola, especialmente para culturas de grande valor de mercado, como a soja e o milho. A concessão de crédito rural nessas áreas deve considerar a continuidade do financiamento ao longo dos anos, uma vez que os resultados mostraram que o impacto do crédito é mais duradouro quando investimentos são realizados de forma sustentada. Políticas que incentivem o financiamento de longo prazo, especialmente em tecnologia agrícola e infraestrutura, podem assegurar que a produtividade se mantenha elevada e que o Cerrado continue a desempenhar um papel central na produção nacional.

No entanto, as áreas de baixa produtividade, que se destacaram no cluster baixo-baixo, merecem uma atenção especial. A criação de políticas de crédito mais acessíveis e adaptadas às necessidades desses municípios pode reduzir as desigualdades regionais e promover uma distribuição mais equitativa do desenvolvimento agrícola no Cerrado. Políticas de crédito inclusivas, voltadas para pequenas propriedades e produtores de menor porte, podem contribuir para aumentar a competitividade das áreas menos desenvolvidas, promovendo maior estabilidade econômica e social na região.

Uma limitação fundamental deste estudo é a ausência de dados identificados para cada município, o que restringe a capacidade de análise detalhada e impede uma avaliação mais precisa das dinâmicas locais. Com dados identificados, seria possível empregar uma gama mais ampla de metodologias e obter resultados mais específicos para cada município, além de utilizar abordagens metodológicas mais variadas e adequadas a diferentes realidades. Essa limitação também restringe a capacidade de explorar outras

variáveis contextuais que poderiam influenciar a relação entre crédito e produção agrícola, como fatores climáticos e características demográficas. A inclusão de dados identificados possibilitaria recomendações de políticas ainda mais direcionadas e ampliaria o alcance e a eficácia das ações de apoio ao setor agrícola no Cerrado.

Em conclusão, o presente estudo contribui para a compreensão da dinâmica de produção agrícola e crédito no Cerrado, evidenciando o papel fundamental do crédito rural na promoção do desenvolvimento agrícola e destacando a importância de políticas públicas regionais que considerem tanto os polos produtivos quanto as áreas de menor intensidade produtiva. A continuidade de pesquisas com dados identificados e metodologias avançadas é essencial para aprofundar o conhecimento sobre as necessidades e desafios do Cerrado e para formular políticas cada vez mais eficientes e equitativas, que assegurem o desenvolvimento sustentável e equilibrado de toda a região.

7. 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, 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., & 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>

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.

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-](https://doi.org/10.1016/S0304-4076(98)00009-)

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>

Breusch, T. S., & Pagan, A. R. (1979). A simple test for heteroscedasticity and random coefficient variation. *Econometrica*, 47(5), 1287-1294. <https://doi.org/10.2307/1911963>

Carrer, M. J., Maia, A. G., Vinholis, M. D. M. B., & de Souza Filho, H. M. (2020). Assessing the effectiveness of rural credit policy on the adoption of integrated crop-livestock systems in Brazil. *Land use policy*, 92, 104468.

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>

Crocco, M. A., Galinari, R., Santos, F., Lemos, M. B., & Simões, R. (2006). Metodologia de identificação de aglomerações produtivas locais. *Nova Economia*, 16(2), 211-241. <https://doi.org/10.1590/S0103-63512006000200001>

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.

Debarsy, 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>

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>

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>

Krugman, P. (1991). Geography and trade. MIT Press.

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., & 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>

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.

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>

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.

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>

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 Filho, L. A., Silva, F. J. F., & Queiroz, S. N. (2015). Nordeste industrial: a fragmentação territorial de uma região periférica. *Revista Econômica do Nordeste*, 46(2), 9-24.

Silva, A. C., Lima, E. C., & Lima, E. P. C. (2017). Análise da concentração da produção agrícola nas microrregiões paranaenses em 2001 e 2010. *Revista de Economia da UEG*, 13(2), 1-17.

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 Ensaio*, 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.

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.