

**MODELO DE ESCOLHA TECNOLÓGICA COM CUSTOS DE AJUSTE,
SPILLOVER, PAPEL DO CRÉDITO E DA TERRA**
**TECHNOLOGICAL CHOICE MODEL WITH ADJUSTMENT COSTS, SPILLOVER,
ROLE OF CREDIT AND LAND**

Autor(es): Luis Felipe de Souza Rodrigues¹; Daniel Thomaz Giacomelli Nunes Maciel²

Filiação: Universidade Federal de Mato Grosso

E-mail: 1 – lfsouza25@gmail.com; 2 – daniel_mt_br@hotmail.com;

Grupo de Trabalho (GT): GT12. Impactos socioambientais das novas tecnologias no agronegócio

Resumo

Este estudo analisa as disparidades regionais na mecanização agrícola no Brasil, destacando fatores como produtividade, acesso a crédito, spillovers espaciais e custos de ajuste. Utilizando dados do Censo Agropecuário do IBGE (2006 e 2017) em 510 regiões imediatas, o modelo incorpora variáveis como terra (T), trabalho (L), produção (P) e financiamento (F), representando a intensidade tecnológica intertemporal por $A(t)$. Métodos de econometria espacial corrigem vieses tradicionais, capturando efeitos de vizinhança e dependência espacial nos erros, enquanto o modelo SDEM aborda interações entre variáveis e spillovers. A Lei de Kaldor-Verdoorn sustenta a relação entre mecanização e ganhos de produtividade, confirmando que a substituição de trabalho manual por tecnologia impulsiona eficiência ao gerar economias de escala. No entanto, gera disparidades marcantes: o Centro-Sul, com maior infraestrutura e crédito, lidera a adoção, enquanto o Norte-Nordeste enfrenta limitações. A defasagem histórica revela influência regional acumulada, destacando spillovers de conhecimento. Para reduzir assimetrias, propõem-se estratégias dualísticas: (i) mitigar o desconto intertemporal com financiamento de longo prazo e subsídios iniciais, e (ii) fortalecer redes colaborativas para ampliar spillovers, como parcerias interregionais.

Palavras-chave: Spillover; Crédito; Tecnologia; Agronegócio; Terra.

Abstract

This study analyzes regional disparities in agricultural mechanization in Brazil, highlighting factors such as productivity, access to credit, spatial spillovers and adjustment costs. Using data from the IBGE Agricultural Census (2006 and 2017) in 510 immediate regions, the model incorporates variables such as land (T), labor (L), production (P) and financing (F), representing intertemporal technological intensity by $A(t)$. Spatial econometric methods correct for traditional biases, capturing neighborhood effects and spatial dependence in errors, while the SDEM model addresses interactions between variables and spillovers. The Kaldor-Verdoorn Law supports the relationship between mechanization and productivity gains, confirming that replacing manual labour with technology boosts efficiency by generating economies of scale. However, it generates marked disparities: the Center-South, with greater infrastructure and credit, leads adoption, while the North-Northeast faces limitations. The historical gap reveals accumulated regional influence, highlighting knowledge spillovers. To reduce asymmetries, dual strategies are proposed: (i) mitigate the intertemporal discount with long-term financing and initial subsidies, and (ii) strengthen collaborative networks to increase spillovers, such as interregional partnerships.

Key words: Spillover; Credit; Technology; Agribusiness; Land.

1. Introdução

Nas últimas quatro décadas, a produção agropecuária tem desempenhado um papel central no crescimento e desenvolvimento regional do Brasil. A interação espacial e temporal entre as atividades agrícolas resultou em mudanças estruturais significativas, promovendo a modernização dos sistemas produtivos e a intensificação tecnológica. Particularmente nas regiões de fronteira agrícola, esse processo impulsionou a reorganização do espaço rural, alterando a dinâmica da alocação de recursos e a estrutura produtiva local. Essa reorganização

não ocorreu de maneira homogênea, pois fatores como a disponibilidade de crédito, o acesso à infraestrutura e as condições climáticas e geográficas moldaram trajetórias distintas de desenvolvimento regional (DIAS et al., 2021; LI et al., 2022).

A mecanização agrícola, entendida como a adoção de tecnologias intensivas em capital, constitui um dos principais vetores desse processo de transformação estrutural, influenciando diretamente a produtividade do trabalho e a alocação de fatores de produção (CAUNEDO & KALA, 2021). A literatura sobre desenvolvimento agrícola destaca que o uso de máquinas e implementos modernos não apenas substitui a mão de obra em atividades repetitivas e extenuantes, mas também padroniza processos produtivos e permite o melhor aproveitamento de insumos e do solo. Essa transição, no entanto, não ocorre de maneira uniforme entre regiões, pois depende de fatores institucionais, estruturais e econômicos, incluindo a disponibilidade de crédito e o nível de capitalização dos produtores (FOSTER & ROSENZWEIG, 1995, 2010).

A adoção de tecnologias agrícolas frequentemente segue um padrão de difusão espacial, no qual produtores tomam decisões com base na observação e no aprendizado advindo da experiência de seus pares. Esse efeito, conhecido como *spillover* tecnológico, ocorre quando a adoção de maquinário por um grupo de produtores influencia a decisão de outros, reduzindo incertezas sobre a rentabilidade dos investimentos e ampliando o acesso a conhecimento técnico (BLACKMAN, 2010). Entretanto, esse processo pode ser limitado por assimetrias de informação, barreiras institucionais e restrições de financiamento, o que resulta em uma adoção desigual entre regiões e classes de produtores (SOBREIRA, 2024; GARCIA & KASSOUF, 2016).

A literatura econômica enfatiza que o mercado de crédito exerce papel crucial na modernização agrícola, pois possibilita o financiamento da aquisição de bens de capital e a expansão da capacidade produtiva. No entanto, em países em desenvolvimento, como o Brasil, credores frequentemente demonstram relutância em financiar mudanças tecnológicas devido ao alto risco de inadimplência e à assimetria de informação quanto à solvência dos tomadores (BLACKMAN, 2010). Esse fator contribui para uma dualidade tecnológica, onde produtores com maior acesso a crédito e garantias patrimoniais modernizam-se mais rapidamente, enquanto agricultores de menor porte enfrentam dificuldades na adoção de novas tecnologias, perpetuando desigualdades regionais na produtividade agrícola (DIAS et al., 2021; TANURE et al., 2024).

O impacto da mecanização sobre a produtividade do trabalho no setor agrícola brasileiro pode ser analisado à luz da Lei de Kaldor-Verdoorn, que postula uma relação positiva entre o crescimento da produção e os ganhos de produtividade. Embora formulada originalmente para o setor industrial, diversos estudos indicam que essa relação também se aplica ao setor agrícola, sugerindo que a mecanização pode gerar economias de escala e ganhos cumulativos de eficiência (ALMEIDA, 2009; SOUZA et al., 2024; GUIMARÃES, 2002). Entretanto, a heterogeneidade espacial da agricultura brasileira impõe desafios à generalização desse fenômeno, uma vez que fatores como a disponibilidade de capital humano, a qualidade da terra e a variabilidade climática afetam a produtividade de forma desigual (HAYAMI & RUTTAN, 1970).

Diante do exposto, este estudo tem como objetivo investigar as disparidades regionais na mecanização agrícola no Brasil, analisando os fatores determinantes que impulsionam ou restringem esse processo em diferentes localidades. Pretende-se identificar os elementos estruturais que condicionam a adoção de tecnologia, incluindo a disponibilidade de recursos naturais, o acesso a financiamento e o nível de capital humano. Além disso, examina-se a relação entre mecanização e produtividade do trabalho agrícola, fundamentando-se na Lei de Kaldor-Verdoorn para compreender os efeitos da modernização sobre a eficiência produtiva.

Por fim, busca-se avaliar como as diferenças regionais na alocação de recursos impactam os níveis de produção e a eficiência agrícola no país.

2. Estrutura geral do modelo

A adoção de tecnologia é modelada como um processo intertemporal influenciado pela produtividade, pelo acesso ao crédito, pelos spillovers e pelos custos de ajuste, fundamentando-se na estrutura teórica de David (1986) sobre difusão tecnológica e competitividade. O modelo incorpora as contribuições de Freeman (1994) acerca dos determinantes econômicos da mudança técnica, de Dodgson (2018) sobre colaboração tecnológica e inovação, e de Anacka e Lechman (2023) quanto aos efeitos de rede na disseminação de novas tecnologias. Além disso, considera o impacto dos incentivos analisados por Abbuzzese, Infante e Smirnova (2024) na difusão de inovações. O problema de maximização considerado neste modelo é formulado da seguinte maneira:

$$\max_{A(t)} \int_0^{\infty} e^{-\rho t} [\Delta B(A(t), L(t)) - \tilde{C}(A(t), L(t), S(t)) + F(t)] dt,$$

onde cada termo e variável representa:

- $A(t)$: representa o nível ou a taxa de adoção da nova tecnologia no tempo (t). Essa variável capta a intensidade com que os agentes implementam a inovação tecnológica ao longo do tempo, incluindo a mecanização como um dos principais vetores desse processo.
- $L(t)$: denota a extensão ou o tamanho da terra utilizada na produção. O fator terra é crucial, pois propriedades com áreas maiores podem explorar melhor as economias de escala, influenciando diretamente os lucros.
- $S(t)$: corresponde ao efeito de spillover tecnológico, ou seja, a influência que a adoção da tecnologia por outros agentes ou regiões exerce sobre o processo de transição tecnológica do agente em análise.
- $\Delta B(A(t), L(t))$: representa o benefício líquido adicional proporcionado pela nova tecnologia em comparação com a tecnologia tradicional, levando em conta tanto o nível de adoção ($A(t)$) quanto o tamanho da terra ($L(t)$).
- $\tilde{C}(A(t), L(t), S(t))$: é o custo de ajuste para a transição tecnológica, o qual é modificado pelo efeito dos spillovers ($S(t)$). A presença de spillovers tende a reduzir esses custos, pois facilita a disseminação de conhecimento e práticas mais eficientes.
- $F(t)$: captura o impacto positivo do acesso ao crédito.
- ρ : é a taxa de desconto intertemporal, refletindo a preferência dos agentes por benefícios presentes em relação aos futuros.

3. Componentes do Modelo

3.1 Custo de Ajuste com Spillover

Os custos de ajuste, sem considerar os efeitos dos spillovers, são modelados por:

$$C(A(t), L(t)) = \phi A(t)^{\theta} L(t)^{\kappa} \quad (1)$$

onde:

- $\phi > 0$, é um parâmetro de escala;
- $\theta > 1$, indica que os custos de ajuste aumentam de forma convexa com o nível de adoção $A(t)$. Isto é, quanto maior o grau de adoção — o que pode refletir uma

mecanização mais intensiva e tecnologicamente avançada —, maiores serão os custos, aumentando de maneira mais que proporcional;

- κ , representa o ganho de escala proporcionado pelo tamanho da terra $L(t)$ e assume valores tais que ($0 < \kappa \leq 1$). A condição $\kappa > 0$ garante que um aumento na área utilizada reduza os custos de ajuste, evidenciando economias de escala. Ao mesmo tempo, a restrição $\kappa \leq 1$ assegura que essa redução seja proporcional e moderada, evitando efeitos excessivamente fortes que poderiam levar a reduções de custos irreais.

Para incorporar o efeito dos spillovers tecnológicos, definimos o custo ajustado como:

$$\tilde{C}(A(t), L(t), S(t)) = \phi A(t)^\theta L(t)^\kappa e^{-\eta S(t)} \quad (2)$$

onde:

- $S(t)$ representa o spillover tecnológico, definido por:

$$S(t) = \sum_{j \neq i} w_{ij} A_j(t) \quad (3)$$

o qual capta a influência da adoção tecnológica por outros agentes ou regiões.

- $\eta > 0$, é o parâmetro que mede a intensidade do efeito redutor dos spillovers sobre os custos de ajuste.

3.2 Papel do Crédito

O crédito desempenha um papel fundamental ao facilitar a adoção da nova tecnologia. No modelo, o impacto do crédito é expresso por:

$$F(A(t)) = \delta V(t) \quad (4)$$

onde:

- $V(t)$ é o volume de crédito disponível no tempo t ;
- $\delta > 0$ representa a elasticidade da adoção em relação ao crédito, ou seja, a sensibilidade da decisão de adoção às variações no acesso ao crédito.

4. Condição para Adoção da Nova Tecnologia

Considerando a formulação intertemporal, o problema de maximização é reescrito substituindo o benefício líquido adicional pelo lucro diferencial, o custo de ajuste pela função de custo ajustada e o financiamento pelo efeito do acesso ao crédito. Assim, temos:

$$J[A(\cdot)] = \int_0^\infty e^{-\rho t} [\pi_{\text{new}}(A(t), L(t)) - \pi_{\text{old}}(L(t)) - \phi A(t)^\theta L(t)^\kappa e^{-\eta S(t)} + \delta V(t)] dt \quad (5)$$

onde $A(t)$ representa a taxa de adoção, $L(t)$ a área de terra (que, com ganho de escala, reduz os custos unitários para $0 < \kappa \leq 1$), e $S(t) = \sum_{j \neq i} w_{ij} A_j(t)$ capta os spillovers tecnológicos. Aqui, $\theta > 1$ indica custos de ajuste convexos, π_{new} e π_{old} denotam os lucros da nova e da antiga tecnologia, respectivamente, e $\delta V(t)$ reflete o efeito do acesso ao crédito. O investidor adotará a nova tecnologia se o valor presente líquido, dado por essa expressão, for positivo. O investidor adotará a nova tecnologia ao longo do tempo se os lucros adicionais, ajustados pelo custo de transição (que diminui com maiores spillovers e com a exploração de economias de

escala proporcionadas por uma maior área $L(t)$, somados aos benefícios advindos do acesso ao crédito, superarem os custos envolvidos na adoção.

4.1 Aplicação do cálculo de variações

Com a equação (5) não depende de derivadas temporais de $A(t)$ (ou seja, não há termo envolvendo $A(t)$), o problema pode ser tratado utilizando uma forma simplificada do método de Euler para problemas de cálculo de variações. Assim, a condição de primeira ordem (F.O.C) para a otimização é obtida impondo

$$\frac{\partial}{\partial A(t)} \{ \pi_{new}(A(t), L(t)) - \pi_{old}(L(t)) - \Phi A(t)^\theta L(t)^k e^{-\eta S(t)} + \delta F(t) \} = 0 \quad (6)$$

Observando que $\pi_{old}(L(t))$ e $\delta V(t)$ não depende de $A(t)$, a derivada parcial se concentra nos termos $\pi_{new}(A(t), L(t))$ e $\Phi A(t)^\theta L(t)^k e^{-\eta S(t)}$. Portanto, temos

$$\frac{\partial \pi_{new}}{\partial A(t)} (A(t), L(t)) - \theta \Phi A(t)^{\theta-1} L(t)^k e^{-\eta S(t)} = 0 \quad (7)$$

A equação (7) impõe o equilíbrio ótimo entre os benefícios marginais e os custos marginais decorrentes da adoção incremental da nova tecnologia. Em termos econômicos, $\frac{\partial \pi_{new}}{\partial A(t)} (A(t), L(t))$ mensura o acréscimo no lucro resultante do incremento na taxa de adoção $A(t)$, considerando, inclusive, os efeitos de escala de produção, representado por $L(t)$.

O termo $\theta \Phi A(t)^{\theta-1} L(t)^k e^{-\eta S(t)}$ caracteriza o custo marginal associado a esse aumento. Especificamente, o expoente $\theta - 1$ em $A(t)$ é exatamente compensado pelo custo marginal em lucros decorrentes de um aumento infinitesimal em $A(t)$ é exatamente compensado pelo custo marginal desse aumento. Esse equilíbrio é fundamental para a determinação da trajetória ótima de adoção da nova tecnologia, integrando os efeitos diretos da inovação, as economias de escala e os benefícios advindos dos spillovers tecnológicos.

Os resultados teóricos do modelo indicam que a adoção de tecnologia, incluindo a mecanização agrícola, é um processo intertemporal impulsionado por fatores como acesso ao crédito, spillovers tecnológicos e economias de escala. Esses elementos serão analisados empiricamente nos próximos tópicos.

5. Conceituação empírica

5.1 Análise exploratória dos dados espaciais

A Análise Exploratória dos Dados Espaciais (AEDE) visa identificar e visualizar padrões espaciais, sendo fundamental a definição do critério de vizinhança, que determina a dependência espacial entre unidades de análise por meio da matriz de ponderação espacial W . Diferentes tipos de matrizes podem ser utilizadas, refletindo vizinhança geográfica ou socioeconômica, e sua escolha influencia diretamente a autocorrelação espacial. Este estudo adota o coeficiente de autocorrelação espacial I de Moran (7) como métrica para selecionar a matriz de ponderação mais apropriada, considerando aquela com maior valor absoluto estatisticamente significativo, garantindo maior precisão na análise espacial do uso de maquinário agrícola.

$$I_z = \frac{n}{S_0} \times \frac{\sum_i \sum_j w_{ij} z_i z_j}{\sum_{i=1}^n z_i^2} \quad (7)$$

em que n representa o número de observações; z aponta os valores padronizados da variável dependente; w_{ij} representam os pesos espaciais da matriz w de uma dada observação existente na linha i e coluna j ; e S_0 é o somatório de todos os pesos espaciais w_{ij} .

O teste de I de Moran verifica a autocorrelação espacial ao testar a hipótese nula de independência entre os valores da variável estuda e suas observações vizinhas. O Diagrama de Dispersão complementa essa análise ao usar valores normalizados para identificar padrões de dependência espacial, diferenciando entre autocorrelação positiva e negativa por meio de quadrantes que representam distintas associações espaciais, sendo estes altos ou baixos.

O Indicador Local de Associação Espacial (LISA) (8) avalia padrões locais de dependência espacial, conforme Anselin (1995). O método identificar clusters significativos para cada observação e garantir que a soma dos indicadores locais seja proporcional à autocorrelação espacial global, destacando cenários específicos de distribuição espacial.

$$I_i^{z_1 z_2} = z_{1i} W z_{2i} \quad (8)$$

O teste de significância para o coeficiente de autocorreção espacial I de Moran Local é dado por $-Wi/n - 1$, onde Wi é a soma dos elementos na linha da matriz W . Esse teste indica a presença ou ausência de autocorrelação espacial local na unidade locacional i , para um determinado nível de significância. Calcula-se o coeficiente I de Moran Local para cada unidade locacional, acompanhado de seus níveis de significância, identificando clusters de observações que atendem a esse critério. Combinando as informações do diagrama de dispersão com os clusters locais, é possível criar um mapa de clusters LISA.

5.2 Métodos econométricos espaciais

Modelos de econometria espacial são utilizados para tratar dependência e heterogeneidade espacial, incorporando a defasagem das variáveis nos termos de erro. O processo inicia com a estimação por MQO, seguida de testes para definir a matriz de ponderação W mais adequada, garantindo a correta captura da autocorrelação espacial. Após essa escolha, testes do tipo Multiplicador de Lagrange são aplicados para identificar o tipo predominante de autocorrelação, como o teste MLp para defasagem espacial na variável dependente e o teste MLγ para autocorrelação no erro, auxiliando na definição dos modelos SAR ou SEM.

No modelo SAR (3), um termo adicional Wy é incluído para capturar a influência da variável dependente y nas regiões vizinhas. Como Wy é endógeno, a dependência espacial gera um processo circular, onde a variável dependente influencia e é influenciada por observações vizinhas.

$$y = \rho Wy + X\beta + \varepsilon \quad (9)$$

Em que Wy é a defasagem espacial para a variável dependente y , ρ é o coeficiente autorregressivo espacial, X é a matriz de variáveis explicativas, β é o coeficiente de regressão e ε é o termo de erros aleatórios.

No modelo SEM (10), a dependência espacial ocorre no termo de erro, seguindo uma estrutura autorregressiva. Ele é adequado quando variáveis omitidas exibem autocorrelação espacial no erro, diferindo do SAR, onde a dependência afeta a variável dependente.

$$y = \alpha + X\beta + \lambda W\mu + \varepsilon \quad (10)$$

Em que o coeficiente λ é o parâmetro do erro autorregressivo espacial que acompanha a defasagem $W\mu$.

Anselin (1996) propôs um procedimento em etapas para especificação de modelos espaciais: estima-se primeiro o modelo por MQO, seguido dos testes ML ρ e ML γ . Se nenhum for significativo, mantém-se o modelo clássico. Se apenas um for significativo, estima-se SAR (ML ρ) ou SEM (ML γ). Caso ambos sejam significativos, utilizam-se versões robustas, escolhendo o modelo com maior significância.

O modelo SDEM (11) é particularmente adequado quando há spillovers, ou seja, efeitos exógenos que se propagam entre as unidades espaciais, afetando tanto as interações das variáveis explicativas quanto os erros. Sua especificação ocorre após testes do Multiplicador de Lagrange indicarem autocorrelação significativa nos erros em um modelo MQO com defasagens das variáveis explicativas.

$$y = \alpha + \theta WX + X\beta + \lambda Wu + \varepsilon \quad (11)$$

Em que o coeficiente θ é o parâmetro que considera as relações exógenas nas interações espaciais das variáveis explicativas WX, ou seja, suas defasagens. Enquanto o termo λ considera a interação espacial nos erros u .

Quando há simultânea autocorrelação espacial e heterocedasticidade desconhecida, Kelejian e Prucha (2010) propõem um estimador para corrigir a heterocedasticidade nos modelos espaciais, estendendo o método de Mínimos Quadrados em Dois Estágios Espaciais Generalizados (S2SLS) (12) para lidar com essa questão.

$$y = \rho W_1 y + X\beta + W_1 X_\tau + \xi \quad (12.1)$$

$$\xi = \lambda W_2 \xi + \varsigma \varsigma \text{ Normal}(0, \Omega) \quad (12.2)$$

$$\Omega = \text{diag}(\sigma_i^2) \quad (12.3)$$

Em que a variável dependente y é explicada pela sua defasagem espacial, por variáveis explicativas exógenas, pela defasagem espacial das variáveis explicativas exógenas, e por um termo de erro autocorrelacionado espacialmente com erros heterocedásticos. A matriz Ω é uma matriz diagonal composta pelos termos da variância que não são constantes e desconhecidas em sua especificação.

5.3 Especificações do modelo e dos dados

A pesquisa abrange uma área territorial que inclui as 510 regiões geográficas imediatas do Brasil, de acordo com a classificação do Instituto Brasileiro de Geografia e Estatística (IBGE). Os dados foram extraídos do Censo Agropecuário de 2017 e 2006, fornecido pelo IBGE. As variáveis usadas foram organizadas em uma tabela e associadas a um arquivo *shapefile* das regiões geográficas imediatas. Esse processo permitiu a preparação e estruturação adequadas dos dados para a análise espacial proposta no estudo.

Segundo a literatura, a mecanização agrícola (M), que é o principal objeto de estudo, é influenciada por várias variáveis, incluindo a contribuição da terra (T), do trabalho (L), da produção (P) e do financiamento (F). Essas variáveis ajudam a entender os fatores que determinam a adoção de maquinário agrícola em diferentes regiões e como essas variáveis interagem para determinar o grau de mecanização.

O modelo incorpora um conceito de defasagem espacial ($\omega_{(-10)}$), que se refere ao efeito histórico da mecanização agrícola nas regiões, isto é, como a mecanização de dez anos atrás pode influenciar a mecanização no presente. Essa defasagem permite analisar o “aprendizado” das regiões ao longo do tempo, observando como as práticas de mecanização em uma região podem afetar as vizinhas. A variável $\omega_{(-10)}$ busca quantificar essa interação espacial e temporal entre as regiões. Isso é importante porque em muitos casos, os processos de adoção de tecnologia, como a mecanização agrícola, não são independentes entre regiões. As decisões dos agricultores em uma região podem ser influenciadas pelas práticas de vizinhos no

passado, criando um efeito de convergência regional. Dessa forma, o modelo é formalizado da seguinte forma:

$$M = [T, L, P, F, \omega M_{-10}]$$

$$\omega_{(-10)} = [M_{(-10)} = [WM_{(-10)}]]$$

Visto isso, estabelece-se um modelo de regressão *cross-section* do tipo log-log (5), no qual a M é a variável dependente, usando o ano de 2017 como referência, enquanto os demais indicadores atuam como variáveis explicativas. Por sua vez, a variável instrumental busca identificar os valores previstos do quanto a defasagem espacial explicava a mecanização dez anos atrás (6). Esse modelo serve como base para a estimativa dos modelos de MQO e modelos espaciais, no qual se avaliam seus coeficientes, assim como a realização de testes estatísticos para verificar a significância e robustez das relações estabelecidas.

$$\ln(M) = \alpha + \beta_1 \ln(T) + \beta_2 \ln(L) + \beta_3 \ln(P) + \beta_4 \ln(F) + \beta_5 \omega_{(-10)} + \varepsilon \quad (7)$$

$$\omega_{-10} = [M_{(-10)} = \alpha + WM_{-10} + \varepsilon] \quad (8)$$

Enquanto isso, a Lei de Kaldor-Verdoorn se valia pela relação entre o trabalho e a produção, o que sugere que o aumento na produção de um setor leva a um aumento na demanda por trabalho. No contexto da mecanização agrícola, a Lei de Kaldor-Verdoorn pode ser usada para entender como o aumento da mecanização (e, portanto, da produção) pode afetar o emprego nas regiões. A mecanização tende a aumentar a produtividade, o que, segundo a Lei de Kaldor-Verdoorn, pode estar relacionado com o crescimento da produção e, em algumas circunstâncias, com o aumento de empregos no setor agrícola, embora isso dependa de como a tecnologia é adotada e adaptada em cada região. Sendo assim, busca-se avaliar esse comportamento da seguinte forma:

$$\ln(L) = \alpha + \beta \ln(P) + \varepsilon \quad (9)$$

Por fim, avaliam-se as diferenças regionais por meio de variáveis dummies para as regiões Norte-Nordeste (D_{NN}) e Centro-Sul (D_{CS}) em relação a sua variável explicativa (X) para a variável dependente (Y). Essas variáveis são usadas para entender como a localização geográfica de uma região influencia a relação entre as variáveis explicativas (T, L, P, F) e a mecanização (M). Por exemplo, pode-se investigar se a região Norte-Nordeste tem características distintas em relação à mecanização agrícola em comparação com o Centro-Sul. Essas diferenças ajudam a entender como as políticas agrícolas e os investimentos em mecanização podem ter efeitos distintos em diferentes partes do país. Dessa forma, sendo equacionado da seguinte maneira:

$$\ln(Y) = \alpha + \beta_1 D_{NN} \ln(X) + \beta_2 D_{CS} \ln(X) + \varepsilon \quad (10)$$

A análise descritiva (Tabela 1) dos dados revela grande heterogeneidade entre as variáveis avaliadas. A taxa de maquinário apresenta ampla variação (média de 0,595 e máximo de 5,185), enquanto as áreas de terra são igualmente dispersas, com uma média de 688.804 ha e um desvio padrão elevado. O trabalho humano tem uma média de 29.618 pessoas, mas com casos extremos de até 182.600. A produção, em milhares de reais, apresenta assimetria, com uma média de R\$ 506.372 mil e mediana superior (R\$ 906.591 mil), sugerindo concentrações em altos valores. Já o financiamento corresponde, em média, a 48,17% dos recursos, enquanto o passado defasado (variável histórica) mostra um comportamento estável com valores médios de 1,069. Esses resultados indicam disparidades significativas entre as observações, possivelmente influenciadas por diferenças regionais ou estruturais.

Tabela 1. Análise descritiva dos dados.

Estatística	Taxa de Maquinário	Terra (ha)	Trabalho (Pessoas)	Produção (mil R\$)	Financiamento (%)	Passado Defasado
Média	0.595	688804	29618	506372	48.17	1.069
Mediana	0.302	374514	22462	906591	47.34	0.756
Desvio Padrão	0.701	879311.8	23171.6	1181764	16.00	0.912
Mínimo	0.0009	10313	920	20051	6.10	0.004
Máximo	5.185	5567519	182600	12224955	85.57	3.923

Fonte: IBGE, 2017.

A Tabela 2 evidencia disparidades significativas no desenvolvimento agrícola entre as regiões Norte-Nordeste e Centro-Sul, refletindo diferenças estruturais, tecnológicas e econômicas. O Centro-Sul destaca-se pela alta mecanização (média de 0,967 na taxa de maquinário) e maior produtividade econômica, com média de R\$ 1.284.907 mil em produção, além de maior acesso a financiamento de 54,85%, características que indicam uma agricultura mais modernizada e eficiente. Por outro lado, o Norte-Nordeste depende mais de trabalho humano, com uma média de 38.829 trabalhadores, evidenciando menor nível de mecanização de 0,088 e uma agricultura mais tradicional. A região também apresenta maior desigualdade na distribuição do tamanho das propriedades (desvio padrão de 735.276,5 ha) e valores de produção muito inferiores de R\$ 391.662 mil. Ambas as regiões demonstram alta variabilidade interna nos indicadores, mas o Centro-Sul mantém vantagem em termos de produtividade, infraestrutura e modernização agrícola, enquanto o Norte-Nordeste permanece mais vulnerável, refletindo desigualdades históricas e tecnológicas no setor agrícola brasileiro.

Tabela 2. Análises descritivas regionais.

	Norte-Nordeste			Centro-Sul		
	Média	Mediana	Desvio Padrão	Média	Mediana	Desvio Padrão
Taxa de Maquinário	0.088	0.043	0.123	0.967	0.842	0.717
Terra (ha)	630126	375058	735276.5	731914	374514	970604.6
Trabalho (Pessoas)	38829	32143	28121.57	22851	19356	15618.97
Produção (mil R\$)	391662	211364	628183.2	1284907	951050	1340698
Financiamento (%)	39.07	39.34	12.923	54.85	55.67	14.723
Passado Defasado	0.291	0.228	0.212	1.640	1.595	0.800


Fonte: IBGE, 2017.

6. Resultados

A Figura 1 ilustra a distribuição espacial da Taxa de Maquinário no Brasil nos anos de 2006 (A) e 2017 (B), com os valores classificados em categorias representadas por uma escala de cores, variando do amarelo (menor densidade) ao azul-escuro (maior densidade). Em 2006, as maiores concentrações de maquinário estavam localizadas predominantemente nas regiões Sul e Sudeste. Em 2017, observa-se uma expansão dessas áreas de alta densidade para o Centro-Oeste, enquanto as regiões Norte e Nordeste permaneceram com baixos índices de mecanização. Os mapas indicam alterações nos padrões de mecanização agrícola ao longo do período analisado, refletindo desigualdades regionais e mudanças no avanço ou recuo da

mecanização em determinadas áreas. Destaca-se, por exemplo, o incremento da mecanização agrícola no norte do estado de Mato Grosso, contrastando com o retrocesso observado em partes da região Nordeste.

Figura 1. Box-map da Taxa de Maquinário de 2006 e 2017.




Fonte: IBGE (2006; 2017).

Nota: foram usadas quebras naturais de Jerks.

Com um índice de Moran igual a 0,751, os resultados indicam uma forte autocorrelação espacial positiva, sugerindo que áreas geograficamente próximas tendem a compartilhar características similares em relação à taxa de mecanização. Esse padrão reflete a tendência de agrupamento regional, em que áreas com alta mecanização estão concentradas próximas a outras igualmente mecanizadas, enquanto regiões de baixa mecanização se encontram rodeadas por áreas com características semelhantes. Os quadrantes representam padrões espaciais: Alto-Alto (áreas altamente mecanizadas próximas a outras similares), Baixo-Baixo (áreas de baixa mecanização circundadas por regiões similares), e os outliers Alto-Baixo e Baixo-Alto (discrepâncias locais). A linha vermelha reflete a tendência positiva entre a taxa de mecanização e sua defasagem espacial, reforçando a existência de clusters de mecanização e desigualdades regionais.


Figura 2. Quadrantes da Estatística I de Moran Global da Taxa de Maquinário de 2017.



Fonte: elaboração própria.

A Figura 3 destaca três grandes clusters significativos de mecanização agrícola no Brasil em 2017. O maior deles está localizado na região central do estado de Mato Grosso, reconhecido como o principal produtor de grãos do país, especialmente soja e milho, representando 31,2% de toda a produção nacional, conforme dados do IBGE. Na região Sul, destaca-se o estado do Rio Grande do Sul, com clusters localizados nas regiões da Campanha, Fronteira Oeste e Serra Gaúcha, sendo o estado reconhecido como o maior produtor de vinhos do país e o terceiro maior em produção de grãos. Adicionalmente, identifica-se um cluster abrangendo grande parte do Centro-Oeste paulista, estendendo-se às regiões do Triângulo Mineiro, no sul de Minas Gerais, e às áreas ao sul de Goiás, tradicionalmente reconhecidas pela produção de café e cana-de-açúcar. Na região central de Mato Grosso do Sul, destaca-se um cluster outlier Alto-Baixo, caracterizado por um alto nível de mecanização em comparação às áreas vizinhas, que apresentam uma mecanização mais baixa, devido à proximidade com o Pantanal, onde as atividades predominantes são voltadas para a pecuária. De forma similar, a região imediata de Cuiabá, localizada no Pantanal, ao sul de Mato Grosso, apresenta características de cluster Baixo-Baixo, refletindo a baixa mecanização associada ao bioma pantaneiro e às áreas vizinhas. Por fim, não foram identificados clusters significativos a 5% nas regiões Norte e Nordeste.

Figura 3. Cluster LISA da Taxa de Maquinário de 2017.



Fonte: elaboração própria.

Por sua vez, a mecanização agrícola é explicada por fatores determinísticos, como a disponibilidade de recursos financeiros, a produtividade agrícola e a substituição da mão de obra por tecnologias. O modelo OLS (Tabela 3.1) demonstrou que a contribuição da terra para a mecanização é quase nula e estatisticamente insignificante. Isso está relacionado ao fato de que o tipo de cultivo e o estágio de desenvolvimento agrícola da região têm um impacto mais determinante do que a área de terra disponível, o que resulta em diferenças regionais na taxa de mecanização. Os resultados ainda revelaram que a relação entre trabalho e produção exerce efeitos distintos sobre a produtividade agrícola. O aumento da utilização de mão de obra está negativamente relacionado com a mecanização, o que indica uma dependência de trabalho manual reduz a adoção de tecnologias. Por outro lado, a produção apresentou uma relação positiva e significativa com a mecanização, sugerindo que regiões mais produtivas buscam aumentar ainda mais sua eficiência por meio do uso de maquinário. Dessa forma, evidenciando que a mecanização ajuda a explicar o aumento da produtividade agrícola, pois, o equilíbrio entre trabalho e produção reflete escolhas de alocação de recursos que impactam diretamente o nível de eficiência no campo.

Tabela 3. Resultados das estimações.

Coeficientes	OLS (1)	SAR (2)	SEM (3)	SDEM (4)
α	-7.091***	-4.362***	-6.206***	-7.388***
$\ln(T)$	0.016	-0.012	0.122**	0.137**
$\ln(L)$	-1.094***	-0.659***	-0.988***	-0.867***
$\ln(P)$	1.072***	0.688***	0.867***	0.763***
$\ln(F)$	0.485***	0.345***	0.319***	0.314***
$\omega M_{(-10)}$	0.410***	0.050	0.418***	-0.426***
ρ		0.508***		
λ			0.725***	0.686***
$\theta \ln(T)$				-0.215*
$\theta \ln(L)$				-0.265*
$\theta \ln(P)$				0.506***
$\theta \ln(F)$				0.012
$\theta \omega M_{(-10)}$				0.763***
R^2 ajustado	0.886	0.920	0.926	0.929
Breusch-Pagan	49.34***	39.20***	17.60**	39.78***
AIC	930.43	750.72	763.17	703.39
BIC	960.07	784.59	797.04	758.43
I de Moran	0.373***			
LM ρ	185.57***			
R-LM ρ	40.24***			
LM λ	186.06***			
R-LM λ	40.72***			

Fonte: elaboração própria.

Nota: * significativo em <5%; ** significativo em <1%; *** significativo em <0,1%.

Além disso, os resultados indicam que o acesso ao crédito está associado com a interação entre trabalho, produção e mecanização agrícola. O resultado positivo e significativo para financiamento mostra que regiões com maior acesso estão mais aptas a investir em maquinário, o que reduz a dependência de mão de obra e aumenta a eficiência produtiva. Portanto, o crédito facilita a superação das barreiras financeiras iniciais para a adoção de tecnologias, especialmente em áreas de alta produção, onde o retorno sobre o investimento em mecanização é mais evidente. Dessa forma, o acesso ao crédito não apenas incentiva a substituição do trabalho manual por máquinas, mas também potencializa os ganhos de produtividade nas regiões agrícolas, que, por sua vez, podem gerar economias de escala.

Por fim, o efeito de convergência regional, evidenciado pela defasagem espacial do passado positiva e significativa, reflete o aprendizado acumulado ao longo do tempo nas regiões agrícolas. Esse efeito demonstra que a mecanização de uma região é influenciada pelo histórico de mecanização, tanto local quanto de regiões vizinhas, indicando um processo de difusão tecnológica. À medida que as práticas de mecanização se propagam, as regiões tendem a adotar tecnologias semelhantes, promovendo uma convergência tecnológica. Esse aprendizado regional, acumulado ao longo do tempo, demonstra que a adoção de maquinário

agrícola é moldada por fatores históricos de contextos sociais e ambientais, demonstrando o compartilhamento de conhecimento e inovação entre os agricultores.

No modelo SAR (Tabela 3.2), ao contrário do modelo OLS, a variável de defasagem espacial do passado perde significância estatística, indicando que as interações espaciais passadas não são mais determinantes. Em contrapartida, as demais variáveis mantêm seu comportamento, mas com efeitos reduzidos. A variável de defasagem espacial recente (ρ) se destaca, sugerindo que a interação espacial atual tem maior influência sobre a mecanização do que a interação passada. Isso ocorre porque, ao considerar os efeitos espaciais atuais, a convergência regional se torna mais relevante. Assim, o comportamento das regiões se ajusta às práticas de mecanização mais recentes, refletindo um aprendizado e adaptação contínuos, em vez de depender de influências históricas.

O modelo SEM (Tabela 2.3) se diferencia dos modelos anteriores ao incorporar os efeitos espaciais diretamente no termo de erro representado pelo λ , que foi significativo, evidenciando a importância das interações residuais entre regiões. Enquanto o SAR capta interações espaciais diretamente no modelo, o SEM ajusta melhor os impactos espaciais não observáveis, revelando que influências regionais residuais afetam a mecanização agrícola. O comportamento das variáveis é reiterado, mas com ajustes pelos fatores espaciais residuais. No entanto, a variável terra tornou-se significativa e positiva, indicando que, ao considerar os efeitos espaciais no termo de erro, a influência da terra sobre a mecanização agrícola é melhor capturada. Portanto, sugerindo que a disponibilidade de terra, mesmo com diferenças regionais, exerce algum impacto sobre a adoção de tecnologias quando os efeitos espaciais são tratados no erro.

No modelo SDEM (Tabela 3.4), a inclusão das defasagens espaciais (θ) nas variáveis explicativas revelou novas dinâmicas em relação à mecanização agrícola. A terra manteve impacto positivo e significativo, com aumento em sua magnitude, e um efeito negativo das regiões vizinhas. O trabalho tem um efeito positivo direto, o que significa que mais trabalho disponível contribui diretamente para a mecanização agrícola, enquanto as regiões vizinhas têm um efeito negativo, sugerindo que a disponibilidade de trabalho em áreas próximas pode reduzir o efeito positivo do trabalho local. A produção teve impacto direto reduzido, mas sua defasagem foi significativa, indicando que a produção em regiões vizinhas estimula a mecanização local. O financiamento manteve um efeito positivo local significativo, mas sem influência das regiões vizinhas. Por fim, a mecanização realizada no passado tem um efeito negativo direto na necessidade de mais mecanização local atual. Porém, a forte influência positiva das vizinhanças sugere que a mecanização em áreas próximas no passado estimula a adoção de maquinário na região atualmente, criando um efeito de difusão ou imitação entre as regiões. Comparado aos outros modelos, o SDEM destaca que as interações espaciais não apenas residuais, mas também entre as variáveis explicativas, são determinantes para compreender a difusão da mecanização.

Os resultados dos modelos revelam que o modelo SDEM se destaca como o mais eficiente entre os quatro analisados, apresentando o maior R^2 ajustado de 0,929, o que sugere que ele consegue explicar uma alta proporção da variabilidade dos dados, com um excelente ajuste. Além disso, o modelo apresenta os menores valores de AIC de 703.39 e BIC de 758.43, indicadores de que, mesmo considerando sua complexidade e o número de parâmetros incluídos, o modelo mantém uma boa capacidade explicativa sem sobrecarregar com variáveis desnecessárias. O teste de Breusch-Pagan, que verifica a presença de heterocedasticidade, mostra que todos os modelos possuem significância, ou seja, há variação não constante nos erros. No entanto, o modelo SDEM se mantém como o mais robusto em termos de desempenho geral, destacando-se como a melhor escolha para explicar os dados analisados, considerando tanto a qualidade do ajuste quanto a penalização por complexidade.

Além disso, o Teste de Moran de 0.373 reforça a autocorrelação espacial no modelo, indicando que os valores da variável estão agrupados de forma positiva, sendo indicado o uso de modelos espaciais. Já os testes de Lagrange avaliam diferentes formas de dependência espacial. O LM_p de 185.57 testa se existe autocorrelação espacial na variável dependente, enquanto o LM_λ de 186.06 verifica a presença de autocorrelação espacial nos resíduos. Ambos os testes são robustos, com alta significância, sugerindo forte evidência de autocorrelação espacial. No entanto, o valor mais alto e significativo no teste robusto foi de LM_λ , indicando a importância de considerar a autocorrelação espacial nos erros do modelo. Sendo assim, os modelos SEM e SDEM são os mais adequados para explicar a dependência espacial.

Os efeitos diretos, indiretos (spillover) e totais no modelo SDEM destacam dinâmicas espaciais da mecanização agrícola, conforme a Tabela 4. A variável terra apresenta um efeito direto positivo, indicando que mais terra incentiva a mecanização local, mas o spillover negativo aponta que mais terra em regiões vizinhas reduz esse impacto. O efeito total ligeiramente negativo evidencia que, embora relevante localmente, a terra tem sua influência geral limitada pelas interações espaciais.

Tabela 4. Efeitos diretos, indiretos (Spillover) e totais sobre a Taxa de Maquinário.

Variável	Direto	Indireto	Total
$\ln(T)$	0.154***	-0.338**	-0.183
$\ln(L)$	-0.884***	-0.227	-1.111***
$\ln(P)$	0.765***	0.630***	1.396***
$\ln(F)$	0.291***	0.125	0.417
$\omega M_{(-10)}$	-0.334**	0.600**	0.266

Fonte: elaboração própria.

Nota: * significativa em <5%; ** significativa em <1%; *** significativa em <0,1%.

A variável trabalho apresenta um efeito total negativo, com impacto direto e indireto, indicando que maior disponibilidade de mão de obra, reduz a mecanização agrícola, e sendo significativa apenas localmente. A variável produção tem forte impacto total positivo, com efeito direto e de spillover, indicando que maior produção local e regional incentiva significativamente a mecanização agrícola. A variável financiamento tem efeito direto positivo, mostrando que o crédito incentiva a mecanização local, mas sem impacto significativo das regiões vizinhas. Por fim, a mecanização no passado tem um impacto local negativo, mas um spillover positivo, sugerindo um processo de difusão tecnológica entre regiões, culminando em um efeito total positivo.

Entretanto, todos os modelos anteriores apresentaram indícios de heterocedasticidade, cuja origem é desconhecida, mas possivelmente relacionada à heterogeneidade inerente aos dados espaciais, que refletem características distintas entre as regiões. Essa heterocedasticidade pode influenciar negativamente a precisão das estimativas, resultando em coeficientes viesados e ineficientes. Para lidar com essa questão, foi utilizado o modelo S2SLS robusto com correção heterocedástica (Tabela 5), que incorpora uma matriz de covariância dos erros, permitindo ajustar adequadamente as variações não constantes. Essa abordagem garante a obtenção de coeficientes consistentes e eficientes, mesmo na presença de heterogeneidade espacial, contribuindo para uma análise mais robusta e confiável das relações entre as variáveis explicativas e a mecanização agrícola.

Tabela 5. Resultados por estimação S2SLS com correção heterocedástica.

Variáveis	Coefficiente
α	-2.839**
$\ln(T)$	0.161**
$\ln(L)$	-0.821***
$\ln(P)$	0.735***
$\ln(F)$	0.207**
$\omega M_{(-10)}$	-0.023
$\theta \ln(T)$	-0.272***
$\theta \ln(L)$	0.316**
$\theta \ln(P)$	-0.098
$\theta \ln(F)$	-0.099
$\theta \omega M_{(-10)}$	0.110*
ρ	0.540***
R^2	0.931

Fonte: elaboração própria.

Nota: * significativo em <5%; ** significativo em <1%; *** significativo em <0,1%.

O coeficiente de terra indica que um aumento da disponibilidade de terra eleva a mecanização agrícola local em 16,1%, mostrando um impacto positivo e significativo. Já a defasagem espacial da terra revela que o aumento da terra em regiões vizinhas reduz a mecanização local em -27,2%, possivelmente devido ao deslocamento de investimentos para essas áreas. Por sua vez, o maior uso de mão de obra reduz a mecanização local em -82,1%, enquanto sua defasagem espacial mostra que mais mão de obra em regiões vizinhas incentiva a mecanização local em 31,1%, sugerindo uma relação compensatória regional. O aumento da mecanização aumenta a produção em 73,5%, enquanto nas regiões vizinhas é estatisticamente insignificante, sugerindo que o impacto da produção nas áreas vizinhas é irrelevante. O financiamento teve um efeito direto significativo de 20,7% na mecanização, enquanto a defasagem espacial negativa e insignificante sugere que o efeito indireto nas áreas vizinhas é irrelevante. O coeficiente de mecanização agrícola no passado indica um efeito direto insignificante, enquanto sua defasagem espacial sugere um efeito indireto significativo, com impacto positivo de 11% nas áreas vizinhas, refletindo a propagação espacial dos efeitos ao longo do tempo. Por fim, o coeficiente de autocorrelação espacial ρ indica uma correlação positiva significativa entre os níveis de mecanização em áreas próximas. De modo geral, o R^2 elevado indica que o modelo é capaz de explicar uma grande parte da variabilidade dos dados, proporcionando um ajuste preciso.

Os resultados da Tabela 6 mostram que os modelos espaciais são mais adequados do que o modelo OLS para analisar a relação entre trabalho e produção segundo a Lei Kaldor-Verdoorn. O modelo SEM, em particular, apresenta o menor AIC e BIC, sugerindo o melhor ajuste. Além disso, a elasticidade da produção em relação ao trabalho de 63,1% é maior no modelo SEM, indicando uma relação mais forte quando se considera os efeitos espaciais nos erros. O coeficiente λ no SEM e o ρ no SAR confirmam a relevância da autocorrelação espacial, ou seja, a produção em uma região é influenciada pelas regiões vizinhas. Enquanto o OLS apresenta problemas de heterocedasticidade e autocorrelação espacial nos resíduos, esses problemas são corrigidos nos modelos SAR e SEM. Os testes de multiplicadores de Lagrange indicam que o modelo SEM é o mais apropriado para capturar as dependências espaciais,

evidenciado pelos valores mais elevados e pela significância estatística observada nos testes relacionados aos erros espaciais. Sendo assim, os resultados confirmam a hipótese da Lei de Kaldor-Verdoorn para a agricultura brasileira, evidenciando economias de escala. O incremento na produção agrícola resulta em uma maior demanda por força de trabalho, impulsionando a produtividade pela adoção de tecnologias e maquinário. Esse processo requer a contratação de trabalhadores especializados para acompanhar a expansão da produção.

Tabela 6. Resultados para a Lei Kaldor-Verdoorn da relação entre Trabalho e Produção.

Variável	OLS (1)	SAR (2)	SEM (3)
α	7.560***	0.905*	1.563***
$\ln(P)$	0.189***	0.225***	0.631***
ρ		0.609***	
λ			0.898***
R^2 ajustado	0.092	0,101	0,105
Breusch-Pagan	22.4***	2.49	5.20*
AIC	1105.28	955.46	603.75
BIC	1117.98	972.39	620.69
I de Moran	0.503***		
LMLAG	204.89***		
R-LMLAG	147.97***		
LMERRO	337.49***		
R-LMERRO	280.57**		

Fonte: elaboração própria.

Nota: * significante em <5%; ** significante em <1%; *** significante em <0,1%.

Entretanto, a Tabela 7 mostra a existência de diferenças regionais entre Norte-Nordeste e Centro-Sul sobre a mecanização agrícola, em que Norte-Nordeste apresenta uma desvantagem estrutural, enquanto o Centro-Sul uma vantagem significativa. No Norte-Nordeste, o impacto do trabalho é negativo e significativo, indicando uso ineficiente devido à baixa mecanização. No Centro-Sul, o impacto positivo, mas não significativo, podendo ser ocasionada por efeitos espaciais, como proximidade entre propriedades, indicando possíveis economias de escala regionais, onde o trabalho é complementado por maior mecanização. A produção tem impacto positivo e significativo em ambas as regiões, sendo mais forte no Centro-Sul do que no Norte-Nordeste, refletindo maior eficiência estrutural e acesso a recursos no Centro-Sul. No Norte-Nordeste, o impacto da terra é positivo e significativo, mas menor que no Centro-Sul, indicando menor eficácia no uso do recurso. Para o financiamento, o impacto no Norte-Nordeste não é significativo, enquanto no Centro-Sul é positivo e significativo, refletindo maior acesso e eficiência no uso de crédito para mecanização agrícola. A defasagem histórica do maquinário agrícola apresenta impactos opostos nas regiões, destacando o papel das condições passadas na mecanização atual. No Norte-Nordeste, o impacto é negativo e significativo, indicando que a defasagem histórica contribuiu para limitar o desenvolvimento agrícola, possivelmente devido à falta de investimentos e modernização ao longo do tempo. Já no Centro-Sul, o impacto é positivo e significativo, sugerindo que o acúmulo histórico de maquinário criou uma base sólida que

continua favorecendo a mecanização, refletindo um efeito cumulativo positivo associado ao maior desenvolvimento estrutural da região no passado.

Tabela 7. Resultados das diferenças regionais Norte-Nordeste e Centro-sul.

Variável	Região	Impacto	Explicação (R^2)	Teste F
Região	Norte-Nordeste	-2.796***	0.607	786.4***
	Centro-sul	2.796***		
T	Norte-Nordeste	0.216***	0.627	426.2***
	Centro-sul	0.427***		
L	Norte-Nordeste	-0.257***	0.611	399.7***
	Centro-sul	0.013		
P	Norte-Nordeste	0.574***	0.745	742.5***
	Centro-sul	0.723***		
F	Norte-Nordeste	-0.146	0.587	361.6***
	Centro-sul	0.558***		
$\omega M_{(-10)}$	Norte-Nordeste	-0.754***	0.654	480.2***
	Centro-sul	1.325***		

Fonte: elaboração própria.

Nota: * significante em <5%; ** significante em <1%; *** significante em <0,1%.

Esses fatores determinam os diferentes níveis de ganhos de produtividade entre as duas regiões. Essa diferença é observada na Tabela 8, que apresenta os coeficientes que medem os impactos regionais da taxa de mecanização agrícola sobre a produtividade nas regiões Norte-Nordeste e Centro-Sul. O coeficiente relacionado à mecanização no Norte-Nordeste é 82,749, enquanto no Centro-Sul é 50,963, ambos estatisticamente significativos. Esse resultado indica que, embora a mecanização contribua positivamente para a produtividade em ambas as regiões, o impacto é mais acentuado no Norte-Nordeste. Isso pode ser explicado pelo estágio inicial de mecanização na região, onde os ganhos marginais derivados de novas tecnologias tendem a ser mais elevados devido à baixa adoção inicial e maior potencial de modernização. Em contrapartida, no Centro-Sul, que já apresenta um nível avançado de mecanização, os ganhos incrementais podem ser menores, refletindo um efeito de saturação tecnológica.

Tabela 8. Resultado das diferenças regionais da Taxa de Mecanização sobre a Produtividade entre Norte-Nordeste e Centro-Sul.

Variável	Coeficiente
α	7.356***
$M_{\text{Norte-Nordeste}}$	82.749***
$M_{\text{Centro-Sul}}$	50.963***
R^2	0.5934
F	370**

Fonte: elaboração própria.

Nota: * significante em <5%; ** significante em <1%; *** significante em <0,1%.

1. Conclusão

A investigação das assimetrias regionais na adoção de tecnologias agrícolas no Brasil revela a intrincada interação entre fatores econômicos, espaciais e temporais que moldam a difusão da mecanização e seus impactos na produtividade. Além dos elementos já destacados, como acesso a crédito e infraestrutura, é fundamental incorporar a dimensão do desconto intertemporal na análise, o qual influencia as decisões de investimento em capital tecnológico. Agricultores enfrentam um trade-off entre custos imediatos (aquisição de maquinário) e benefícios futuros (ganhos de eficiência), sendo a taxa de desconto intertemporal um determinante crítico. Regiões com menor acesso a financiamento ou maior aversão ao risco tendem a desvalorizar os retornos futuros, postergando investimentos em modernização, o que perpetua desigualdades produtivas.

Os efeitos spillover espaciais, corroborados pelos coeficientes positivos da defasagem espacial da mecanização, demonstram que a disseminação tecnológica transcende fatores individuais, operando por meio de externalidades de aprendizado e imitação entre regiões geograficamente próximas. Esse fenômeno sugere que a adoção de tecnologias em uma localidade reduz os custos de ajuste e informação para regiões vizinhas, criando um ciclo virtuoso de difusão. A disponibilidade de terra, ao atuar como um fator que reduz custos de transição, amplifica esses spillovers, pois áreas com maior extensão territorial apresentam viabilidade econômica para internalizar os benefícios de escala da mecanização, servindo como polos catalisadores de inovação.

A relação entre mecanização e produtividade, alinhada à Lei de Kaldor-Verdoorn, é reforçada empiricamente, evidenciando que a substituição de trabalho manual por capital tecnológico gera ganhos dinâmicos de eficiência. Contudo, esses ganhos são modulados pelo horizonte temporal das decisões dos produtores: em regiões com elevado desconto intertemporal (onde o futuro é subvalorizado), mesmos benefícios potenciais expressivos podem ser insuficientes para motivar investimentos imediatos. Políticas de crédito subsidiado ou garantias de longo prazo emergem como instrumentos essenciais para reduzir a taxa de desconto, alinhando incentivos privados aos sociais.

Adicionalmente, a convergência regional observada nos modelos econométricos reflete não apenas spillovers espaciais, mas também a acumulação intertemporal de conhecimento e infraestrutura. Regiões com histórico de mecanização funcionam como reservatórios de expertise, reduzindo incertezas e acelerando a adoção de inovações subsequentes. Esse processo é particularmente relevante no Norte-Nordeste, onde a baixa densidade tecnológica inicial oferece oportunidades para saltos de produtividade via modernização, desde que respaldada por políticas que equilibrem custos de curto prazo e retornos de longo prazo.

Em síntese, a redução das disparidades regionais exige estratégias dualísticas: (i) intervenções que mitiguem o desconto intertemporal, como linhas de crédito adaptadas a ciclos produtivos e seguro agrícola, e (ii) estímulo a redes colaborativas que maximizem spillovers espaciais, como parcerias entre polos tecnológicos e áreas menos desenvolvidas. A integração dessas dimensões temporais e espaciais permitiria não apenas elevar a produtividade agregada, mas também promover uma trajetória de desenvolvimento rural mais equitativa e resiliente, alinhando ganhos privados a externalidades positivas sistêmicas.

REFERÊNCIAS

ABBRUZZESE, Matteo; INFANTE, Davide; SMIRNOVA, Janna. The diffusion of renewable energy production in European countries: the role of incentives. **Economics of Innovation and New Technology**, p. 1-24, 2024.

- ANACKA, Helena; LECHMAN, Ewa. Network effects—do they matter for digital technologies diffusion?. **Journal of Organizational Change Management**, v. 36, n. 5, p. 703-723, 2023.
- ANSELIN, Luc. Local indicators of spatial association—LISA. **Geographical analysis**, v. 27, n. 2, p. 93-115, 1995.
- _____. Simple diagnostic tests for spatial dependence. **Regional science and urban economics**, v. 26, n. 1, p. 77-104, 1996.
- _____. Spatial econometrics. **A companion to theoretical econometrics**, v. 310330, 2001.
- ALMEIDA, E. S. A lei de Verdoorn local para a agricultura. **Revista Econômica do Nordeste**, v. 42, n. 1, p. 87-104, 2001.
- BLACKMAN, Allen. Why don't Lenders Finance High-Return Technological Change in Developing-Country Agriculture? **American Journal of Agricultural Economics**, v. 83, n. 4, p. 1024-1035, 2001.
- CAUNEDO, Julieta; KALA, Namrata. Mechanizing agriculture impacts on labor and productivity. **Dispersion in financing costs and development**, 2021.
- DAVID, Paul A. Technology diffusion, public policy, and industrial competitiveness. **The positive sum strategy: Harnessing technology for economic growth**, p. 373-391, 1986.
- DODGSON, Mark. Technological collaboration in industry: strategy, policy and internationalization in innovation. **Routledge**, 2018.
- Dias, T., Costa, E., Lima, F., & Souza, H. (2021). Regional heterogeneity of the family farming in brazil: an analysis using a spatial stochastic frontier. **Journal of Agricultural Studies**, 9(3), 179. <https://doi.org/10.5296/jas.v9i3.18688>
- FREEMAN, Chris. The economics of technical change. **Cambridge journal of economics**, v. 18, n. 5, p. 463-514, 1994.
- FOSTER, A. D.; ROSENZWEIG, M. R. Microeconomics of technology adoption. **Annu. Rev. Econ.**, 2(1), 395-424, 2010.
- _____. Learning by doing and learning from others: Human capital and technical change in agriculture. **Journal of political Economy**, 103(6), 1176-1209, 1995.
- Garcias, M. and Kassouf, A. (2016). Assessment of rural credit impact on land and labor productivity for brazilian family farmers. **Nova Economia**, 26(3), 721-746. <https://doi.org/10.1590/0103-6351/2761>
- GUIMARÃES, Patrick Wohrle. A lei Kaldor-Verdoorn na economia brasileira. 2002. **Dissertação (Mestrado em Economia Aplicada)** - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2002.
- HAYAMI, Y., RUTTAN, V. W. Agricultural productivity differences among countries. **The American economic review**, 60(5), 895-911, 1970.
- KELEJIAN, H. H.; PRUCHA, I. R.. A generalized spatial two-stage least squares procedure for estimating a spatial autoregressive model with autoregressive disturbances. **The journal of real estate finance and economics**, 17, 99-121, 1998.
- Li, V., Cheong, T., Huang, W., & Shum, W. (2022). Examining the regional disparity of agricultural development: a distribution dynamics approach. **Sustainability**, 14(19), 12779. <https://doi.org/10.3390/su141912779>
- SOBREIRA, D. (2024). Heterogeneous regional effects of rural credit on agricultural production in brazil. **Revista De Economia E Sociologia Rural**, 62(4). <https://doi.org/10.1590/1806-9479.2023.271082>

SOUZA, F. R.; CORONEL, D. A.; FREITAS, C. A. A “Lei” de Kaldor-Verdoorn para a agricultura brasileira: uma investigação pelos modelos de dependências espaciais para 2017. **RPER**, n. 69, p. 113–131, 2024.

OLSON, Mancur. Space, agriculture, and organization. **American Journal of Agricultural Economics**, v. 67, n. 5, p. 928-937, 1985.

TANURE, T., Domingues, É., & Magalhães, A. (2024). Regional impacts of climate change on agricultural productivity: evidence on large-scale and family farming in Brazil. **Revista De Economia E Sociologia Rural**, 62(1). <https://doi.org/10.1590/1806-9479.2022.262515>