

**DISPARIDADES REGIONAIS DA MECANIZAÇÃO AGRÍCOLA COMO
CONSEQUÊNCIA DO CRÉDITO EM MATO GROSSO**
*REGIONAL DISPARITIES IN AGRICULTURAL MECHANIZATION AS A
CONSEQUENCE OF CREDIT IN MATO GROSSO*

Luis Felipe de Souza Rodrigues
Universidade Federal de Mato Grosso - Faculdade de Economia
lfsouza25@gmail.com

**Grupo de Trabalho (GT): GT03. Evolução, estrutura, competitividade e dinâmica dos
complexos agroindustriais**

Resumo

O artigo investiga a influência do crédito rural na disparidade regional do uso de maquinário agrícola em municípios de Mato Grosso, visando compreender padrões espaciais e fatores determinantes. Utilizando econometria espacial, a pesquisa analisa a relação entre acesso ao crédito e distribuição do maquinário, considerando também fatores de produção como terra e trabalho. Como fonte de dados a pesquisa utiliza o Censo Agropecuário de 2017. Os resultados destacam uma significativa autocorrelação espacial na mecanização agrícola, indicando uma interdependência entre municípios e padrões de agrupamento, evidenciando a disparidade presente. A intensificação do trabalho em fazendas, especialmente em propriedades com grande concentração de terra e mão de obra, está fortemente associada à mecanização agrícola, resultando em maior adoção de maquinários. A diferença na proporção de trabalho por área plantada em relação à terra promove uma utilização mais eficiente do solo, aumentando a produtividade de forma ambientalmente favorável. O aumento da mecanização agrícola está relacionado ao incremento da renda proveniente do trabalho, enquanto o acesso facilitado ao crédito rural está positivamente ligado à mecanização, em contraste com os programas governamentais, cujo impacto é insignificante. Esses achados destacam a importância da renda e do acesso ao crédito na dinâmica da mecanização, evidenciando desafios de equidade na distribuição dos recursos. A pesquisa ressalta a importância de políticas agrícolas eficazes e de um ambiente financeiro favorável para promover o desenvolvimento sustentável e equitativo no setor agrícola.

Palavras-chave: mecanização agrícola; crédito; desigualdade; econometria espacial.

Abstract

The article investigates the influence of rural credit on the regional disparity in agricultural machinery use in municipalities of Mato Grosso, aiming to understand spatial patterns and determining factors. Using spatial econometrics, the research analyzes the relationship between credit access and machinery distribution, also considering production factors such as land and labor. The research uses the 2017 Agricultural Census as a data source. The results highlight a significant spatial autocorrelation in agricultural mechanization, indicating interdependence between municipalities and clustering patterns, revealing existing disparity. Intensification of work on farms, especially in properties with a large concentration of land and labor, is strongly associated with agricultural mechanization, resulting in greater machinery adoption. The difference in the proportion of work per planted area relative to land promotes more efficient soil use, increasing productivity in an environmentally favorable manner. The increase in agricultural mechanization is related to the income increment from work, while easy access to rural credit is positively linked to mechanization, contrasting with government programs, whose impact is insignificant. These findings underscore the importance of income and credit access in the dynamics of mechanization, highlighting challenges of equity in resource distribution. The research emphasizes the importance of effective agricultural policies and a favorable financial environment to promote sustainable and equitable development in the agricultural sector.

Key words: agricultural mechanization; credit; inequality; spatial econometrics.

1. Introdução

Nas últimas quatro décadas, a produção agropecuária tornou-se essencial para o crescimento e desenvolvimento regional no Brasil. A interação espacial e temporal ao longo dos anos desencadeou mudanças significativas nos sistemas de cultivo tradicionais. Nas

regiões de fronteira, a interação espacial resultou em transformações que impactaram as características locais. A interação espacial facilitou o fluxo regional de bens, pessoas, informações, tecnologias e processos.

Olson (1985) destaca que a agricultura, devido à sua demanda espacial maior em comparação com a indústria urbana, enfrenta desafios significativos nos custos de coordenação e monitoramento. O autor ressalta a importância do espaço e da distância, especialmente em contextos de altos custos de transporte e comunicação, na organização de grupos para ação coletiva na agricultura. Além disso, a intensidade espacial das atividades econômicas interage com desafios de coordenação e supervisão dentro das empresas, juntamente com dificuldades na formação de coalizões entre elas. Esses fatores contribuem para uma relação entre espaço e agricultura, moldando a organização e produtividade nas atividades agrícolas.

Nesse contexto, o estado de Mato Grosso se destaca por ser líder nacional de produção agrícola, sendo responsável por gerar 21% de toda riqueza nacional nesse segmento em 2022, segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE). O resultado é reflexo da combinação dos ganhos de área e de produtividade das lavouras. No ciclo seguinte (2022/23) o crescimento permanece, pois, conforme dados da Companhia Nacional de Abastecimento (Conab), enquanto a área apresenta uma alta de 5% em relação à safra 2021/22, chegando a 78,3 milhões de hectares, a produtividade média registra uma elevação de 11,8%, saindo de 3.656 quilos por hectare para 4.086 kg/ha.

Melhorias tecnológicas foram um dos fatores determinantes para que Mato Grosso alcançasse tal aumento de produtividade, além de um ambiente financeiro local que a favorecesse. Portanto, ocorre o processo de modernização do campo, alterando-se modelos de cultivo tradicionais para os intensivos no uso de maquinário e alteração do solo. Uma pesquisa realizada pelo Instituto Mato-grossense de Economia Agropecuária (IMEA) revelou que 34% dos produtores do estado possuem interesse em investir em novos maquinários. Os principais motivos para aquisição foram a melhoria no rendimento das operações (59%) e a maior facilidade de cultivo (26%). Entretanto, 88% dos agricultores consideram ter dificuldade para encontrar mão-de-obra capacitada. Em relação ao crédito, os principais obstáculos apontados para obtenção foram a acessibilidade, a burocracia e a dificuldade de liberação pelo banco.

De acordo com Blackman (2001), os credores são relutantes no financiamento de mudanças tecnológicas na agricultura de países em desenvolvimento devido à assimetria de informação sobre as preferências temporais dos solicitantes e ao risco de inadimplência para financiar o consumo imediato. A dualidade tecnológica, favorecendo agricultores ricos, e os custos significativos de adoção também são identificados como obstáculos, exacerbando a disparidade entre agricultores.

Apesar disso, intervenções governamentais têm o poder de aprimorar os mercados de crédito rural. Essas intervenções promovem eficiência na alocação de crédito, fortalecendo direitos de propriedade e garantias. O governo também regula o poder de mercado e influencia o aprendizado nos mercados financeiros por meio de propriedade em bancos e regulamentações, enquanto subsídios de crédito proporcionam oportunidades de aprendizado, impactando a alocação de crédito e contribuindo para o desenvolvimento de práticas e compreensão do mercado (BESLEY, 1994).

Sendo assim, questiona-se se o crédito rural é o responsável por exacerbar as disparidades regionais no uso de maquinário agrícola nos municípios de Mato Grosso. Portanto, a pesquisa tem o intuito investigar se a distribuição espacial das propriedades rurais revela padrões que expliquem as disparidades no uso de maquinário, examinando sua relação com o acesso ao crédito privado e governamental. Como um objetivo secundário, analisar se

os fatores de produção (terra e trabalho) interferem na mecanização, sendo *proxies* para avaliar a riqueza rural. Outro objetivo seria verificar se a rentabilidade per capita também contribui para a aquisição de máquinas.

2. Crédito rural e modernização do campo

A financeirização agrícola começou a se intensificar a partir da década de 1980, impulsionada por reformas econômicas, avanços tecnológicos e globalização (WILLIAMS, 2014). A criação de mercados de derivativos, como contratos futuros e opções sobre commodities agrícolas, proporcionou instrumentos financeiros para hedge e especulação. A globalização permitiu que investidores participassem nos mercados agrícolas em escala mundial, enquanto avanços na tecnologia da informação facilitaram o acesso e a negociação. Além disso, enfatiza-se a importância do espaço agrícola e a necessidade de examinar as desigualdades resultantes desse fenômeno.

Segundo Barry (2001), a crescente de técnicas avançadas de gerenciamento de riscos pelas instituições financeiras pode resultar em mudanças nas práticas de empréstimo e na disponibilidade de crédito para os agricultores. O autor ressalta a importância de compreender o ambiente regulatório em constante evolução e destaca a necessidade de adaptação dos credores agrícolas às mudanças no mercado, desenvolvendo novos produtos e serviços para atender às demandas dos clientes. De acordo com Benjamin e Phimister (2002), as diferentes estruturas de mercados de capital geram disparidades na sensibilidade geral do investimento ao fluxo de caixa, manifestando-se de maneira distinta entre fazendas, com base nos níveis de garantia, e entre os investimentos em estoque e maquinário.

Um estudo realizado por Zhengfei e Lansink (2006) em fazendas holandesas, entre 1990 e 1999, mostrou que a relação entre financeirização agrícola (representada pelo nível de endividamento) e produtividade sugere que o acesso adequado a recursos financeiros, por meio da dívida, pode contribuir para o desenvolvimento e eficiência das atividades agrícolas. No entanto, uma análise realizada por Guirkinger e Boucher (2008) no Peru indica que a produtividade está vinculada aos ativos produtivos em fazendas com restrições de crédito, enquanto aquelas sem restrição não são afetadas. Restrições formais de crédito têm um impacto negativo significativo na eficiência da alocação de recursos, e sua eliminação pode aumentar o valor da produção agrícola na região estudada.

Roberts e Key (2008) abordam a mudança estrutural na agricultura, como mudanças tecnológicas e fatores de preços, destacando o aumento da concentração de terras nas últimas décadas. Os resultados sugerem que uma porção significativa do crescimento observado na concentração agrícola é atribuível aos pagamentos governamentais. Apesar da intervenção governamental contínua nos mercados de crédito rural, Petrick (2004) destaca que a política de subsídio do governo não teve êxito em eliminar o racionamento de crédito em seu estudo realizado na Polônia. Segundo o autor, os agricultores condicionam suas decisões de investimento à disponibilidade de crédito subsidiado, porém, os fundos disponibilizados são utilizados apenas parcialmente para investimentos produtivos, indicando uma possível divergência de fundos para atividades de consumo.

Pequenos agricultores recebem menos crédito do que os médios e grandes devido à falta de ativos para garantia, processos burocráticos demorados e custosos, e influência do status social (HUSSAIN & THAPA, 2012). A incapacidade de oferecer garantias substanciais limita seu acesso ao crédito formal, levando-os a depender predominantemente do crédito informal, que, embora mais acessível, não atende totalmente às suas necessidades imediatas. A disparidade é agravada pela falta de conhecimento sobre os procedimentos formais,

enquanto agricultores maiores têm ativos valiosos e melhor capacidade de navegar no sistema burocrático.

A mecanização agrícola adequada à escala desempenha um papel crucial no aumento da produtividade do trabalho dos pequenos agricultores, e compreender os fatores socioeconômicos que influenciam a aquisição e adoção de máquinas agrícolas em pequena escala é essencial para informar políticas eficazes. Um estudo realizado por Mottaleb et. al. (2016), descobriu que o status de riqueza e o tamanho da terra estavam positivamente relacionados à posse de máquinas, indicando que a posse de bens de capital está associada à base geral de recursos dos proprietários. Além disso, a disponibilidade de eletricidade, o acesso a serviços de crédito e infraestrutura civil foram fatores determinantes significativos.

3. Mecanização agrícola no Brasil e o crédito

De 1960 até o final de 2018, as áreas agrícolas no Brasil cresceram consideravelmente, acompanhadas por um aumento notável na frota de tratores de rodas, resultando em uma significativa redução na área mecanizada por trator, de 410 para 65 hectares por trator (MANTOVANI ET. AL., 2019). A aquisição e maquinários dependem da renda dos agricultores e de políticas de crédito governamentais e privadas. As vendas de maquinaria agrícola no Brasil são fortemente impactadas pelos preços internacionais das commodities, como soja, milho, cítricos e café. Diante da urbanização crescente e da escassez de mão de obra, foram estabelecidos sistemas de cultivo altamente mecanizados, visando atender a cronogramas agrícolas em diferentes níveis de tecnologia.

Programas governamentais como o Moderfrota, Pronamp e Pronaf facilitaram financiamentos para os agricultores, contribuindo para um ambiente favorável. A indústria de máquinas agrícolas no Brasil agora oferece tanto máquinas tradicionais quanto inteligentes, incorporando tecnologias como automação inteligente e agricultura de precisão. Esse foco em inovação visa aumentar a produtividade e reduzir custos operacionais. A automação da produção, desde a preparação do solo até a gestão de insumos, destacou a competitividade e estratégia do Brasil no cenário global, gerando commodities, alimentos e energia para consumo interno e exportação.

Moderfrota foi lançado em 2000 com o objetivo de facilitar o acesso dos produtores a tratores e implementos por meio de financiamento, o programa enfrentou desafios ao longo do tempo, mas teve um papel crucial na modernização do setor e no estímulo à demanda por equipamentos agrícolas. Análises realizadas por Araujo et. al. (2021) indicaram que o programa explicou cerca de 4,14% das variações na produção agrícola, com seu impacto total ocorrendo com um atraso de três trimestres. Uma reformulação posterior, a partir de 2014, buscou ampliar os limites de renda para os produtores rurais, visando aumentar o alcance e o impacto do programa, especialmente nas regiões Norte e Nordeste.

No entanto, Resende (2015) argumenta que as políticas governamentais de trabalho e terra, e ao crédito agrícola subsidiado, resultaram em uma divergência entre os custos sociais e privados do trabalho e do capital na agricultura. Essa distorção, ao tornar a mão de obra agrícola cara e o capital barato para o setor, incentivou uma rápida transição tecnológica em direção à mecanização. A disponibilidade de mão de obra barata inicialmente levou à adoção de tecnologia estrangeira e, posteriormente, à criação de máquinas específicas para a agricultura brasileira. O autor explora a relação entre mecanização e produção em larga escala na agricultura brasileira, argumentando que a falta de acesso ao crédito e a inviabilidade da produção doméstica de máquinas para pequenos agricultores levaram à predominância de máquinas voltadas para grandes produtores, resultando em um fenômeno de "indivisibilidade" de máquinas.

Por outro lado, uma pesquisa conduzida por Souza et al. (2022) ressaltou a relevância do crédito rural ao analisar seus efeitos sobre a aquisição de máquinas agrícolas no Brasil, indicando que a acessibilidade a esse crédito amplifica a produção agrícola sem resultar em desmatamento adicional. Segundo os autores, houve uma leve conversão de pastagens em terras cultivadas, indicando maior produtividade em áreas mais intensivas em mão de obra. Para mais, destacou-se que o crédito do Banco Nacional de Desenvolvimento Econômico e Social (BNDES) tem implicações além dos objetivos específicos, influenciando o meio ambiente e a eficiência da produção agrícola. Dessa forma, o estudo sublinha a importância de considerar aspectos ambientais e de produtividade ao formular políticas de crédito, visando contribuir para o progresso econômico, social e ambiental do Brasil.

No nível de unidades federativas, Castro e Teixeira (2012) examinam o programa de crédito rural no Brasil, concentrando-se no impacto do financiamento do Tesouro Estadual (TE) no setor agrícola. Os resultados indicam um impacto positivo do TE no fornecimento de produção e na demanda por insumos, sugerindo uma resposta favorável do setor agrícola ao programa de crédito. Os autores destacam a importância do programa diante de restrições orçamentárias, levantando questões sobre a efetiva acessibilidade ao crédito subsidiado por parte dos agricultores com limitações financeiras. Identificou setores mais beneficiados, como milho e soja, e apontou limitações nos dados agregados, sugerindo a necessidade de análises regionais mais detalhadas.

4. Metodologia

A econometria espacial, que estuda a interação e estrutura espacial em modelos de regressão, antes associada a campos como ciência regional, recentemente, esses modelos têm sido amplamente utilizados em estudos convencionais da economia. Esse aumento de interesse reflete a necessidade de compreender a interação entre agentes econômicos heterogêneos, impulsionada pelo crescimento de dados geocodificados e a prevalência da autocorrelação espacial em conjuntos de dados transversais (ANSELIN, 2001).

Thünen (1910), pioneiro da teoria da localização agrícola, destacou a importância do espaço na economia agrícola ao modelar a organização ótima das atividades agrícolas com base em fatores de localização, considerando a localização das fazendas. A variação espacial de atividades agrícolas pode ser resultado tanto da heterogeneidade espacial, com fatores de localização tradicionais variando geograficamente, quanto da dependência espacial, originada pelos efeitos benéficos dessas atividades em si. A heterogeneidade espacial refere-se à variação de variáveis como trabalho ou área colhida em diferentes localidades, enquanto a dependência espacial indica uma relação funcional entre eventos em locais distintos, originando-se de efeitos de aglomeração.

Nesse estudo, focado no uso de maquinário agrícola em Mato Grosso, utiliza ferramentas de econometria espacial para analisar a distribuição espacial desse maquinário, explicitamente considerando efeitos espaciais em estudos da relação com o crédito rural. Esta abordagem corrige vieses decorrentes da falta de consideração pelas informações espaciais em análises econômicas convencionais, como o Modelo Clássico de Regressão Linear (MCRL), contribuindo para uma compreensão mais abrangente das dinâmicas espaciais.

4.1. Análise Exploratória dos Dados Espaciais

A Análise Exploratória dos Dados Espaciais (AEDE) tem como objetivo facilitar a identificação e a visualização de padrões espaciais em um determinado fenômeno. Um passo fundamental nesse processo é a definição do critério de vizinhança, que estabelece o grau de

proximidade considerado na análise de dependência espacial. A partir desse critério, é proposta uma matriz de defasagem espacial W que descreve as relações espaciais entre as unidades de análise. A escolha do critério de vizinhança é crucial para determinar a autocorrelação espacial, e diferentes tipos de matrizes de ponderação espacial W podem ser aplicados, incluindo matrizes de vizinhança, proximidade geográfica e socioeconômica. A matriz de ponderação espacial atribui pesos que indicam as dependências espaciais entre as unidades analisadas no modelo econométrico espacial. Portanto, a escolha adequada da matriz de ponderação é essencial para uma análise espacial precisa.

O presente artigo utiliza o coeficiente de autocorrelação espacial I de Moran (1) como métrica para determinar a matriz de ponderação mais apropriada, optando por aquela que apresenta o maior valor absoluto estatisticamente significativo, variando de -1 a 1 . Portanto, o coeficiente I de Moran univariado, originado da proposta inicial de Moran (1948) e posteriormente refinado por Cliff e Ord (1973), é utilizado como uma métrica estatística para avaliar a autocorrelação espacial do uso de maquinário agrícola.

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

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

O teste de I de Moran tem como hipótese nula a independência dos valores da variável analisada em relação aos valores das observações vizinhas, representada pela equação $-[1/n-1]$, onde n é o número de observações. Isso sugere a ausência de autocorrelação espacial para um determinado nível de significância. O Diagrama de Dispersão, uma ferramenta adicional, utiliza o coeficiente de regressão com valores normalizados do atributo em estudo para verificar a dependência espacial, distinguindo padrões como autocorrelação positiva ou negativa. O diagrama é dividido em quadrantes, refletindo diferentes associações espaciais entre unidades locais com altos e baixos valores.

O Indicador Local de Associação Espacial (LISA) é empregado para avaliar os padrões locais de dependência espacial em relação ao atributo em análise. Esse indicador, conforme Anselin (1995), deve satisfazer dois critérios essenciais: (a) a capacidade de indicar cluster espacial significativo para cada observação individualmente; e (b) a propriedade de que a soma dos indicadores locais, para todas as unidades locais, seja proporcional ao indicador de autocorrelação espacial correspondente. Assim, a autocorrelação espacial I de Moran local (2) para cada unidade local destaca diferentes cenários, proporcionando uma compreensão clara das características de distribuição espacial específicas.

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

O teste de significância para o coeficiente de autocorrelação espacial I de Moran Local é dado por $-W_i/n-1$, onde W_i 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, juntamente com 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.

4.2. Métodos econométricos espaciais

Na presença de dependência espacial, são aplicados modelos de econometria espacial para lidar com a dependência e heterogeneidade espacial. Isso envolve a incorporação do componente espacial pela defasagem das variáveis nos termos de erro. O processo começa com a estimação do modelo de Mínimos Quadrados Ordinários (MQO) e testes subsequentes para identificar o modelo econométrico espacial mais adequado. A escolha criteriosa de uma matriz de ponderação W é determinante para capturar a autocorrelação espacial, evitando medições com erro nas variáveis defasadas. O procedimento proposto no artigo sugere testar diversas matrizes W , selecionando aquela com a maior autocorrelação espacial estatisticamente significativa após a estimação inicial por MQO.

Após a determinação da matriz W mais apropriada, são realizados testes específicos para identificar o tipo predominante de autocorrelação na regressão por MQO. A maioria desses testes é do tipo Multiplicador de Lagrange, buscando avaliar se a incorporação de um modelo irrestrito melhora a capacidade explicativa do modelo. O teste ML_p verifica a presença de defasagem espacial na variável dependente, com a hipótese nula $H_0: \rho=0$. Por sua vez, o teste ML_γ investiga a autocorrelação espacial no erro, com a hipótese nula $H_0: \gamma=0$. É importante notar que esses testes foram desenvolvidos especificamente para avaliar os modelos de defasagem espacial (SAR) e o modelo de erro espacial (SEM).

No contexto do modelo de MQO, o modelo de SAR (3) adiciona um termo adicional, Wy , para capturar o efeito de vizinhança que reflete a influência da variável dependente y nas regiões vizinhas. A variável Wy é considerada endógena devido às diversas direcionalidades de dependência espacial, resultando em um processo circular de influência da variável dependente sobre as variáveis dependentes em regiões vizinhas.

$$y = \rho Wy + X\beta + \varepsilon \quad (3)$$

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.

A distinção do SEM (4) em comparação com o SAR reside no fato de que a dependência espacial se reflete no termo de erro, não mais na variável dependente. Isso implica que a dependência espacial é residual, caracterizada pela estrutura auto-regressiva de primeira ordem no termo de erro. O modelo SEM é apropriado quando as variáveis não incluídas no modelo estão presentes no termo de erro e , consequentemente, exibem autocorrelação espacial.

$$y = \alpha + X\beta + \lambda Wu + \varepsilon \quad (4)$$

Em que o coeficiente λ é o parâmetro do erro autorregressivo espacial que acompanha a defasagem Wu .

Anselin (1996) propôs um procedimento de especificação de modelos espaciais em diversas etapas: (I) inicialmente, estima-se o modelo por Mínimos Quadrados Ordinários (MQO); (II) em seguida, são realizados os testes ML_p e ML_γ ; (III) se ambos os testes não apresentarem significância estatística, o modelo clássico de regressão é considerado o mais apropriado; (IV) no caso de apenas um dos testes ser significativo, o modelo SAR é estimado quando ML_p é significativo, enquanto o modelo SEM é estimado quando ML_γ é significativo; (V) se ambos os testes forem significantes, são testadas versões robustas, e o modelo é estimado com base no teste que indicar maior significância.

4.3. Especificações do modelo e dos dados

A pesquisa abrange uma vasta área compreendendo 141 municípios no estado de Mato Grosso. Para coletar os dados, foi utilizado o Censo Agropecuário de 2017 do IBGE, junto aos limites geográficos municipais fornecidos pelo mesmo instituto. As variáveis foram organizadas em uma tabela e associadas a um arquivo shapefile, posteriormente manipulado no software R Studio. Esse processo permitiu uma preparação meticulosa dos dados, integrando informações tabulares e geoespaciais, garantindo a qualidade e estruturação adequadas para a análise espacial proposta no estudo.

A literatura sobre mecanização agrícola (MA) (RESENDE, 2015; MANTOVANI ET. AL., 2019) destaca que o nível de mecanização está intrinsecamente relacionado com as contribuições de terra (Te) e capital (Ca), que compõem os fatores de produção, bem como o rendimento (Re) e o crédito, tanto privado (CPr) quanto público (CPu), que são fontes fundamentais para a aquisição de capital físico. Com o objetivo de capturar a influência dessas variáveis em cada município, foram desenvolvidos índices (tabela 1) que estabelecem uma relação com a quantidade de empreendimentos rurais (ER) e seus trabalhadores em cada localidade.

Tabela 1. Índices.

Índice	Descrição	Fórmula
Taxa de Mecanização Agrícola (TXM)	O grau de utilização de maquinário agrícola empregado pelos empreendimentos rurais	MA/ER
Rendimento Rural Per Capita (RRP)	Contribuição do trabalho para geração de rendimento dos empreendimentos rurais	Re/Tr
Área Rural Per Capital (ARP)	A intensidade de trabalho aplicado por área plantada	Te/Tr
Taxa de Participação do Trabalho (TPT)	O grau de utilização do trabalho empregado pelos empreendimentos rurais	Tr/ER
Taxa de Participação do Crédito Privado (TPPr)	Quanto empreendimentos rurais são financiados por meio de crédito privado	CPr/ER
Taxa de Participação do Crédito Público (TPPu)	Quanto empreendimentos rurais são financiados por meio de programas governamentais	CPu/ER

Fonte: elaborado pelo autor.

Ao utilizar um modelo de regressão cross-section do tipo log-log (5), com a taxa de mortalidade (TXM) como variável dependente e os demais indicadores como variáveis explicativas. O modelo log-log não apenas permite avaliar a direção e magnitude dos efeitos das variáveis explicativas na TXM, mas também compreender se esses efeitos são lineares ou não lineares. Por exemplo, coeficientes positivos indicam um aumento proporcional na TXM com aumentos nas variáveis explicativas, enquanto coeficientes negativos indicam o oposto. Além disso, a análise do modelo log-log possibilita examinar a diferença marginal das

variáveis explicativas, revelando como mudanças incrementais nessas variáveis afetam a TXM.

$$\ln(TXM) = \alpha + \beta_1 \ln(RRP) + \beta_2 \ln(ARP) + \beta_3 \ln(TPT) + \beta_4 \ln(TPP_r) + \beta_5 \ln(TPP_u) + \varepsilon \quad (5)$$

Destaca-se que esse modelo log-log é a base para a estimativa de modelos de mínimos quadrados ordinários (MQO) e modelos espaciais. Entender esses modelos permite avaliar a significância estatística dos coeficientes e a robustez das relações identificadas. Isso é realizado por meio da aplicação de testes estatísticos apropriados, que permitem determinar se os coeficientes são estatisticamente significativos e se o modelo como um todo é válido. Essa abordagem não apenas oferece uma compreensão mais abrangente das relações entre as variáveis, mas também fornece uma base sólida para análises mais avançadas e interpretações mais precisas dos resultados.

A análise descritiva dos dados (tabela 2) mostra que uma grande variância de algumas variáveis, como TXM e RRP, e uma grande amplitude de valores. Isso pode ser indício de que valores dessas variáveis em uma ou mais localidade se destoam dos valores apresentados em outras localidade do estado, levando a médias enviesadas. Portanto, a mediana é a métrica de medida central mais adequada nesses casos, sendo necessário uma avaliação mais aprofundada.

Tabela 2. Descrição dos Dados.

Variável	Média	Mediana	Desvio Padrão	Mínimo	Máximo
TXM	1,622	0,778	2,504	0,100	19,94
RRP ¹	141,4	86,37	139,6	14,44	672,9
ARP ²	37,13	12,93	52,22	0,035	244,8
TPT	4,553	3,293	4,711	1,895	49,77
TPPr	0,122	0,101	0,093	0,006	0,604
TPPu	0,077	0,051	0,100	0,001	1,000

Fonte: elaborado pelo autor.

Nota: ¹ em mil reais; ² em hectares.


5. RESULTADOS

Os resultados da pesquisa, apresentados nas seções 5.1 e 5.2, destacam a importância da AEDE como uma etapa preliminar para compreender padrões espaciais na mecanização agrícola. Utilizando técnicas como Boxmap, Índice de Moran e LISA, a pesquisa identificou disparidades significativas na distribuição da mecanização agrícola em municípios de Mato Grosso, ressaltando a presença de autocorrelação espacial. Na sequência, a introdução de modelos econométricos espaciais na seção 5.2 permitiu uma análise mais aprofundada da disparidade espacial. A comparação entre MQO e SEM indicou a superioridade do modelo espacial, evidenciada por critérios como Log-verossimilhança e AIC. O significativo valor do parâmetro λ no SEM sugere uma interdependência na mecanização agrícola entre os municípios.

5.1. AEDE

A AEDE constitui uma fase descritiva precedente à proposição de fatores dinâmicos para elucidar os padrões espaciais em estudo, antecedendo ainda a estimação e teste de modelos de regressão mais avançados. Inicialmente, realiza-se o mapeamento dos fenômenos e conduz uma AEDE para investigar padrões de autocorrelação espacial. Apresenta-se, neste contexto, o Boxmap (Figura 1) que ilustra a distribuição da mecanização agrícola nos municípios de Mato Grosso. Este mapa possibilita visualizar a posição de cada município na distribuição total da mecanização agrícola, facilitando a detecção de valores atípicos. A Figura 1 evidencia que a distribuição espacial da mecanização agrícola nos municípios de Mato Grosso é notavelmente desigual, sendo mais pronunciada nos municípios centrais em comparação com aqueles próximos às fronteiras do estado. Diante do indício de autocorrelação espacial no Boxmap, emprega-se o Índice de Moran e o LISA para identificar a presença de autocorrelação espacial tanto 'global' quanto 'local'.

Figura 1. Boxmap da Taxa de Mecanização Agrícola.



Fonte: elaborado pelo autor.

Nota: utiliza a classificação de Quebras Naturais de Jenks.

A fase seguinte da AEDE envolve o estabelecimento do critério de vizinhança para investigar a dependência espacial do uso de maquinário agrícola nos municípios de Mato Grosso. Essa etapa compreende a seleção da matriz que apresenta a maior autocorrelação espacial estatisticamente mais significativa. Diversos testes são conduzidos, utilizando o coeficiente I de Moran para diferentes tipos de matrizes, como as matrizes rainha, torre e k-vizinhos (com valores de k sendo 3, 6 e 9) (Tabela 3). Todas as matrizes demonstram significância estatística, indicando autocorrelação positiva. A matriz de ordem espacial "k-vizinhos" (para 3 vizinhos mais próximos) destaca-se com o maior valor de 0,398, sendo escolhida para os subseqüentes testes na análise exploratória.

Tabela 3. Estatística I de Moran.


Matriz de Contiguidade	I de Moran
Rainha	0,293***
Torre	0,291***
K 3 vizinhos	0,398***
K 6 vizinhos	0,316***
K 9 vizinhos	0,243***

Fonte: elaborado pelo autor.

Nota: *** >0,01.

Para obter uma compreensão mais detalhada sobre a distribuição dos municípios com alta ou baixa mecanização agrícola no estado, utiliza-se o mapa de agrupamento LISA para identificar clusters locais. A Figura 2 exhibe os mapas de agrupamento LISA para a mecanização agrícola, revelando uma clara distinção entre dois clusters espaciais locais positivos do tipo Alto-Alto. Um desses clusters está localizado a oeste, envolvendo municípios como Sapezal, Campos de Júlio e Campo Novo do Parecis, que se destacam em termos de mecanização agrícola em comparação com a média estadual. O segundo cluster, situado na região central, abrange municípios como Sorriso, Nova Ubiratã, Lucas do Rio Verde e Tapurah, enquanto Itanhangá se destaca como Baixo-baixo. O primeiro cluster apresenta uma média de mecanização de 12,86, enquanto no segundo a média é de 4,23, demonstrando uma clara distinção entre as duas regiões com as maiores concentrações de maquinários.

Figura 2. Cluster LISA.



Fonte: elaborado pelo autor.

Os resultados da AEDE nesta seção indicam que a mecanização agrícola nos municípios mato-grossenses é influenciada pela autocorrelação espacial, revelando

disparidades intrarregionais. Portanto, a presença da autocorrelação espacial deve ser considerada nas estimativas econômicas. A identificação dessas disparidades dentro do estado destaca a necessidade de abordagens analíticas robustas, considerando efeitos espaciais presentes nos dados para uma compreensão mais completa dos padrões e fatores que afetam a mecanização agrícola no estado.

5.2. Modelos econométricos espaciais

A análise realizada na seção anterior confirma a presença de autocorrelação espacial na mecanização agrícola, porém não consegue identificar os fatores que exercem influência no agrupamento espacial e explicar a disparidade espacial. Diante disso, nesta seção, propomos uma análise cross-section da mecanização agrícola nos municípios do Mato Grosso, referente ao ano de 2017. Esta abordagem visa aprofundar nossa compreensão dos elementos que contribuem para a distribuição espacial da mecanização agrícola no estado, proporcionando compreensão aprofundada sobre os padrões e fatores subjacentes a essa dinâmica.

Inicialmente, realiza uma estimação por MQO para diagnosticar os parâmetros, seguido pelos testes de dependência espacial e de Lagrange. Os resultados da estimação (Tabela 3) revelam um coeficiente significativo e positivo para TPPr, confirmando a hipótese de que o crédito privado contribui para o uso de maquinário agrícola. No entanto, TPPu não apresentou significância estatística, sugerindo que o crédito proveniente de programas governamentais pode não estar influenciando a aquisição de maquinário. Todos os outros coeficientes foram estatisticamente significativos e positivos. A ausência de multicolinearidade indica eficiência nos parâmetros das variáveis. A presença de heterocedasticidade no modelo era esperada, considerando a natureza heterogênea dos dados espaciais. Além disso, o R^2 ajustado de 0,89 evidencia que as variáveis explicativas têm um efeito significativo na explicação da disparidade espacial na mecanização agrícola.

Tabela 4. Estimação por MQO.

Variável	Coefficiente	Erro Padrão	Teste t	P-valor	VIF
Constate	-3,07677	0,29169	-10,548	< 2e-16 ***	—
RRP	0.44475	0.06159	7.221	3.40e-11 ***	4.3703
ARP	0.09731	0.02337	4.164	5.55e-05 ***	3.6414
TPT	0.80076	0.07299	10.970	< 2e-16 ***	1.7910
TPPu	0.01774	0.02807	0.632	0.5284	1.1385
TPPr	0.10523	0.04059	2.593	0.0106 *	1.4008
Diagnóstico					
F	3,504	< 2.e-16 ***			
Breusch Pagan	18.329	1.85e-05 ***			
Jarque Bera	16.458	0.00026 ***			
LogLikelihood	-37.42885				

AIC 88.85771

Fonte: elaborado pelo autor.

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

Foi detectada autocorrelação espacial significativa no teste de I de Moran (tabela 3), sendo necessário selecionar uma especificação alternativa em vez de adotar o MCRL. Os diagnósticos para a dependência espacial mostram que o Índice de Moran (0,2485) demonstra uma dependência espacial significativa (autocorrelação espacial), assim como todos os testes de Lagrange são significativos. Portanto, avalia-se os testes robustos para determinar qual modelo é o mais adequado. O teste R-LMERR, com um p-valor de 0.0005831, inferior ao 0.03646 de R-LMLAG, dá indícios que o modelo SEM é o modelo mais apropriado para estimação, de acordo com o processo de decisão de regressão espacial.

Tabela 5. Testes de I de Moran e de Lagrange.

Teste	MI/DF	Valor	P-valor
I de Moran	0.24859	5.3204 ***	5.177e-08
LMLAG	1	15.062 ***	0.000104
R-LMLAG	1	4.3755 *	0.03646
LMERR	1	22.516 ***	2.084e-06
R-LMERR	1	11.829 ***	0.0005831

Fonte: elaborado pelo autor.

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

A comparação entre os resultados da estimação por MQO e pelo SEM (Tabela 4) usando os critérios de Log-verossimilhança e AIC indica que o modelo considerando a espacialidade apresenta uma melhor adequação. O critério de Log-verossimilhança para o MQO resultou em -37,42885, menor do que o valor de -25,80654 obtido pelo SEM. No que diz respeito ao critério AIC, o modelo anterior registrou um valor superior de 88,85771 em comparação com o valor de 67,61307 no modelo espacial. Além disso, observou-se uma leve melhoria na capacidade explicativa das variáveis independentes ao comparar os R² ajustados entre os modelos.

Tabela 6. Estimação por SEM.

Variável	Coeficiente	Erro Padrão	Teste t	P-valor
Constante	-3.042419	0.275145	-11.0575	< 2.2e-16 ***
RRP	0.453099	0.060195	7.5272	5.174e-14 ***
ARP	0.054367	0.024248	2.2421	0.024955 *
TPT	0.853546	0.066979	12.7435	< 2.2e-16 ***
TPPu	0.036634	0.024604	1.4889	0.136510

TPPr	0.101691	0.038380	0.038380	0.008058 **
λ	0.5748	0.089344	6.4336	1.2463e-10 ***

Diagnóstico

R ² ajustado ¹	0.9191
LogLikelihood	-25.80654
AIC	67.61307

Fonte: elaborado pelo autor.

Nota: * significativa em <5%; ** significativa em <1%; *** significativa em <0,1%. ¹ Pseudo R².

A significância do parâmetro λ no modelo SEM sugere que a mecanização agrícola no município i está diretamente relacionada à mecanização agrícola nos municípios vizinhos. Em outras palavras, há uma interdependência entre as províncias com percentuais elevados ou baixos de mecanização agrícola, indicando uma tendência de agrupamento e interação entre elas.

Com exceção de TPPu, todos os outros coeficientes são positivos e significativos ao nível de 5% no modelo SEM. O sinal positivo de TPT implica que a taxa de mecanização agrícola depende fortemente do grau de participação do trabalho nas fazendas. Ou seja, um aumento da intensificação do trabalho nos empreendimentos rurais resulta em um aumento mais do que proporcional na mecanização agrícola. No entanto, o coeficiente de ARP mostrou uma menor força explicativa, indicando que um aumento na intensidade de trabalho aplicado por área plantada resulta em um aumento proporcionalmente menor na mecanização agrícola. Portanto, um aumento da área plantada terá um impacto substancialmente menor na mecanização do que um aumento do trabalho. O coeficiente RRP também é relevante em explicar, pois um aumento marginal da contribuição do trabalho na geração de rendimento dos empreendimentos rurais leva a um significativo aumento da mecanização agrícola. Essas variáveis são proxies destinadas a capturar o nível de riqueza das fazendas nos municípios, que está associado à facilidade de acesso ao crédito. Partindo disso, o TPPr positivo satisfaz a hipótese de que o crédito rural contribui relativamente para o uso de maquinário agrícola. Sendo assim, municípios com menores restrições ao crédito apresentam mais facilidade para aquisição de maquinário. No entanto, o TPPu não significativo implica que não existem evidências suficientes para admitir que os atuais programas governamentais de acesso ao crédito tenham contribuído efetivamente para a mecanização. Esses resultados ressaltam a importância desses fatores na compreensão da dinâmica da mecanização agrícola em relação ao crédito.

6. Conclusão

A análise realizada proporcionou uma compreensão específica da dinâmica da mecanização agrícola nos municípios de Mato Grosso. Os resultados revelaram disparidades significativas na distribuição espacial da mecanização agrícola, indicando uma interdependência entre municípios e a presença de padrões de agrupamento. Esses padrões podem ser indícios das disparidades regionais de mecanização agrícola existentes no estado, refletindo diferentes níveis de acesso a recursos, tecnologias e infraestrutura agrícola.

Os resultados apontam que a intensificação do trabalho nas fazendas está mais intimamente ligada à mecanização agrícola, especialmente em propriedades rurais que concentram terra e mão de obra. Esse aumento na intensificação do trabalho resulta em um significativo crescimento na adoção de maquinário. Por outro lado, o aumento na intensidade do trabalho por área plantada tem um impacto relativamente menor na mecanização. Essa diferença de proporção em relação à terra é ambientalmente favorável, promovendo maior produtividade e uma utilização menos intensiva do solo.

Além disso, é importante ressaltar que a contribuição do trabalho para a geração de renda também se mostrou um fator relevante, com um aumento marginal associado a um significativo aumento na mecanização agrícola. No que diz respeito ao crédito rural, a facilidade de acesso foi positivamente associada à mecanização, enquanto os programas governamentais não demonstraram impacto significativo. Estes resultados sublinham a importância desses fatores na compreensão da dinâmica da mecanização agrícola, uma vez que a renda e o acesso ao crédito constituem fontes de capital para a aquisição de capital físico. A concentração de recursos em áreas menores e menos produtores sugere que o crédito pode não estar impulsionando equitativamente a produção em todo o estado.

Ao destacar disparidades espaciais e interdependências entre municípios, a pesquisa fornece uma base essencial para políticas agrícolas mais eficazes e promove uma alocação mais eficiente de recursos. A ênfase na influência do crédito, especialmente do setor privado, destaca a importância de existir um ambiente financeiro favorável para impulsionar a modernização no setor agrícola. Essas implicações não apenas beneficiam Mato Grosso, mas também têm sugestões valiosas para outros estados agrícolas, oferecendo uma abordagem integrada para promover o desenvolvimento sustentável e equitativo.

Entretanto, é fundamental destacar que os resultados obtidos nesta pesquisa são específicos para o estado de Mato Grosso. Para uma compreensão mais abrangente e precisa da dinâmica da mecanização agrícola no Brasil, são necessárias pesquisas adicionais em outros estados, a fim de investigar se os padrões identificados se repetem e como esses fatores influenciam a mecanização agrícola em contextos diversos. Essa abordagem comparativa e integrada pode orientar políticas e práticas agrícolas, visando promover o desenvolvimento sustentável e equitativo em todo o setor agrícola brasileiro. Ao compreender as nuances regionais e as diferentes realidades socioeconômicas, é possível implementar estratégias mais eficazes e adaptadas às necessidades específicas de cada região, contribuindo para a construção de um setor agrícola mais resiliente e inclusivo em todo o país.

7. Referências

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.

ARAÚJO, Beatriz Santos; HECK, Claudia Regina; CARRARA, Anieli Fagundes. Crédito rural e mecanização da agricultura: o impacto do Moderfrota. **Revista de Política Agrícola**, v. 30, n. 4, p. 45, 2021.

BARRY, Peter J. Modern capital management by financial institutions: implications for agricultural lenders. **Agricultural Finance Review**, v. 61, n. 2, p. 103-122, 2001.

- BENJAMIN, Catherine; PHIMISTER, Euan. Does capital market structure affect farm investment? A comparison using French and British farm-level panel data. **American Journal of agricultural economics**, v. 84, n. 4, p. 1115-1129, 2002.
- BESLEY, Timothy. How do market failures justify interventions in rural credit markets? **The World Bank Research Observer**, v. 9, n. 1, p. 27-47, 1994.
- 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.
- DE CASTRO, Eduardo Rodrigues; TEIXEIRA, Erly Cardoso. Rural credit and agricultural supply in Brazil. **Agricultural Economics**, v. 43, n. 3, p. 293-302, 2012.
- CLIFF, Andrew David; ORD, J. Keith. **Spatial autocorrelation**. 1973.
- GUIRKINGER, Catherine; BOUCHER, Stephen R. Credit constraints and productivity in Peruvian agriculture. **Agricultural Economics**, v. 39, n. 3, p. 295-308, 2008.
- HUSSAIN, Abid; THAPA, Gopal Bahadur. Smallholders' access to agricultural credit in Pakistan. **Food Security**, v. 4, p. 73-85, 2012.
- IMEA - INSTITUTO MATO-GROSSENSE DE ECONOMIA AGROPECUÁRIA. **Pesquisa sobre mecanização agrícola em Mato Grosso**. Cuiabá, MT: IMEA, 2015.
- MANTOVANI, Evandro Chartuni et al. Current status and future prospect of the agricultural mechanization in Brazil. **AMA, Agricultural Mechanization in Asia, Africa and Latin America**, v. 50, n. 2, p. 20-28, 2019.
- MORAN, Patrick AP. The interpretation of statistical maps. **Journal of the Royal Statistical Society. Series B (Methodological)**, v. 10, n. 2, p. 243-251, 1948.
- MOTTALEB, Khondoker Abdul; KRUPNIK, Timothy J.; ERENSTEIN, Olaf. Factors associated with small-scale agricultural machinery adoption in Bangladesh: Census findings. **Journal of rural studies**, v. 46, p. 155-168, 2016.
- OLSON, Mancur. Space, agriculture, and organization. **American Journal of Agricultural Economics**, v. 67, n. 5, p. 928-937, 1985.
- PETRICK, Martin. Farm investment, credit rationing, and governmentally promoted credit access in Poland: a cross-sectional analysis. **Food policy**, v. 29, n. 3, p. 275-294, 2004.
- REZENDE, Gervásio Castro de. Labor, land and agricultural credit policies and their adverse impacts on poverty in Brazil. **Instituto de Pesquisa Econômica Aplicada (Ipea)**. 2015.
- ROBERTS, Michael J.; KEY, Nigel. Agricultural payments and land concentration: a semiparametric spatial regression analysis. **American Journal of Agricultural Economics**, v. 90, n. 3, p. 627-643, 2008.
- SOUZA, Priscila; SANT'ANNA, André; MACHADO, Luciano; INTROPIDI, Barbara; VOGT, Pedro. Rural Investment: BNDES Credit Contributes to Agricultural Intensification. **Climate Policy Initiative**, 2022.
- VON THÜNEN, Johann Heinrich. Der isolierte staat in beziehung auf landwirtschaft und nationalökonomie. **Walter de Gruyter GmbH & Co KG**, 2022.
- WILLIAMS, James W. Feeding finance: a critical account of the shifting relationships between finance, food and farming. **Economy and Society**, v. 43, n. 3, p. 401-431, 2014.
- ZHENGFEI, Guan; LANSINK, Alfons Oude. The source of productivity growth in Dutch agriculture: A perspective from finance. **American journal of agricultural economics**, v. 88, n. 3, p. 644-656, 2006.