
CONVERGÊNCIA E DIVERGÊNCIA DA PRODUTIVIDADE AGROPECUÁRIA DO NORDESTE BRASILEIRO: UMA ANÁLISE CONSIDERANDO O MATOPIBA¹

Convergence and divergence of agricultural and ranching productivity in Northeastern Brazil: an analysis considering Matopiba

Luzia Aparecida Antunes

Economista. Doutoranda em Economia Aplicada pelo Programa de Pós-Graduação em Economia Aplicada da Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo. Av. Pádua Dias 11, Caixa Postal 9, 13418-900, Piracicaba, São Paulo. luziantunes@usp.br.

Raphael José Pereira Freitas

Economista. Doutor em Economia pelo Programa de Pós-Graduação em Economia da Universidade de Brasília. Campus Darcy Ribeiro, Asa Norte, 70910-900, Brasília, Distrito Federal. rjp_freitas@hotmail.com.

Resumo: Diante da idiosincrasia da produtividade agropecuária das regiões brasileiras, este trabalho se propõe a analisar a Região do Nordeste brasileiro, que apresenta mudanças significativas desde o início de sua formação econômica. A principal motivação para o desenvolvimento do estudo é o fato de que a Região Nordeste, embora apresente diversos problemas que acarretam empecilhos para o desenvolvimento agropecuário, possui áreas de alto desempenho, como o Matopiba. Considerando isso, procura-se identificar se há convergência da produtividade agropecuária entre as microrregiões nordestinas entre 1995 e 2017. Para tal, será utilizada a Econometria Espacial, e serão considerados regimes espaciais. Os resultados sugerem que, mesmo a Região Nordeste sendo considerada por parte da literatura como de baixa produtividade agropecuária, há discrepâncias entre suas próprias microrregiões. Identifica-se um processo de convergência entre as microrregiões localizadas nos estados que pertencem ao Matopiba, ao passo que, fora do Matopiba, as microrregiões nordestinas não apresentam um processo de convergência. Já para a Região do Nordeste como um todo, não se pode confirmar a hipótese de convergência. Dentre as variáveis que causam impacto no processo de convergência, o número de tratores por hectares e a precipitação mostraram-se positivos e significativos.

Palavras-chave: eficiência, Brasil, alimentos, simulação, estatística.

Abstract: Given the idiosyncrasies of agricultural and ranching productivity in Brazilian regions, this study aims to analyze the Northeast Region of Brazil, which has undergone significant changes since the beginning of its economic development. The main motivation for the study is the fact that, although the Northeast has a few problems that hinder agricultural development, it still has high-performance areas, such as Matopiba. The aim is to identify whether there is convergence in agricultural and ranching productivity between the northeastern micro-regions spanning from 1995 to 2017. To this end, Spatial Econometrics will be used, and spatial regimes will be considered. The results suggest that even though the Northeast is considered by some of the literature to have low agricultural and ranching productivity, there are discrepancies between its own micro-regions. There is a process of convergence between the micro-regions located in the states that belong to Matopiba, while outside Matopiba, the Northeastern micro-regions do not show a process of convergence. The hypothesis of convergence cannot be confirmed for the Northeast as a whole. Among the variables that have an impact on the convergence process, the number of tractors per hectare and rainfall were positive and significant.

Keywords: efficiency, Brazil, food, simulation, statistics.

¹ Os autores agradecem o apoio financeiro da CAPES, assim como as valiosas sugestões e revisões da equipe editorial da REN.

1 INTRODUÇÃO

A partir da década de 1960, o Brasil passou por um processo de modernização agropecuária com crescimento da Produtividade Total dos Fatores (PTF), intensificado entre 2000 e 2012. Esse avanço foi desigual, com o Nordeste destacando-se negativamente, devido ao uso de técnicas obsoletas e baixa produtividade (Gasques *et al.*, 2004). A região do Matopiba, formada pela Bahia, Maranhão, Piauí e Tocantins, ganhou destaque desde 1980, especialmente na produção de grãos como soja e milho, devido às suas condições ambientais favoráveis.

A produtividade agropecuária é mensurada por índices como a PTF, Produtividade Parcial dos Fatores (PPF), Produtividade Parcial da Terra (PPT) e a produtividade por valor adicionado (PT). A PTF captura mudanças tecnológicas, enquanto a PPF avalia a variação de um produto com a mudança de um único insumo (Gasques *et al.*, 2004). A PPT relaciona produção com terra utilizada, e a PT calcula a produtividade baseada nos valores da produção e consumo intermediário (Felema *et al.*, 2013, Avillez, 2017).

A análise da produtividade ao longo do tempo permite identificar convergência, que indica a redução das diferenças de produtividade entre regiões. Existem dois tipos de convergência: absoluta, que verifica se a produtividade converge para um valor estacionário, e condicional, que considera as diferenças estruturais de cada região ou país.

Estudos sobre convergência em agropecuária incluem Baumol (1986), que analisou a produtividade nos EUA, Ball, Hallahan e Nehring (2004), que observaram a PTF nos EUA, e Raiher *et al.* (2016), que identificaram convergência na produtividade do Sul do Brasil. Fochezatto e Stülp (2008) e Castelar *et al.* (2009) investigaram a convergência da produtividade no Brasil, enquanto Almeida e Barreto (2009) estudaram os efeitos dos investimentos em pesquisa agropecuária. Linhares e Penna (2013) discutiram a contradição nos testes de convergência do PIB agropecuário.

Nesse contexto, a presente pesquisa visa testar a hipótese de convergência da agropecuária entre as microrregiões do Nordeste. Destaca-se, adicionalmente, que o território se divide em quatro sub-regiões naturais: i) meio-norte; ii) sertão; iii) agreste; e iv) zona da mata. É importante salientar também que a maior parte do espaço da Região, cerca de 65%, encontra-se no semiárido brasileiro. Ademais, dentre as idiossincrasias predominantes no meio rural nordestino, podem ser destacadas: i) a pluviosidade baixa e irregular, em que há ocorrência comum de secas; ii) as altas temperaturas associadas às altas taxas de evapotranspiração; iii) os solos com pouca permeabilidade e mais sujeitos à erosão; e iv) a predominância da vegetação da Caatinga.

Feito este preâmbulo, este trabalho busca verificar a importância da agropecuária para o Nordeste. Mais especificamente, a pergunta que se faz é: há convergência absoluta e condicional da produtividade agropecuária para as microrregiões do Nordeste entre os anos de 1995 e 2017? Para tal, será utilizada a Econometria Espacial e regimes espaciais para se agregar a região dos estados do Matopiba e fora da região do Matopiba no período. Serão considerados na análise apenas os estados que pertencem à Região Nordeste — Maranhão, Piauí e Bahia.

2 Abordagem Econométrica e Dados

Novamente, a agropecuária é um setor de suma importância para a economia brasileira. Essa relação entre agropecuária e Brasil se torna ainda mais evidente quando se observa a Região do Nordeste do Brasil. É notória a predominância de propriedades consideradas da agricultura familiar, em que há emprego de mais de 80% da mão de obra rural da região nordestina. Além disso, a Região conta com uma área de mais de 1,5 milhões de km² e mais de 57 milhões de habitantes. A Região engloba nove estados: Alagoas, Bahia, Ceará, Maranhão, Paraíba, Piauí, Pernambuco, Rio Grande do Norte e Sergipe (IBGE, 1995, 2017, 2018, 2020).

Desse modo, é de suma importância identificar a magnitude da relação espacial da produtividade agropecuária na Região do Nordeste e, adicionalmente, analisar os resultados obtidos, verificando a hi-

pótese de um processo de convergência da produtividade agropecuária. Em consonância, esse processo será realizado nos próximos passos.

2.1 Análise exploratória de dados espaciais

A agropecuária está intrinsecamente ligada ao ambiente em que ocorre, refletindo uma dependência em relação a fatores climáticos, à estrutura local, às distâncias entre fazendas e indústrias, e aos locais de escoamento da produção. Além disso, surge uma interdependência entre produtores, em que eventos como pragas ou melhorias na produção podem se propagar para além das fronteiras de uma fazenda, afetando fazendeiros vizinhos do município e até mesmo fazendeiros de outros municípios. Esse fenômeno, conhecido como dependência espacial, é importante e deve ser observado em avaliações que tratem do setor. Para isso, utiliza-se a Análise Exploratória de Dados Espaciais (AEDE).

A AEDE é um conjunto de ferramentas empregadas para identificar a presença de dependência espacial em uma variável, no caso, a produtividade agropecuária entre as microrregiões nordestinas (Almeida, 2012, Raiher *et al.*, 2016). A dependência espacial é analisada por meio do de Moran Global e Local. O primeiro indica se há dependência espacial em uma variável entre regiões vizinhas, enquanto o segundo fornece um valor de de Moran específico para cada microrregião, possibilitando a identificação de *clusters*, isto é, concentrações de microrregiões com um determinado grau de de Moran.

Em relação ao conceito de vizinhança, a técnica utiliza matrizes de ponderação espacial, as quais buscam quantificar a proximidade entre as microrregiões conforme algum critério. Matrizes do tipo torre, rainha e bispo referem-se às microrregiões que compartilham fronteiras, enquanto matrizes de k-vizinhos mais próximos são calculadas com base na distância entre elas.

A estatística I de Moran Global é expressa algebricamente pela equação 1:

$$I = \frac{n}{s_0} \frac{\sum_i \sum_j W_{ij} z_i z_j}{\sum_i z_i^2} \quad (1)$$

em que I é o Índice Moran; n é o número de microrregiões; Z são os valores da variável de interesse padronizada; W_z é o valor médio da variável de interesse padronizada nos vizinhos, definidos através de uma matriz de ponderação espacial W ; e S_0 é igual à operação $\sum_i \sum_j W_{ij}$ o que significa que todos os elementos da matriz de pesos devem ser somados. O valor esperado do I de Moran é de $-\frac{1}{n-1}$, isto é, esse valor é obtido caso não exista a presença de padrão espacial nos dados, indicando a ausência de dependência. Quando os valores obtidos são maiores do que o valor esperado, constata-se a presença de autocorrelação espacial positiva; quando os valores obtidos são menores do que o esperado, constata-se uma autocorrelação espacial negativa (Almeida, 2012).

O I de Moran Local revela um valor do I de Moran para cada microrregião, como supracitado. Desse modo, o Índice capta os padrões locais de autocorrelação espacial e é conhecido como *Local Indicator of Spatial Association* (LISA), podendo ser expresso pela Equação 2:

$$I_i = z_i \sum_{j=1}^j W_{ij} z_j \quad (2)$$

em que I é o Índice Moran; z_i é o valor padronizado da i -ésima microrregião; z_j é o valor padronizado da j -ésima microrregião; e W_{ij} são os valores médios da variável de interesse padronizada nos vizinhos, seguindo uma determinada matriz de ponderação.

Como resultado, tem-se quatro quadrantes, nos quais os valores são classificados como alto-alto (AA), alto-baixo (AB), baixo-alto (BA) e baixo-baixo (BB). Resultados do tipo AA (ou BB) significam que uma microrregião com elevada produtividade agropecuária (ou baixa produtividade) está rodeada por microrregiões com produtividades agropecuárias também elevadas (ou produtividades também baixas). Já um *cluster* espacial do tipo AB (ou BA) indica que uma microrregião com elevada produtividade agropecuária (ou baixa produtividade) está cercada por microrregiões com baixa produtividade agrope-

cuária (ou elevada produtividade) (Almeida, 2012).

2.2 Modelo empírico e variáveis

Para a estimação da convergência da produtividade agropecuária, faz-se o uso do modelo de convergência proposto por Barro e Sala-i-Martin (1997), com alteração da variável renda pela variável que capta a produtividade agropecuária. A Equação (3) apresenta o modelo de convergência absoluta da PT:

$$\ln \left(\frac{PT_{2017}}{PT_{1995}} \right) = \alpha + \beta \ln (PT_{1995}) + \epsilon \quad (3)$$

em que $\ln \left(\frac{PT_{2017}}{PT_{1995}} \right)$ é o logaritmo natural da razão entre a produtividade média entre os dois anos em análise, isto é, as produtividades agropecuárias em 2017 e em 1995; $\ln(PT_{1995})$ é o logaritmo natural da produtividade em 1995; e ϵ é o termo de erro. A variável $\left(\frac{PT_{2017}}{PT_{1995}} \right)$ recebeu uma transformação a fim de evitar os possíveis resultados negativos, sendo somada a um para depois ser logaritmizada.

Nesse modelo, caso ocorra a convergência da produtividade agropecuária, o coeficiente associado ao parâmetro β deve possuir um sinal negativo e ser estatisticamente significativo. Isso confirma a hipótese de que, com o decorrer dos anos, as diferenças entre as produtividades agropecuárias tendem a diminuir. Entretanto, nem sempre apenas o estado inicial do processo será determinante para a β convergência, uma vez que as características estruturais das localidades exercem influência sobre o desempenho agropecuário. Desse modo, o modelo a ser estimado é especificado através da Equação (4), baseada em Raiher *et al.* (2016).

$$\ln \left(\frac{PT_{2017}}{PT_{1995}} \right) = \alpha + \beta \ln (PT_{1995}) + \epsilon \quad (4)$$

A explicação da Equação (4) segue o mesmo raciocínio daquela dada para a Equação (3). No entanto, agora, adiciona-se a variável X , que representa a matriz de variáveis explicativas da produtividade e, conseqüentemente, da convergência. Por fim, λ representa o parâmetro que capta os impactos das variáveis explicativas sobre a β - convergência.

2.2.1 Modelos econométricos de controle de dependência espacial

A relação observada entre as unidades de corte transversal, isto é, a relação de uma variável de uma região com seus vizinhos, conhecida como dependência espacial, é verificada em diversos estudos. O espaço passou a ganhar cada vez mais atenção a partir das pesquisas geradas pela nova geografia econômica. A primeira teoria que determina o espaço como fator impactante é conhecida como Lei de Tobler, também tratada como a Primeira Lei da Geografia. Essa Lei estabelece a seguinte teoria: “tudo depende de todo o restante, porém o que está mais próximo depende mais do que aquilo que está mais distante”. Outro adendo que merece destaque é que a distância mencionada não se refere apenas à distância geográfica, mas também à distância econômica ou política (Almeida, 2012).

Assim, a dependência espacial mostra que o valor de uma variável de interesse em uma região recebe influência das mesmas variáveis observadas nas regiões consideradas vizinhas. Adicionalmente, há a possibilidade da influência das variáveis explicativas exógenas e, em algumas vezes, dos fatores que estão contidos no termo de erro dessas regiões próximas. Outro fenômeno que pode ocorrer quando se aborda o espaço é a heterogeneidade espacial, que foi denominada como a Segunda Lei da Geografia. A heterogeneidade espacial ocorre quando há instabilidade estrutural através das regiões. Nesse caso, as variáveis apresentam diferentes respostas que dependem da localidade em que se encontram. Isso significa dizer que as próprias características de uma localidade podem estar impactando o desempenho da variável de interesse. Por exemplo, para a agropecuária, pode-se citar o tipo de solo. Quando a dependência e a heterogeneidade ocorrem ao mesmo tempo, tem-se o que é chamado de imbricação na Econometria Espacial.

Com a confirmação da dependência espacial, o modelo ideal é um que controle essa dependência, isto é, que minimize as distorções causadas pela presença de dependência no espaço. O Modelo Clássico

de Regressão Linear não leva em consideração os efeitos que o espaço exerce sobre as variáveis. Isso justifica a necessidade da utilização de um modelo de controle de dependência espacial, que é encontrado na Econometria Espacial. As Equações (5) e (6) retratam o modelo espacial geral:

$$\ln\left(\frac{PT_{t+n}}{PT_n}\right) = \rho W\left(\frac{PT_{t+n}}{PT_n}\right) + \ln(PT_n)\beta_1 + X\beta_2 + WX_\tau + \zeta_h \quad (5)$$

$$\zeta_h = \lambda W\zeta_h + \epsilon \quad (6)$$

em que ρ é um vetor do coeficiente autorregressivo; $W\left(\frac{PT_{t+n}}{PT_n}\right)$ é um vetor de defasagens espaciais para a variável dependente; $\ln(PT_n)$ é o logaritmo natural da produtividade no período inicial para cada microrregião; β_1 e β_2 são os vetores dos parâmetros que serão estimados; WX é o vetor de defasagem das variáveis explicativas; τ é o vetor ($K - 1$ por 1) do coeficiente autorregressivo das variáveis explicativas; ζ_h é um vetor dos termos de erro; ζ_h é o parâmetro do erro autorregressivo espacial; $W\zeta_h$ e ϵ são os erros defasados espacialmente.

Almeida (2012) mostra que a partir do modelo geral, deve-se observar o comportamento dos parâmetros. Quando as Equações (5) e (6) apresentam valores de τ e de λ iguais a zero, e um valor de ρ diferente de zero, o modelo a ser considerado seria o modelo de Defasagem Espacial (SAR). Nesse modelo, a variável dependente da região i repercute no valor da variável dependente da região j . Essa relação pode ser percebida na Equação (7):

$$\ln\left(\frac{PT_{t+n}}{PT_n}\right) = \rho W\left(\frac{PT_{t+n}}{PT_n}\right) + \ln(PT_n)\beta_1 + X\beta_2 + \epsilon \quad (7)$$

Quando as Equações (5) e (6) apresentam os valores dos parâmetros τ e λ iguais a zero, e o valor do parâmetro ρ diferente de zero, tem-se o Modelo de Erro Autorregressivo Espacial (SEM). Nesse modelo, a autocorrelação das regiões é encontrada no termo de erro. Isso significa que o erro da região i reverberará no crescimento da produtividade da região j , e vice-versa. O erro da região refere-se a fatores que não estão contidos no modelo, isto é, variáveis não especificadas, como, por exemplo, a introdução de novas técnicas para a produção de um bem. O SEM é representado pelas Equações (8) e (9):

$$\ln\left(\frac{PT_{t+n}}{PT_n}\right) = \ln(PT_n)\beta_1 + X\beta_2 + \zeta \quad (8)$$

$$\zeta = \lambda W\zeta + \epsilon \quad (9)$$

em que ζ_h é um vetor dos termos de erro; $W\zeta_h$ são os erros defasados espaciais; e λ é o vetor do parâmetro do erro autorregressivo espacial.

Partindo novamente do modelo espacial geral [Equações (5) e (6)], quando se encontra um λ igual a zero, e ρ e τ diferentes de zero, o modelo a ser estimado será um Modelo de Durbin Espacial (SDM). No SDM, incorpora-se o transbordamento por meio da defasagem das variáveis independentes, além da defasagem da variável endógena. Esse modelo pode ser representado pela Equação (10):

$$\ln\left(\frac{PT_{t+n}}{PT_n}\right) = \rho W\left(\frac{PT_{t+n}}{PT_n}\right) + \ln(PT_n)\beta_1 + \ln X\beta_2 + W(\ln X)_\tau + \epsilon \quad (10)$$

Novamente, ao retornar às Equações (5) e (6), quando se observam ρ igual a zero, e τ e λ diferentes de zero, o modelo a ser estimado é o Modelo de Durbin Espacial do Erro (SDEM). Nesse modelo, os transbordamentos espaciais de alcance local nas variáveis explicativas são captados, além do transbordamento espacial global contido no termo de erro. O SDEM pode ser representado pelas Equações (11) e (12):

$$\ln\left(\frac{PT_{t+n}}{PT_n}\right) = \ln(PT_n)\beta_1 + \ln X\beta_2 + W(\ln X)_\tau + \zeta \quad (11)$$

$$\zeta = \lambda W\zeta + \epsilon \quad (12)$$

Já o modelo Regressivo Cruzado Espacial (SLX) é obtido quando se tem valores para ρ e λ iguais a zero, e o valor de τ é diferente de zero, nas Equações (5) e (6). Nesse modelo, considera-se que todas as variáveis contidas na matriz podem transbordar espacialmente. Sua representação pode ser observada na Equação (13):

$$\ln\left(\frac{PT_{t+n}}{PT_n}\right) = \ln(P T_n) \beta_1 + \ln X \beta_2 + W(\ln X)_{\tau} + \epsilon \quad (13)$$

Por fim, para casos em que os valores para ρ , τ e λ são iguais a zero nas Equações (5) e (6), o melhor modelo a ser considerado é o modelo de Mínimos Quadrados Ordinários (MQO). Neste trabalho, serão testados todos os modelos descritos acima: SAR, SEM, SDM, SDEM e SLX. A escolha do modelo que melhor controla a dependência espacial é baseada nas Equações (14) e (15), além da avaliação da autocorrelação dos resíduos:

$$AIC = -2LIK + 2K \quad (14)$$

$$SC = -2LIK + K \ln n \quad (15)$$

em que LIK é referente ao valor da função de verossimilhança; k é o número de parâmetros contidos no modelo; e n é o número de observações.

Para avaliar os critérios de Akaike (AIC) e de Schwartz (SC), deve-se considerar que quanto menor o valor encontrado no critério, melhor será o modelo. Quando se tem uma amostra com mais de oito observações, o SC penaliza os modelos que contêm mais parâmetros do que o AIC . Todas as equações apresentadas aqui, juntamente com suas respectivas definições, podem ser encontradas em Almeida (2012).

2.2.2 Teste de Chow Espacial

Posto que se pretende considerar a possibilidade de estimação por regimes espaciais, Almeida (2012) argumenta que se deve realizar o teste de Chow Espacial. A análise, por meio do uso de regimes espaciais, busca controlar questões relacionadas às características dos locais. Como supracitado, esse fenômeno é chamado de heterogeneidade. O teste de Chow Espacial é baseado na comparação da soma dos quadrados dos resíduos de uma regressão, com a utilização de todo o conjunto de dados. É importante destacar que, nesse caso, o conjunto de dados é dividido em subamostras. O teste de Chow Espacial é dado pela Equação (16):

$$Ch = \left\{ \frac{\frac{e'_{re} - e'_{ir} e_{ir}}{k}}{n - 2k} \right\} \quad (16)$$

em que e_{re} é o resíduo por MQO do modelo restrito na subamostra; e e_{ir} é o resíduo do modelo irrestrito com toda a amostra.

A ideia do teste de Chow Espacial é que, se ele for estatisticamente significativo, rejeita-se a hipótese de uma regressão com todos os dados conjuntamente, em detrimento de uma regressão com distintos regimes espaciais. Isso significa que será estimada uma equação de convergência para um grupo de microrregiões, de acordo com seu desempenho agropecuário. Em caso de confirmação da utilização dos regimes, o modelo a ser utilizado é descrito pela Equação (17):

$$\begin{bmatrix} \ln\left(\frac{PT_{2017,M}}{PT_{1995,M}}\right) \\ \ln\left(\frac{PT_{2017,O}}{PT_{1995,O}}\right) \end{bmatrix} = \begin{bmatrix} \ln PT_{1995,M} & 0 \\ 0 & \ln PT_{1995,O} \end{bmatrix} \begin{bmatrix} \beta_{1,M} & 0 \\ 0 & \beta_{2,O} \end{bmatrix} + \begin{bmatrix} \ln X_M & 0 \\ 0 & \ln X_O \end{bmatrix} \begin{bmatrix} \beta_{2,M} & 0 \\ 0 & \beta_{2,O} \end{bmatrix} + \begin{bmatrix} \epsilon_M \\ \epsilon_O \end{bmatrix} \quad (17)$$

2.2.3 Variáveis utilizadas no modelo

A variável dependente utilizada na estimação do modelo de convergência da produtividade agropecuária foi derivada dos trabalhos de Felema, Ferreira e Raiher (2013) e Raiher *et al.* (2016). A escolha da variável PT para a estimação baseou-se no seu emprego em diversos estudos que tratam do cálculo da produtividade agropecuária, tais como os supracitados. A variável é obtida a partir das formulações das Equações (18) e (19):

$$VA_i = VBP_i - CI_i \quad (18)$$

$$PT_i = \frac{VA_i}{ATE_i} \quad (19)$$

A partir da Equação (18), calculou-se o Valor Agregado para cada microrregião (VA_i), subtraindo-se os Custos Intermediários (CI_i) do Valor Bruto da Produção (VBP_i). Após esse cálculo, obtém-se a produtividade através da razão entre o VA_i e a Área Total Explorada (ATE_i). O valor encontrado dessa razão é a Produtividade Agropecuária da microrregião i (PT_i).

Os dados utilizados para o cálculo da produtividade agropecuária nesta pesquisa foram coletados do Censo Agropecuário, divulgados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) para os anos de 1995 e 2017. Para o cálculo do valor agregado, foram utilizados os valores das produções totais dos animais e vegetais. No caso dos animais, inclui-se o valor da produção de animais de pequeno, médio e grande porte, e aves. Já para os vegetais, consideram-se lavouras permanentes e temporárias, horticultura, floricultura, silvicultura e extração vegetal. Os custos considerados abrangem valores de adubos e corretivos de solo, sementes e mudas, agrotóxicos, alimentação dos animais, medicamentos para animais, aluguel de máquinas e equipamentos, transporte da produção, combustíveis e lubrificantes, gastos com energia elétrica, ovos fertilizados e pintos de um dia, e sacarias e outras embalagens.

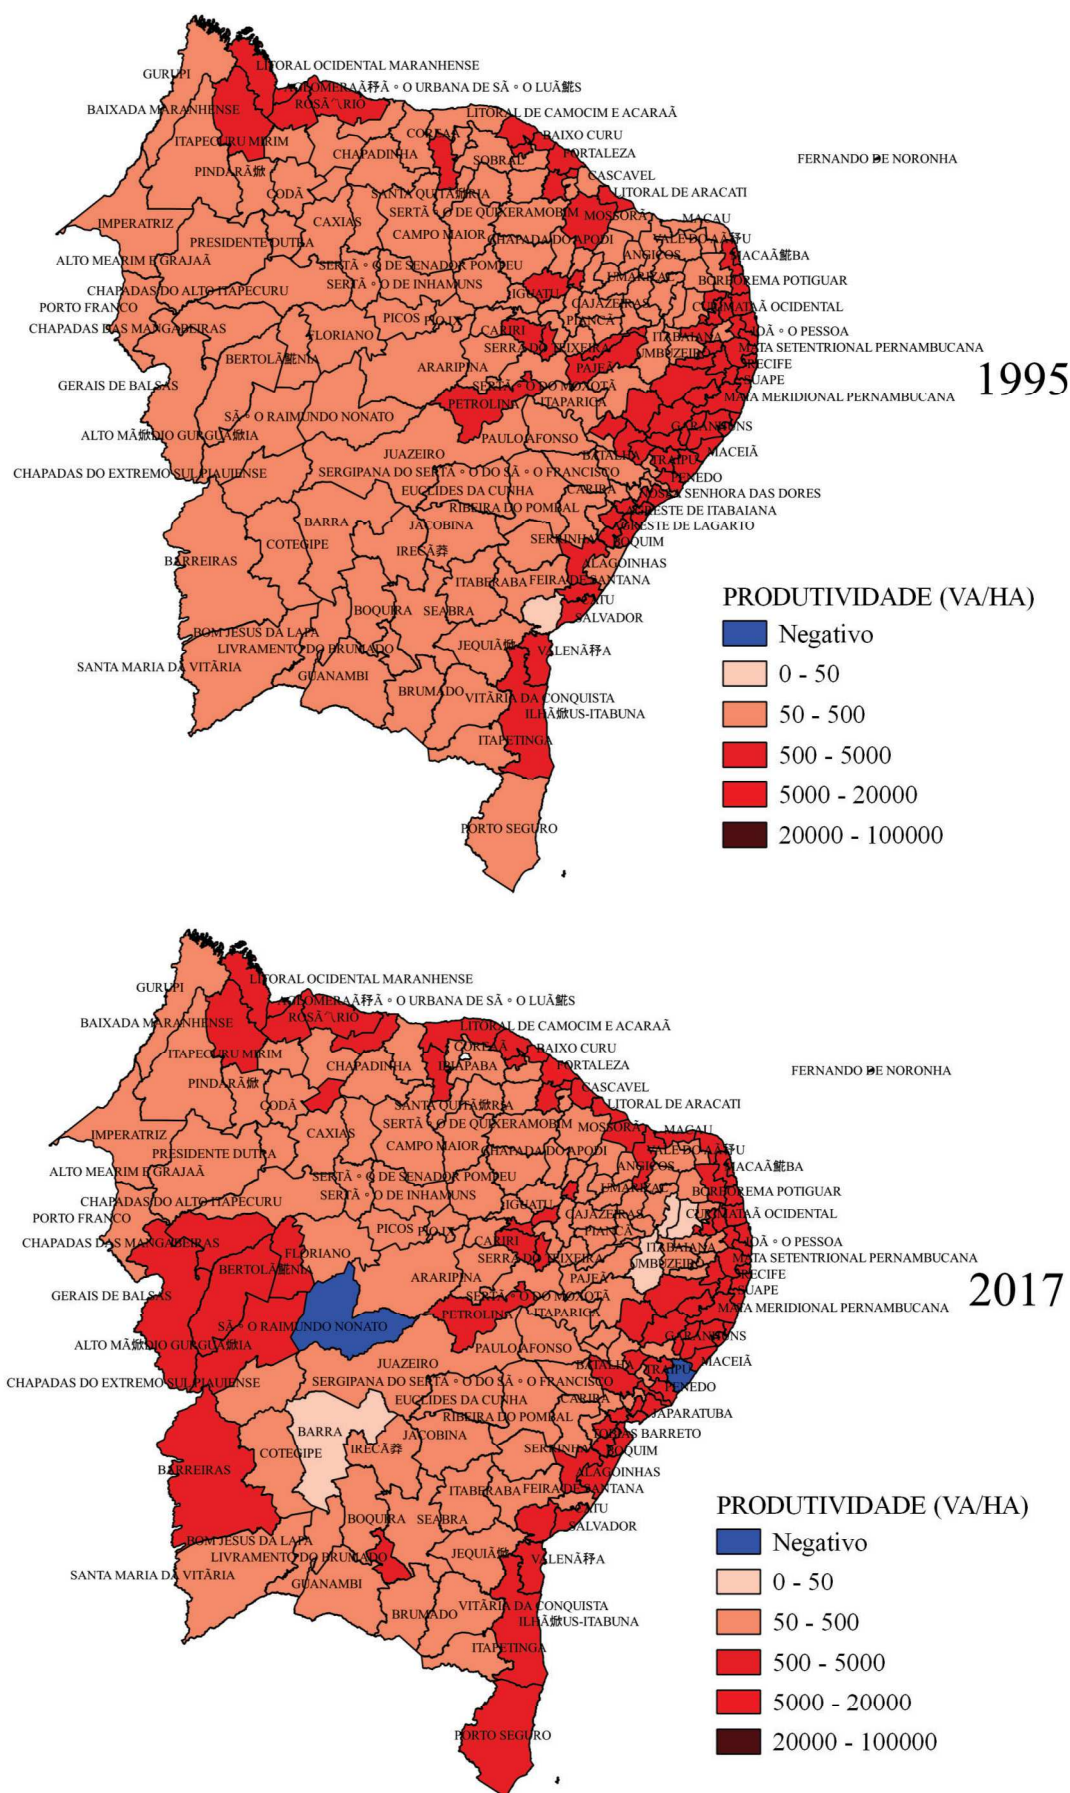
A área considerada engloba o total de área explorada menos os hectares de área considerados como terras inaproveitáveis. Além disso, matas e/ou florestas naturais são destinadas à preservação permanente ou são reservas legais e terras inaproveitáveis. A matriz de variáveis explicativas é composta pela proporção de estabelecimentos com irrigação (IR), proporção de estabelecimentos com algum tipo de conservação de solo (SL), proporção de estabelecimentos que receberam assistência técnica (AT) e a quantidade de trabalhadores por hectare (TR). Para esta última variável, foi efetuado o cálculo de equivalente-homem, baseado em Hoffmann *et al.* (1985). O número de tratores por hectare, medido por cavalo-vapor (TT), disponibilidade de crédito por hectare (CR) e índice de Gini da Terra (GT) referem-se ao ano de 2017 e foram coletados do Censo Agropecuário 2017, disponibilizado pelo IBGE. O GT foi fornecido por e-mail pelo IBGE. Além disso, as informações de temperatura e precipitação foram coletadas do Instituto Nacional de Meteorologia e interpoladas no espaço para gerar um valor para cada microrregião.

Por fim, todas as variáveis monetárias utilizadas nesta pesquisa foram inflacionadas utilizando o índice IGP-DI, com 2017 como ano base. Os dados utilizados referem-se a 188 microrregiões nordestinas. Não houve necessidade de realizar nenhuma correção de áreas mínimas comparáveis, visto que no período abordado pela pesquisa, 1995-2017, não houve criação nem destruição de nenhuma microrregião, e todas as variáveis estão logaritmizadas para maior simplificação das análises. O embasamento teórico sobre a escolha das variáveis é verificado em Pavan (2013), Raiher *et al.* (2016) e Murtaza e Masood (2020).

3 RESULTADOS

Nesta seção, apresentam-se os resultados obtidos para a produtividade agropecuária do Nordeste, nos quais se observam diferentes desempenhos da produtividade agropecuária. Essas nuances podem ser explicadas por fatores estruturais e climáticos, e até mesmo por questões relacionadas à qualificação da mão de obra, conforme argumenta Furtado (2009). A distribuição espacial da produtividade agropecuária entre 1995 e 2017 entre as microrregiões do Nordeste, retratada na Figura 1, corrobora esse cenário.

Figura 1 – Distribuição espacial da produtividade agropecuária: microrregiões do Nordeste brasileiro (anos 1995 e 2017)



Fonte: Mapas gerados a partir das análises espaciais efetuadas.

Verifica-se que as microrregiões mais produtivas se encontram no litoral nordestino. A região do litoral do Nordeste lidera na produção de banana, com 34% da produção nacional, e mandioca, com 34,7% da produção brasileira. Também é a segunda região que mais produz arroz, além de se destacar na produção de frutas. No entanto, apesar de observarem-se maiores produtividades no litoral nordestino, o estado de Sergipe, por exemplo, apresenta 73,6% de sua área suscetível à desertificação. Essa área equivale a 48 municípios do estado. Em abril de 2017, 29 municípios haviam decretado estado de emergência devido à seca. No mesmo ano, quatro microrregiões localizadas no centro-oeste do Nordeste apresentaram desempenho insatisfatório: i) Aracaju; ii) Meruoca; iii) São Miguel dos Campos; e iv) São Raimundo Nonato. Esse baixo desempenho pode ser atribuído aos problemas ambientais que a região centro-oeste do Nordeste enfrenta, como a escassez de chuvas (Rocha, 2017).

A Figura 1 também mostra que as microrregiões produtivas estão próximas de outras microrregiões produtivas. Isso indica a possibilidade de existir algum tipo de autocorrelação no espaço da produtividade agropecuária entre as microrregiões nordestinas nos anos de 1995 e 2017. Para verificar essa hipótese, calculou-se o *I* de Moran Global Univariado, cujos resultados podem ser conferidos na Tabela 1.

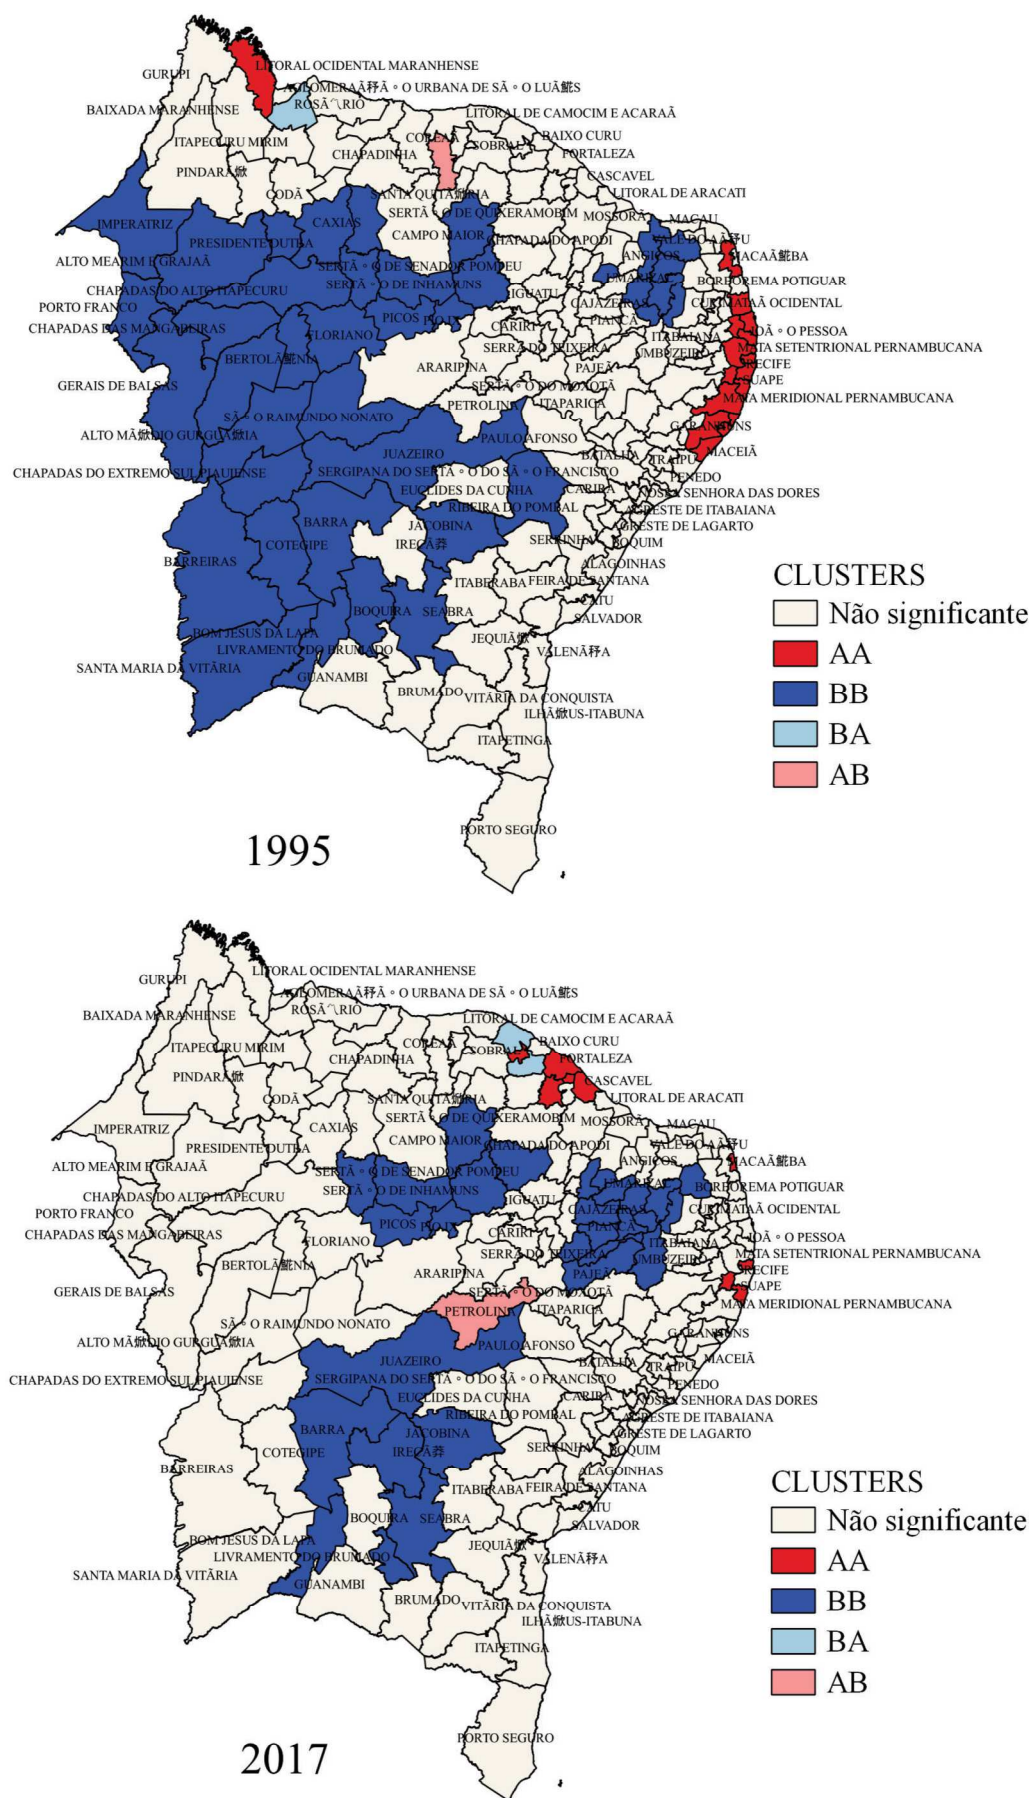
Tabela 1 – *I* de Moran Global da produtividade agropecuária: Nordeste brasileiro (anos 1995 e 2017)

Matriz	1995	2017
Rainha	0,149	0,272
Torre	0,149	0,272
4 vizinhos	0,136	0,038
5 vizinhos	0,126	0,035
7 vizinhos	0,099	0,023

Fonte: Análises espaciais efetuadas.

Os valores do *I* de Moran para os anos de 1995 e 2017 foram positivos e estatisticamente significativos a 1%. Isso indica a presença de autocorrelação espacial positiva, sugerindo que as microrregiões nordestinas que apresentam alta (baixa) produtividade são vizinhas de outras microrregiões nordestinas com características semelhantes. Dessa forma, a proximidade geográfica influencia a semelhança nos níveis de produtividade. Dada a existência de autocorrelação espacial, o próximo passo consiste na construção do mapa de clusters LISA. O objetivo é verificar a possível formação de clusters de produtividade, representando grupos de microrregiões com produtividades baixas ou altas. Essa relação pode ser visualizada na Figura 2.

Figura 2 – Mapa de *clusters* LISA da produtividade total: Nordeste brasileiro (anos 1995 e 2017)

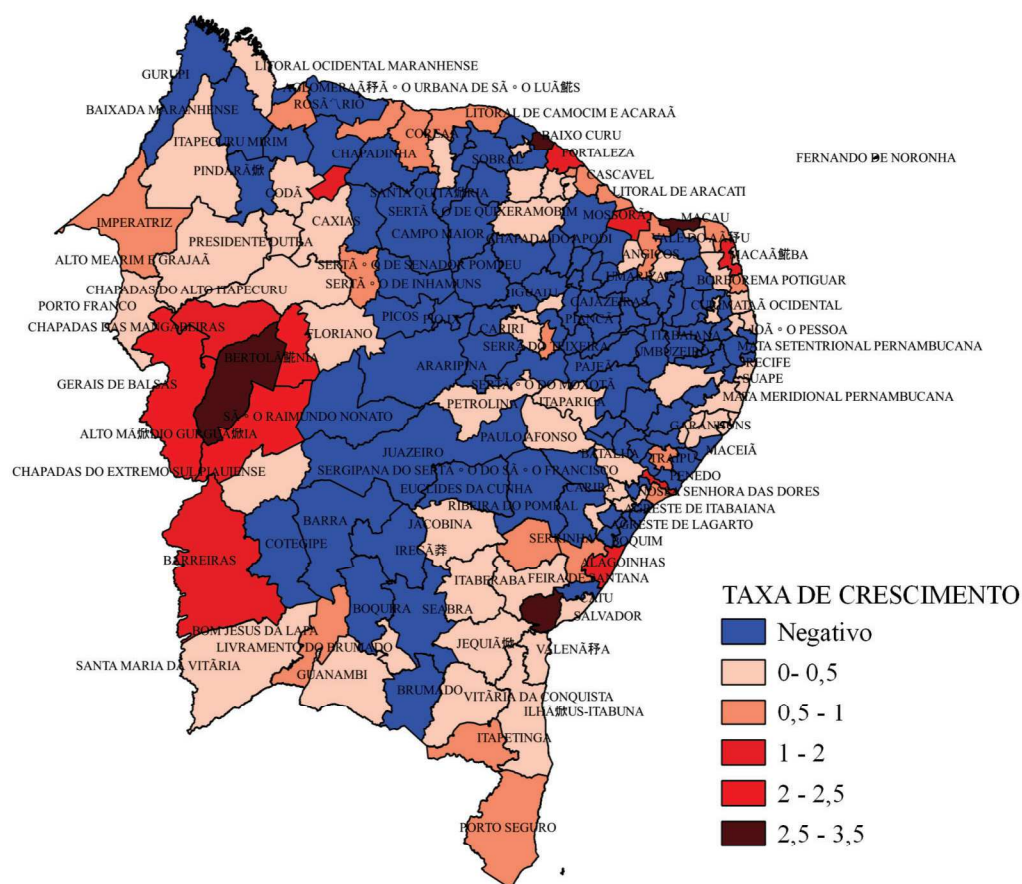


Fonte: Mapas gerados a partir das análises espaciais efetuadas.

Nota: 999 permutações.

A Figura 2 foi criada com base na matriz rainha, que apresentou o maior valor e significância em seu de Moran. É notório que a maior parte do Nordeste apresentou *clusters* do tipo BB em 1995. Já em 2017, o número de microrregiões que pertenciam ao *cluster* BB era menor. Os *clusters* do tipo AA estavam presentes apenas em dois pontos em 1995, enquanto em 2017 sua significância geográfica se reduziu ainda mais. Esses primeiros resultados sugerem que as produções se tornaram mais homogêneas ao longo dos anos. Em continuidade com essa análise, a Figura 3 retrata a distribuição espacial da taxa de crescimento da produtividade agropecuária entre 1995 e 2017 para as microrregiões nordestinas.

Figura 3 – Distribuição espacial da taxa de crescimento da produtividade agropecuária do Nordeste brasileiro (1995-2017)



Fonte: Mapa gerado a partir das análises espaciais efetuadas.

Nota: 999 permutações.

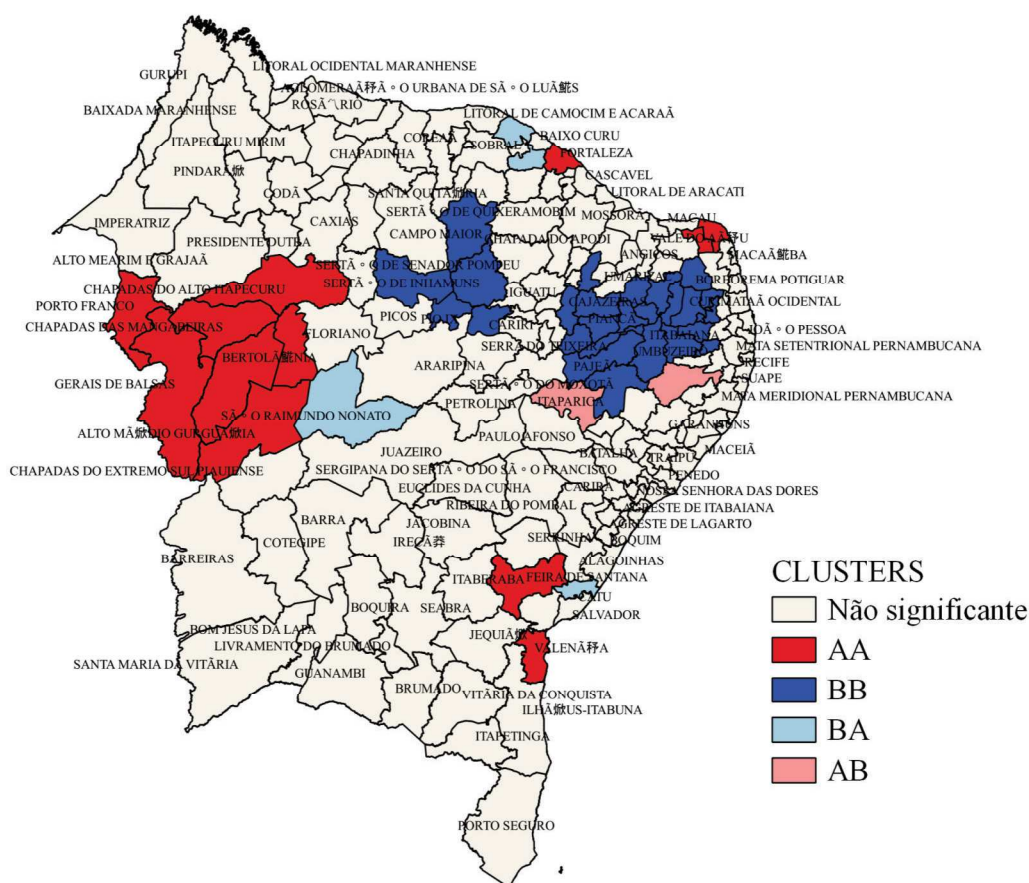
A Figura 3 mostra que muitas microrregiões da Região do Nordeste brasileiro apresentaram taxas de crescimento negativas, entre 1995 e 2017. Novamente, tanto fatores climáticos quanto a concentração de terras contribuem negativamente para a produtividade observada. A maior parte dos agricultores é considerada familiar e, portanto, possui uma pequena parcela das terras da região. Desse modo, a grande maioria das terras do local se concentra nas mãos de poucos produtores rurais. Além disso, observa-se que as microrregiões com altas taxas de crescimento de produtividade (baixas taxas de crescimento de produtividade) estão próximas de outras regiões com altas taxas de crescimento de produtividade (baixas taxas de crescimento de produtividade). Como forma de identificar se existe alguma relação espacial na taxa de crescimento da produtividade, calcula-se o *de* Moran Global Univariado da taxa de crescimento da produtividade agropecuária das microrregiões mencionadas entre 1995 e 2017, conforme apresentado na Tabela 2.

Tabela 2 – *I* de Moran da taxa de crescimento da produtividade agropecuária: Nordeste brasileiro (1995-2017)

Matriz	Valor
Rainha	0,116
Torre	0,117
4 vizinhos	0,119
5 vizinhos	0,099
7 vizinhos	0,091
10 vizinhos	0,082

Fonte: Análises espaciais efetuadas.

Os valores do *I* de Moran Global foram positivos e significativos a 1%, o que indica a ocorrência de autocorrelação espacial na taxa de crescimento da produtividade agropecuária. Isso significa dizer que uma microrregião com uma alta taxa de crescimento da produtividade está próxima de outra microrregião com uma alta taxa de crescimento da produtividade.

Figura 4 – Mapa de *clusters* LISA da taxa de crescimento da produtividade agropecuária do Nordeste brasileiro (1995-2017)

Fonte: Mapa gerado a partir das análises espaciais efetuadas.

Nota: 999 permutações.

Em consonância, a Figura 4 retrata o mapa de *clusters* LISA da taxa de crescimento da produtividade agropecuária da região nordestina, entre 1995 e 2017. Pode-se observar a existência de um *cluster* AA na região oeste do Nordeste e *cluster* do tipo BB nas regiões norte e leste do Nordeste. O *cluster* do tipo AA está localizado na região de Matopiba. Além disso, essa região é composta, no Nordeste brasileiro, pelos seguintes estados: i) Maranhão; ii) Piauí; e iii) Bahia.

Além da produtividade total apresentar taxas de crescimento positivas para a Região Nordeste, percebe-se que há certa suavização nos *clusters* com o decorrer dos anos. Desse modo, testou-se a hipótese de convergência da produtividade agropecuária entre as microrregiões do Nordeste, entre 1995 e 2017. A Tabela 3 retrata os resultados do modelo a-espacial de convergência absoluta da produtividade

agropecuária. Quando há comprovação da hipótese de convergência através do parâmetro α , o parâmetro apresenta um sinal negativo e é significativo. No entanto, a Tabela 3 mostra que, apesar do parâmetro apresentar um sinal negativo, ele não é estatisticamente significativo. Desse modo, não é possível afirmar que houve um processo de convergência da produtividade agropecuária entre as microrregiões nordestinas no período de 1995 a 2017. Visto que o I de Moran dos resíduos é positivo e estatisticamente significativo, há a necessidade de controle da dependência espacial. Portanto, os cinco tipos de modelos foram testados: i) SAR; ii) SEM; iii) SLX; iv) SDM; e v) SDEM. Na Tabela 3 estão representados também os resultados do modelo espacial que melhor efetuou o controle da dependência espacial.

Tabela 3 – Resultados econométricos da convergência absoluta para o Nordeste

Variáveis/Testes	MQO	SEM
α	0,6646* (0,4007)	0,8681 (0,8201)
β	-0,0968 (0,0654)	-0,1280 (0,1304)
λ	- -	0,5516*** (0,0728)
AIC	477,124	433,665
SC	0,0654	440,138
I de Moran	0,2372	-
Dos Resíduos	{0,0000}	-
Jarque-Bera	120,458 {0,0000}	- -
Breusch-Pagan	11,458 {0,0000}	- -
Koenker-Basset	4,483 {0,0000}	- -

Fonte: Análises espaciais efetuadas.

Notas: * significativo a 10%. Os valores entre parênteses correspondem ao desvio-padrão. Os valores entre chaves correspondem ao valor da probabilidade do teste. Estimado com base na matriz 4 vizinhos.

A Tabela 3 mostra o resultado da convergência para o modelo SEM, que apresentou os menores valores dos critérios de AIC e de SC , além do melhor controle da dependência espacial nos resíduos. Novamente, o modelo de convergência, já corrigido para heterocedasticidade e dependência espacial, não demonstrou um processo de convergência absoluta, uma vez que o parâmetro α não apresentou um valor significativo. Desse modo, não é possível afirmar que as diferenças de produtividade agropecuária entre as microrregiões do Nordeste estão diminuindo. Além disso, como observado nas figuras desta seção, algumas microrregiões da região nordestina não apresentam crescimento no período entre 1995 e 2017.

Nesse sentido, é interessante analisar as microrregiões separadamente, de acordo com seu nível de desempenho de produtividade agropecuária. Com esse pressuposto, esta pesquisa buscou dividir as estimações em dois regimes: i) um regime composto pelas 68 microrregiões que fazem parte dos estados do Matopiba localizados no Nordeste – Maranhão, Piauí, Bahia (M); e ii) um regime composto pelas 120 microrregiões que se localizam fora da região do Matopiba no Nordeste (O). A Tabela 4 retrata os resultados do teste de Chow Espacial para o modelo de convergência absoluta.

Tabela 4 – Teste de Chow Espacial e diagnóstico de dependência espacial do modelo econométrico não espacial e com regimes espaciais para convergência absoluta

Variáveis/Teses	Valor	Probabilidade
α	24,477	0,0000
β	20,766	0,0000
Teste Global	28,541	0,0000
I de Moran dos Resíduos	0,3525	0,0000

Fonte: Análises espaciais efetuadas.

O resultado do teste de Chow (Teste Global) apresentou significância estatística a 1%. Isso significa que há a necessidade da estimação de um modelo de convergência absoluta por regimes espaciais. Nesse sentido, a Tabela 5 reporta os resultados do modelo de convergência absoluta por regimes espaciais. Percebe-se que entre as microrregiões que estão localizadas fora dos estados da região do Matopiba, não se identificou um processo de convergência. Já entre as microrregiões que se localizam nos estados da região do Matopiba, houve um processo de convergência. Desse modo, as diferenças entre essas regiões tendem a diminuir ao longo do tempo, enquanto para as microrregiões fora dos estados do Matopiba, existe um processo de divergência da produtividade agropecuária pelo método MQO.

Tabela 5 – Resultados econométricos do modelo não espacial e espacial com regimes espaciais

Variáveis/Testes	MQO M	MQO O	SEM M	SEM O
α	2,6914*** (0,6262)	-1,3920** (0,5376)	3,0213*** (0,9781)	-1,4033 (1,1119)
β	-0,4280*** (0,1119)	0,2099** (0,0840)	-0,4900*** (0,1681)	0,2136 (0,1069)
λ	-	-	0,5182***	
	-	-	0,0619	
AIC	454,023		414,784	
SC	466,969		427,729	
Jarque-Bera	221,159 {0,0000}		-	-
Breusch-Pagan	16,079 {0,0011}		-	-
Koenker-Basset	4,920 {0,1778}		-	-

Fonte: Análises espaciais efetuadas.

Notas: *** significativo a 1%. Os valores entre parênteses correspondem ao desvio-padrão. Os valores entre chaves correspondem ao valor da probabilidade do teste. Estimado com base na matriz quatro vizinhos.

Por fim, como o I de Moran dos resíduos apresentou sinal positivo e significância estatística, os modelos espaciais para o controle da dependência espacial foram estimados. Merece destaque o controle da heterogeneidade espacial através dos regimes. Os modelos SAR, SEM, SLX, SDM e SDEM foram novamente testados. Os resultados estão na Tabela 5 e sugerem que o melhor modelo para essa análise é o modelo SEM.

O modelo confirmou novamente a existência de um processo de convergência apenas no grupo de microrregiões que pertencem aos estados da região do Matopiba. A repetição desse resultado corrobora que há uma tendência de homogeneização da produtividade nas microrregiões próximas ao Matopiba. O mesmo não é identificado nas regiões fora dos estados do Matopiba, já que não se percebe redução das diferenças com o decorrer do tempo. O parâmetro que capta a dependência espacial, λ , apresentou significância estatística e sinal positivo. Isso sugere que choques aleatórios de uma microrregião pertencente aos estados do Matopiba reverberam nas produtividades do grupo de microrregiões fora dos estados do Matopiba e vice-versa.

Como a hipótese de convergência absoluta para o grupo de microrregiões pertencentes aos estados do Matopiba foi confirmada, foi realizado o cálculo da velocidade e da meia-vida. Os resultados sugeriram que a velocidade da convergência é de 0,0292 e a meia-vida possui valor de 23,67. Isso indica que as microrregiões do Nordeste do Brasil que pertencem aos estados da região do Matopiba levaram cerca de 24 anos para alcançar a homogeneidade desse tipo específico de produtividade, considerando apenas a sua produtividade inicial.

3.1 Convergência condicional

Como já mencionado, diversos fatores podem exercer influências positivas ou negativas sobre o crescimento da produtividade e, consequentemente, sobre a sua convergência. Nesse sentido, testa-se a hipótese de convergência condicional. Para o modelo estimado por MQO para o Nordeste como um todo, a convergência foi identificada; o parâmetro que capta a convergência foi negativo e significativo a 5%. Dentre as variáveis explicativas, verifica-se significância na proporção de estabelecimentos com assistência técnica (AT) com sinal negativo. O número de trabalhadores por hectare (TR) e a precipitação

(P) apresentaram sinal positivo e significância a 1%. Como a dependência espacial foi evidenciada através do valor positivo e significativo do I de Moran, testaram-se os modelos de controle de dependência espacial SAR, SEM, SLX, SDM e SDEM. A Tabela 6 retrata os resultados para a estimação do modelo por MQO e do modelo SEM, que foi o que melhor controlou a dependência espacial.

Tabela 6 – Resultados econométricos não espacial e espacial da convergência condicional para o Nordeste

Variáveis/Testes	MQO	SEM
α	0,3363 (1,2793)	1,0485 (1,6914)
β	-0,1744** (0,0761)	-0,1546 (0,1219)
AT	-0,1433* (0,0749)	-0,1079* (0,0634)
CR	0,0048 (0,0245)	-0,0090 (0,0283)
GT	-1,0296 (0,8302)	-0,8954 (1,2455)
IR	0,0754 (0,0637)	0,0620 (0,0770)
SL	0,0234 (0,0476)	0,0385 (0,0479)
TR	0,5011*** (0,1821)	0,4808** (0,1693)
TT	0,0948 (0,0712)	0,0538 (0,0481)
P	4,5607*** (1,1234)	3,4015* (1,3033)
T	0,0046 (0,0403)	-0,0210 (0,0453)
λ	- -	0,4606*** (0,0872)
AIC	458,977	434,130
SC	494,578	469,731
I de Moran	0,3525	-
Dos Resíduos	{0,0000}	-
Jarque-Bera	102,959 {0,0000}	-
Breusch-Pagan	70,160 {0,0000}	-
Koenker-Basset	28,805 {0,0013}	-

Fonte: Análises espaciais efetuadas.

Notas: * significativo a 10%. Os valores entre parênteses correspondem ao desvio-padrão. Os valores entre chaves correspondem ao valor da probabilidade do teste. Estimado com base na matriz quatro vizinhos. Modelo SEM corrigido para heterocedasticidade e erros não normais.

Para o modelo de convergência com a dependência controlada através do SEM, o parâmetro que capta a convergência não se apresentou com significância, mas obteve o sinal esperado sendo negativo. Porém, observando as taxas de crescimento nas microrregiões nordestinas (Figura 3), identificam-se certas microrregiões que são produtivas e que apresentaram maior desempenho entre o período de análise. Desse modo, há indícios que esteja ocorrendo um processo de convergência condicional entre um grupo de microrregiões que seja mais intenso que no restante do Nordeste. Novamente, testa-se a necessidade de um modelo formulado por regimes espaciais para as microrregiões dos estados da região do Matopiba e fora dela. A Tabela 7 apresenta os resultados para o teste de Chow Espacial para identificar se isso é válido.

Tabela 7 – Teste de Chow Espacial e diagnóstico de dependência espacial do modelo econométrico para convergência condicional

Variáveis/Teses	Valor	Probabilidade
α	16,243	0,0001
β	39,344	0,0000
AS	0,248	0,6181
CR	3,299	0,0693
GT	4,335	0,0373
IR	0,754	0,3852
SL	0,382	0,5367
TR	1,244	0,2646
TT	0,938	0,3327
P	2,196	0,1383
T	3,490	0,0618
Teste Global	61,794	0,0000
<i>I</i> de Moran dos Resíduos	0,3575	0,0000

Fonte: Análises espaciais efetuadas.

O resultado do teste de Chow demonstrou a necessidade da estimação de um modelo considerando os regimes espaciais, através do seu valor de teste global altamente significativo. Assim, o processo de convergência foi novamente avaliado, mas agora considerando os regimes para microrregiões do Matopiba e fora do Matopiba. A Tabela 8 retrata os resultados para o modelo de regimes espaciais estimado por MQO e para o modelo que melhor controlou a dependência espacial, dado que o *I* de Moran dos resíduos foi positivo e significativo a 1%.

O modelo de convergência condicional estimado por regimes espaciais apresentou um processo de convergência condicional apenas para aquelas microrregiões que se encontram nos estados da região de Matopiba. Isso indica que ao longo do tempo, as diferenças de produtividade agropecuária tendem a diminuir nessas localidades e se aproximar de uma média do grupo. Dentre as variáveis que podem explicar tal processo, apenas o número de tratores por hectares e a precipitação foram significativas, ambas com sinal positivo. Desse modo, um maior número de trabalhadores por hectares e um maior nível de precipitação tendem a melhorar o desempenho agropecuário e, logo, impactar positivamente o processo de convergência.

Assim, pode-se concluir que entre aquelas microrregiões nordestinas que se localizam nos estados da região do Matopiba, isto é, em partes da nova fronteira agrícola do Brasil, o processo de convergência foi confirmado. Isso sugere que, apesar de existirem microrregiões com baixas produtividades no Nordeste, existem aquelas nas quais a produtividade é significativa. Em relação ao parâmetro que capta a dependência espacial, houve significância. Esse cenário implica que existe o transbordamento espacial das variáveis contidas no erro de um regime para o outro. Por exemplo, inovações tecnológicas aplicadas na região do Matopiba podem influenciar a produtividade da agropecuária das microrregiões fora dos estados do Matopiba, e tal impacto é positivo.

Como o processo de convergência condicional foi confirmado para as microrregiões localizadas nos estados da região do Matopiba, calcularam-se a velocidade e a meia-vida. A velocidade da convergência foi de 0,0442, enquanto a meia-vida ficou em cerca de 16 anos. Isso significa dizer que se levará 16 anos para que as microrregiões localizadas nos estados do Matopiba tenham produtividades próximas da média do grupo, isto é, 16 anos para diminuir as disparidades entre as produtividades agropecuárias.

Tabela 8 – Resultados econométricos do modelo não espacial e espacial com regimes espaciais

Variáveis/Testes	MQO M	MQO O	SEM M	SEM O
α	3,6829** (1,8457)	-6,3583*** (1,6734)	4,0350** (1,8453)	-5,3453 (1,6630)
β	-0,6769*** (0,1192)	0,3379*** (0,1093)	-0,6384*** (0,1107)	0,3183** (0,1047)
AS	-0,0103 (0,1477)	-0,0952 (0,0845)	0,0095 (0,1370)	-0,0964 (0,0874)
CR	-0,1142 (0,0762)	0,0313 (0,0246)	-0,0936 (0,0731)	0,0226 (0,0242)
GT	1,5517 (1,6042)	-2,2761** (0,8979)	1,4033 (1,4347)	-2,3587** (0,8569)
IR	0,1487 (0,1032)	0,0399 (0,0709)	0,1002 (0,0988)	0,0364 (0,0687)
SL	0,0212 (0,0774)	0,0818 (0,0603)	0,0113 (0,0724)	0,0805 (0,0571)
TR	0,3686 (0,30936)	0,7867*** (0,2115)	0,3608 (0,2981)	0,6760*** (0,1950)
TT	0,2039* (0,1058)	0,0735 (0,0830)	0,1774* (0,0949)	0,0642 (0,0752)
P	6,7794*** (1,8189)	3,2323** (1,5556)	6,0432*** (1,8302)	2,5018 (1,5350)
T	-0,0196 (0,0635)	0,1289*** (0,0478)	-0,0365 (0,0652)	0,1001** (0,0498)
λ		-		0,2907*** (0,0942)
AIC		421,484		412,794
SC		492,686		483,996
Jarque-Bera		253,564 (0,0000)		-
Breusch-Pagan		91,795 (0,0000)		-
Koenker-Basset		25,568 (0,2234)		-

Fonte: Análises espaciais efetuadas.

Notas: *** significativo a 1%. Os valores entre parênteses correspondem ao desvio-padrão. Os valores entre chaves correspondem ao valor da probabilidade do teste. Estimado com base na matriz quatro vizinhos.

Os resultados obtidos nesta análise da produtividade agropecuária no Nordeste entre 1995 e 2017 oferecem descobertas valiosas para o entendimento das dinâmicas espaciais e temporais nessa região. As descobertas de *clusters* de produtividade, evidenciadas pelos modelos de autocorrelação espacial e mapas de *clusters* LISA, revelam padrões interessantes de convergência e divergência entre as microrregiões nordestinas. Essas observações corroboram estudos anteriores sobre economia agrícola e regional, tais como os de Gasques *et al.* (2004), Vieira Filho (2013) e Andrade *et al.* (1989), que exploraram a relação entre variáveis agropecuárias, fatores espaciais e condições climáticas.

A identificação de um processo de - convergência condicional em microrregiões associadas à região do Matopiba ressalta a importância de considerar especificidades locais na análise da produtividade agropecuária. Além disso, nota-se uma sugestão de que fatores como o número de tratores por hectare e a precipitação desempenham papéis significativos nesse processo de convergência, alinhando-se com achados anteriores na literatura econômica. Essa conexão entre as descobertas deste estudo e a base teórica e empírica estabelecida pelos autores supracitados destaca a relevância desses resultados para o avanço do conhecimento nesse campo.

4 CONSIDERAÇÕES FINAIS

A agropecuária é de suma importância na composição econômica da Região do Nordeste brasileiro. Entretanto, diversos fatores edafoclimáticos contribuem negativamente para a produtividade da Região, tais como: i) altas temperaturas; ii) escassez de chuvas; e iii) solos arenosos e secos. É importante frisar, também, que existem diferentes graus de produtividade dentro da própria macrorregião. Observam-se microrregiões que apresentam níveis mais elevados de produtividade, tais como o litoral nordestino, onde se produz cana-de-açúcar, e os estados que compõem parte do Matopiba – Bahia, Maranhão e Piauí. Essa última hoje se apresenta como uma fronteira agrícola de grãos muito produtiva.

A produtividade agropecuária das microrregiões nordestinas apresentou autocorrelação espacial positiva, e houve certa diminuição dos clusters BB, que em 1995 eram maiores que em 2017. Isso indicava que mais microrregiões estavam com produtividades baixas em 1995. Desse modo, a hipótese de convergência absoluta e condicional da produtividade agropecuária para as microrregiões foi testada. Em um primeiro momento, não se pôde afirmar que há um processo de convergência tanto absoluta quanto condicional para todas as microrregiões nordestinas, visto pelo valor não significativo do seu parâmetro para o modelo final com controle da dependência espacial. Em seguida, a convergência foi testada para dois grupos diferentes de produtividade agropecuária: i) microrregiões localizadas nos estados que estão na região do Matopiba (M); e ii) microrregiões localizadas fora dos estados da região do Matopiba (O). No primeiro grupo, foi observado um processo de convergência tanto absoluto quanto condicional. Já no segundo grupo, o resultado não foi o mesmo. Isso significa dizer que nas microrregiões localizadas nos estados do Matopiba as diferenças de produtividade agropecuária tendem a diminuir com o decorrer dos anos.

Dentre as possíveis variáveis que impactam positivamente ou negativamente a produtividade agropecuária e, logo, sua convergência, apenas o número de tratores por hectares e a precipitação foram significativas. Assim, maiores números de tratores e maiores níveis de precipitação causam impactos positivos na produtividade e, logo, auxiliam no processo de convergência condicional da produtividade agropecuária. As demais variáveis explicativas não foram significativas.

Toda essa análise e os resultados obtidos servem como incentivos para projetos de políticas públicas. Mas dessa vez, o olhar não precisa ser somente sobre como aperfeiçoar a produtividade da Região Nordeste, mas também como maximizar a boa produtividade já existente em algumas localidades. Como sugestão para pesquisas futuras, seria interessante testar a convergência da produtividade agropecuária através de um modelo GWR, que verifique a hipótese de convergência para cada microrregião nordestina. Além disso, testes de convergência também seriam válidos. Salienta-se que uma das limitações da pesquisa é a relação de preços relativos, que pode impactar o cálculo da produtividade. Em outras palavras, as variáveis que compõem o custo intermediário podem sofrer quedas ou aumentos de preço, e esse comportamento pode influenciar a produtividade. Por exemplo, com quedas de preços, mas mantendo a produção, a produtividade tenderia a aumentar.

REFERÊNCIAS

ALMEIDA, E. S. **Econometria Espacial**. Campinas: Alínea, 2012.

ALMEIDA, E. S.; BARRETO, R. C. S. A contribuição da pesquisa para a convergência e crescimento da renda agropecuária no Brasil. **Revista de Economia e Sociologia Rural**, v. 47, n. 3, p. 719-737, 2009. DOI: <https://doi.org/10.1590/S0103-20032009000300009>.

ANDRADE, T. A.; BOISIER, S.; FERREIRA, C. M. C.; HADDAD, P. R. **Economia regional: teorias e métodos de análise**. Fortaleza: Etene, 1989.

AVILLEZ, F. **Produtividade, crescimento e rendimento agrícola em Portugal na última década.** Associação de Jovens Agricultores Micaelenses. 2017.

BALL, V. E.; HALLAHAN, C.; NEHRING, R. Convergence of productivity: an analysis of the catch-up hypothesis within a panel of states. **American Journal of Agricultural Economics**, v. 86, n. 5, p. 1315-1321, 2004. Disponível em: <https://www.jstor.org/stable/3697947>. Acesso em: 27 jun. 2021.

BARRO, R. J.; SALA-I-MARTIN, X. Technological diffusion, convergence, and growth. **Journal of Economic Growth**, v. 2, n. 1, p. 1-26, 1997. DOI: <https://doi.org/10.1023/A:1009746629269>.

BAUMOL, W. J. Productivity Growth, Convergence, and Welfare: What the Long-Run Data Show. **American Economic Review**, v. 76, n. 5, p. 1072-1085, 1986. Disponível em: <https://www.jstor.org/stable/1816469>. Acesso em: 13 jul. 2021.

CASTELAR, I.; DINIZ, E. B.; FERREIRA, R. T.; OLIVEIRA JÚNIOR, J. N. Determinação dos clubes de convergência da renda per capita agrícola: uma análise para os municípios cearenses. **Revista de Economia e Sociologia Rural**, v. 47, n. 4, p. 995-1021, 2009. DOI: <https://doi.org/10.1590/S0103-20032009000400009>.

FELEMA, J.; FERREIRA, C. R.; RAIHER, A. P. Agropecuária brasileira: desempenho regional e determinantes da produtividade. **Revista de Economia e Sociologia Rural**, v. 51, n. 3, p. 555-573, 2013. DOI: <https://doi.org/10.1590/S0103-20032013000300008>.

FOCHEZATTO, A.; STÜLP, V. J. Análise da convergência da produtividade da mão-de-obra agropecuária entre os estados brasileiros: aplicação de matrizes de Markov, 1990-2000. **Revista de Economia e Sociologia Rural**, v. 46, n. 3, p. 739-765, 2008. DOI: <https://doi.org/10.1590/S0103-20032008000300007>.

FURTADO, C. **Formação econômica do Brasil.** São Paulo: Companhia das Letras, 2009.

GASQUES, J. G.; BASTOS, E. T.; BACCHI, M. P. R.; CONCEIÇÃO, J. C. P. R. Condicionantes da produtividade da agropecuária brasileira. **Texto para discussão**, n. 1017. IPEA, 2004.

HOFFMANN, R.; CARVALHO, A. V.; KAGEYAMA, A. A.; WIENDL, M. L. T. B.; QUEDA, O. **Inovações tecnológicas e transformações recentes na agricultura brasileira.** Finep, 1985.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo agropecuário.** 1995. Disponível em: https://ftp.ibge.gov.br/Censo_Agropecuario/Censo_Agropecuario_1995_96/Brasil/. Acesso em: 12 jul. 2021.

_____. 2017. **Censo Agropecuário.** Disponível em: ftp://ftp.ibge.gov.br/Censo_Agropecuario/Censo_Agropecuario_2017/Resultados_Definitivos/plano_tabular_censoagro2017/xls/0_BR.zip. Acesso em: 12 jul. 2021.

_____. **Áreas dos municípios.** 2018. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estruturateritorial/15761-areas-dos-municipios.html?=&t=o-que-e>. Acesso em: 12 jul. 2021.

_____. **Estimativas da população**. 2020. Disponível em: https://ftp.ibge.gov.br/Estimativas_de_Populacao/Estimativas_2020/estimativas_dou_2020.xls. Acesso em: 12 jul. 2021.

LINHARES, E.; PENNA, C. Uma nota sobre “Teste da convergência do PIB per capita da agropecuária no Brasil”. **Revista de Economia e Sociologia Rural**, v. 51, n. 1, p. 91-104, 2013. DOI: <https://doi.org/10.1590/S0103-20032013000100005>.

MURTAZA, M.; MASOOD, T. Inter-district variations in agricultural productivity in India. **Agricultural Economics Research Review**, v. 33, n. 2, p. 219-228, 2020.

PAVAN, L. S. **Os determinantes da produtividade agrícola dos municípios paranaenses: uma análise de dados espaciais**. 2013. 116 f. Dissertação (Mestrado) – Curso de Economia, Universidade Estadual de Maringá, 2013.

RAIHER, A. P.; OLIVEIRA, R. A. D.; CARMO, A. S. S. D.; STEGE, A. L. Convergência da produtividade agropecuária do sul do Brasil: uma análise espacial. **Revista de Economia e Sociologia Rural**, v. 54, n. 3, p. 517-536, 2016. DOI: <http://dx.doi.org/10.1590/1234-56781806-94790540307>.

ROCHA, A. F. D. Panorama da seca no estado de Sergipe: impactos e ações de enfrentamento. **Parcerias Estratégicas**, v. 22, n. 44, p. 181-200, 2017.

VIEIRA FILHO, J. E. R. **Heterogeneidad estructural de la agricultura familiar em el Brasil**. Revista de la CEPAL, v. 111, p. 103-1021, 2013. Disponível em: https://repositorio.cepal.org/bitstream/handle/11362/35935/RVE111VieiraFilho_es.pdf?sequence=1&isAllowed=y. Acesso em: 13 jul. 2021.