

ESCOLA DE NEGÓCIOS
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA DO DESENVOLVIMENTO
DOUTORADO EM ECONOMIA DO DESENVOLVIMENTO

ANA PAULA BUHSE

**TRÊS ENSAIOS SOBRE O IMPACTO DO CAPITAL HUMANO NO CRESCIMENTO
ECONÔMICO REGIONAL**

Porto Alegre
2020

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica
do Rio Grande do Sul

ANA PAULA BUHSE

**TRÊS ENSAIOS SOBRE O IMPACTO DO CAPITAL HUMANO NO
CRESCIMENTO ECONÔMICO REGIONAL**

Tese apresentada ao Programa de Pós-Graduação em Economia do Desenvolvimento da Pontifícia Universidade Católica do Rio Grande do Sul – PUCRS, como requisito parcial para a obtenção do título de Doutora em Economia.

Área de concentração: Economia Regional

Orientador: Prof. Dr. Carlos Eduardo Lobo e Silva

Porto Alegre - RS

2020

Ficha Catalográfica

B931t Buhse, Ana Paula

Três ensaios sobre o impacto do capital humano no crescimento econômico regional / Ana Paula Buhse . – 2020.

90 f.

Tese (Doutorado) – Programa de Pós-Graduação em Economia do Desenvolvimento, PUCRS.

Orientador: Prof. Dr. Carlos Eduardo Lobo e Silva.

1. Capital Humano. 2. Crescimento Econômico. 3. Indústria de alimentos. 4. Aglomeração espacial. I. Silva, Carlos Eduardo Lobo e. II. Título.

Ana Paula Buhse

TRÊS ENSAIOS SOBRE O IMPACTO DO CAPITAL HUMANO NO CRESCIMENTO ECONÔMICO REGIONAL

Tese apresentada como requisito parcial para a obtenção do grau de Doutor em Economia, pelo Programa de Pós-Graduação em Economia da Escola de Negócios da Pontifícia Universidade Católica do Rio Grande do Sul.

Aprovado em 28 de abril de 2020, pela Banca Examinadora.

BANCA EXAMINADORA:

Prof. Dr. Carlos Eduardo Lobo e Silva
Orientador e Presidente da sessão

Prof. Dr. Adelar Fochezatto

Prof. Dr. Gabrielito Rauter Menezes

Prof. Dr. Douglas Mesquita Carneiro

Dedico esta tese aos meus pais e
meu esposo que tanto me apoiaram.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado força e esperança em conquistar mais um sonho de vida.

Agradeço aos meus pais pela oportunidade e incentivo em todos esses anos de estudos. Aos meus irmãos que cada um na sua forma tornaram meus exemplos. Ao meu marido que esteve do meu lado desde a graduação e tanto me apoiou nesses anos de estudo, desta forma agradeço apoio e companheirismo.

Agradeço a todos os professores que passaram pela minha trajetória e que de alguma forma contribuíram para eu chegar até aqui. De forma especial, agradeço meu orientador Dr. Carlos Eduardo por esses quatro anos de dedicação e contribuição, não só na presente tese, mas em decisões que foram tomadas nesse período.

Agradeço a oportunidade que tive de realizar o doutorado sanduíche na ISEG/ Lisboa, especialmente ao professor orientador Dr. José Pedro Pontes e a Filomena.

Agradeço aos colegas do doutorado por esses anos tão importantes de amizade, companheirismo e de muito estudo.

Agradeço a CAPES pelo apoio financeiro durante uma parte do doutorado e por proporcionar a bolsa de doutorado sanduíche. Agradeço a PUC/RS pelos meses de isenção da matrícula, sem ela não seria possível finalizar mais essa fase acadêmica.

Agradeço a todos que de alguma forma me ajudaram conquistar esse sonho.

Muito obrigada!

RESUMO

A literatura mostra a importância do capital humano para reduzir as disparidades entre regiões e, ciente dessa relação, a presente tese compreende três ensaios com ênfase no crescimento econômico regional e setorial, considerando educação como *proxy* de capital humano. No primeiro ensaio, o capital humano é representado pelo percentual da população de 25 anos ou mais com superior completo, enquanto no segundo e terceiro, utiliza-se a porcentagem de vínculos da indústria de alimentos com ensino superior. No ensaio 1, é analisada a influência do capital humano na taxa de crescimento dos municípios brasileiros por meio dos padrões geográficos de aglomeração espacial. Foi possível observar que, nos municípios da região Sul e Sudeste, houve significativa importância do *clusters High-High* entre a taxa de crescimento e a variável de capital humano, enquanto o modelo econométrico espacial permite concluir que o capital humano influencia de forma positiva a taxa de crescimento do Produto Interno Bruto (PIB) *per capita* dos municípios. O segundo ensaio verificou os padrões geográficos das agroindústrias de alimentos dispostos nas microrregiões do Brasil para o ano de 2016, a fim de apurar se ocorre concentração/aglomeração agroindustrial em torno das microrregiões metropolitanas. Os resultados mostram que a indústria de alimentos favorece um desenvolvimento mais concentrado, com alta densidade populacional de mão de obra qualificada, acesso ao mercado consumidor e a clusterização para o ganho de produtividade. Por fim, o terceiro ensaio busca analisar como se distribuem espacialmente os vínculos da indústria de alimentos com maior capital humano. Nesse estudo, foi possível identificar que a presença de capital humano é determinante na participação dos vínculos nas microrregiões que estão alocadas em todos os estados das regiões sudeste e sul, assim como em alguns estados do nordeste (Ceará e Bahia) e do norte (Amapá e Roraima). As indústrias de alimentos que estão aglomeradas nas microrregiões do sudeste e sul apresentam vínculos com maior capital humano, ou seja, nas regiões brasileiras que já são mais desenvolvidas economicamente e cuja população já apresenta maior facilidade na aquisição de maiores níveis de escolaridade e competências.

Palavras-Chave: Capital humano; Crescimento Econômico; Indústria de Alimentos; Aglomeração Espacial.

ABSTRACT

Literature shows the importance of human capital to reduce disparities between regions and, considering this relationship, this thesis comprises three essays emphasizing regional and sectoral economic growth, considering education as a proxy for human capital. In the first essay, human capital is represented by the percentage of the population aged 25 or over with a college degree, while in second and third, the bond percentage in the food industry with higher education is used. In essay 1, the influence of human capital on Brazilian municipalities growth rate is analyzed through the geographic patterns of spatial agglomeration. It was observed that, in southeastern and southern regions, there was significant importance of the High-High clusters between the growth rate and the human capital variable, while the spatial econometric model allows us to conclude that human capital positively influences the rate of Gross Domestic Product (GDP) growth per capita in the cities. The second test verified the food agribusiness geographic patterns arranged in the micro-regions of Brazil in 2016, in order to determine if there is concentration / agribusiness agglomeration around the metropolitan micro-regions. The results show that the food industry favors a more concentrated development, with a high population density of qualified labor, access to consumer market and clustering for productivity gains. Finally, the third essay aimed to analyze the spatial distribution of food industry ties with greater human capital. In this study, it was possible to identify that the presence of human capital is determinant in the participation of ties in the micro-regions that are allocated in all states in the southeastern and southern regions, as well as in some states in the northeast (Ceará and Bahia) and north (Amapá and Roraima). The food industries that are clustered in southeastern and southern micro-regions have links with greater human capital, that is, in the Brazilian regions that are already economically developed and where population are more educated and skilled.

Keywords: Human capital; Economic Growth; Food industry; Spatial Agglomeration.

LISTA DE TABELAS E QUADROS

EFEITOS DO CAPITAL HUMANO NO CRESCIMENTO ECONÔMICO DOS MUNICÍPIOS BRASILEIRO: UMA ANÁLISE ESPACIAL

Tabela 1 – Estudos relevantes	18
Tabela 2 – Estatística descritiva	25
Tabela 3 – Resultados da Regressão em MQO	31
Tabela 4 – Diagnóstico de Dependência Espacial	32
Tabela 5 – Resultados da Regressão para o modelo espacial	33

PADRÕES GEOGRÁFICOS DAS AGROINDÚSTRIAS DE ALIMENTOS: UMA ANÁLISE DAS MICRORREGIÕES DO BRASIL PARA O ANO 2016

Tabela 1 – Estudos relevantes	45
Tabela 2 – Estatística descritiva	53
Tabela 3 – Resultado da Regressão em MQO	59
Tabela 4 – Diagnóstico de Dependência Espacial	60
Tabela 5 – Resultados da Regressão para o modelo espacial SAR e SEM	61
Tabela 6 – Resultados da Regressão para o modelo espacial SAC	61

INFLUÊNCIA DO CAPITAL HUMANO NA INDÚSTRIA DE ALIMENTOS: UMA ANÁLISE A PARTIR DA REGRESSÃO GEOGRAFICAMENTE PONDERADA PARA AS MICRORREGIÕES BRASILEIRAS

Tabela 1 – Resultado do MQO	77
Tabela 2 – Estatísticas dos coeficientes estimados no modelo RGP	78

LISTA DE FIGURAS

EFEITOS DO CAPITAL HUMANO NO CRESCIMENTO ECONÔMICO DOS MUNICÍPIOS BRASILEIRO: UMA ANÁLISE ESPACIAL

Figura 1 - Diagrama de Dispersão de Moran para a variável dependente	27
Figura 2 – Análise de Aglomeração Espacial	28
Figura 3 – <i>Cluster</i> bivariado entre taxa de crescimento e a variável <i>proxy</i> de capital humano	30

PADRÕES GEOGRÁFICOS DAS AGROINDÚSTRIAS DE ALIMENTOS: UMA ANÁLISE DAS MICRORREGIÕES DO BRASIL PARA O ANO 2016

Figura 1 - Diagrama de Dispersão de Moran para a variável dependente	54
Figura 2 – Mapa de clusters para os estabelecimentos agroindustriais	56
Figura 3 - Mapa de clusters bivariados	58

INFLUÊNCIA DO CAPITAL HUMANO NA INDÚSTRIA DE ALIMENTOS: UMA ANÁLISE A PARTIR DA REGRESSÃO GEOGRAFICAMENTE PONDERADA PARA AS MICRORREGIÕES BRASILEIRAS

Figura 1 – Microrregiões com maior porcentagem de capital humano na indústria de alimentos	76
Figura 2 – Coeficiente relacionado ao capital humano	79

SUMÁRIO

1 APRESENTAÇÃO	12
2 EFEITOS DO CAPITAL HUMANO NO CRESCIMENTO ECONÔMICO DOS MUNICÍPIOS BRASILEIRO: UMA ANÁLISE ESPACIAL	15
Resumo	15
Abstract	15
1 INTRODUÇÃO	16
2 REVISÃO DE LITERATURA	17
3 METODOLOGIA	20
3.1 Análise Exploratória de Dados Espaciais (AEDE)	20
3.2 Econometria Espacial	23
3.3 Base de Dados e Descrição das variáveis	24
4 ANÁLISE DOS RESULTADOS	26
4.1 Análise Exploratória de Dados Espaciais	26
4.2 Resultados do Modelo Econométrico	31
4.2.1 Modelos Econométricos Espaciais	32
5 CONSIDERAÇÕES FINAIS	34
REFERÊNCIAS	36
APÊNDICE A	39
A.1 – Determinação da matriz de peso	39
APÊNDICE B	40
B.1 – Resultado dos modelos SAR e SAC	40
B.2 - Resultado dos modelos SAC	40
3 PADRÕES GEOGRÁFICOS DAS AGROINDÚSTRIAS DE ALIMENTOS: UMA ANÁLISE DAS MICRORREGIÕES DO BRASIL PARA O ANO 2016	41
Resumo	41
Abstract	41
1 INTRODUÇÃO	42
2 TEORIA DA LOCALIZAÇÃO INDUSTRIAL	43
3 METODOLOGIA	46
3.1 Análise Exploratória de Dados Espaciais (AEDE)	46

3.2 Econometria Espacial	49
3.2.1 Modelo de Defasagem Espacial	50
3.2.2 Modelo de Erro Autorregressivo Espacial	51
3.2.3 Modelo de Defasagem Espacial com Erro Autorregressivo Espacial	51
3.3 Descrição das variáveis e fonte dos dados	52
4 ANÁLISE DOS RESULTADOS	53
4.1 Análise Exploratória de Dados Espaciais	54
4.2 Resultados do Modelo Econométrico Espacial	59
5 CONSIDERAÇÕES FINAIS	62
REFERÊNCIAS	64

4 VARIAÇÕES NA INFLUÊNCIA DO CAPITAL HUMANO NA INDÚSTRIA DE ALIMENTOS: UMA ANÁLISE A PARTIR DA REGRESSÃO GEOGRAFICAMENTE PONDERADA PARA AS MICRORREGIÕES BRASILEIRAS	69
---	----

Resumo	69
---------------------	----

Abstract	69
-----------------------	----

1 INTRODUÇÃO	70
---------------------------	----

2 REVISÃO DE LITERATURA	71
--------------------------------------	----

3 METODOLOGIA	73
----------------------------	----

3.1 Regressão Geograficamente Ponderada (RPG - <i>Geographically Weighted Regression</i> GWR)	73
--	----

3.2 Descrição das variáveis e fonte dos dados	74
--	----

4 ANÁLISE DOS RESULTADOS	75
---------------------------------------	----

4.1 Capital humano na Indústria de Alimentos	75
---	----

4.2 Resultados para Regressão Geograficamente Ponderada	77
--	----

5 CONSIDERAÇÕES FINAIS	81
-------------------------------------	----

REFERÊNCIAS	82
--------------------------	----

5 CONCLUSÃO	85
--------------------------	----

6 REFERÊNCIAS	88
----------------------------	----

1 APRESENTAÇÃO

Estudos tem mostrado que a desigualdade econômica do país está relacionada com as diferenças educacionais observadas entre os indivíduos (EMILIO et al., 2004). A teoria do capital humano, dentro da Ciência Econômica, ganha destaque como fator determinante do crescimento econômico, especialmente com os estudos clássicos de Mincer (1958), Schultz (1964, 1973, 1987) e Becker (1964, 1993). Para os autores citados, as diferenças de crescimento econômico entre países e regiões eram explicadas pelo incremento do nível educacional da população (LIMA; VIANA, 2009).

As teorias modernas de crescimento endógeno, como Romer (1986, 1989b) e Lucas (1988), destacam a importância do capital humano no crescimento das regiões e dos países promovido por meio de *spillovers* (externalidades positivas) que podem influenciar no crescimento ao longo prazo (GALEANO; MATA, 2009). Lima e Viana (2009) afirmam que a variável capital humano passa a ter destaque na literatura do crescimento econômico com sua inserção em modelos econométricos desenvolvidos a partir dos estudos de Solow (1956), como Lucas (1988), Romer (1986, 1989, 1990) e Mankiw, Romer e Weil (1992).

Lucas (1988), Romer (1990) e Nakabashi (2005) evidenciaram a importância do capital humano para o crescimento econômico de uma região, na qual os indivíduos se tornam mais produtivos quando apresentam maiores habilidades e conhecimentos, resultando em maior nível de produção, além de possibilitar a inovação das técnicas empregadas no processo produtivo. A participação do capital humano no crescimento econômico poderia subdividir-se em *ex ante*, com a formação de tecnologias mais avançadas, como, também, *ex post*, com a existência de mão de obra qualificada para trabalhar essas novas tecnologias (RAIHER; DATHEIN, 2009).

Assim sendo, o capital humano, resultado de maior nível de educação e conhecimento da população, torna-se uma variável importante no conceito e nos modelos de crescimento econômico. O aumento de produtividade, além de estar relacionado com a acumulação de capital físico, também leva em consideração o capital humano, que serviria de suporte para minimizar os rendimentos decrescentes advindos do capital físico. Desta forma, a educação torna-se um aspecto determinante para a redução das disparidades econômicas e o fortalecimento das economias regionais, influenciando na geração de ganhos à população e elevando a produtividade do capital humano e capital físico (LIMA; VIANA, 2009).

Diante deste cenário, a presente tese se propõe a responder inicialmente a seguinte questão: qual a influência do capital humano na taxa de crescimento dos municípios do Brasil?

E, posteriormente, por meio da análise específica da indústria de alimentos, verificar-se-á se ocorre aglomeração agroindustrial no setor e como se dá a relação entre número de empregos do setor e nível de capital humano nas microrregiões brasileiras.

O primeiro ensaio teve como objetivo principal analisar a influência do capital humano na taxa de crescimento dos municípios do Brasil através dos padrões geográficos de aglomeração espacial. Diante da realidade dos municípios brasileiros, em que a disparidade econômica e educacional é tão significativa entre as regiões, o artigo respondeu o seguinte problema de pesquisa: municípios que apresentam maior capital humano influenciam a taxa de crescimento do município e dos seus vizinhos?

A metodologia utilizada para desenvolver foi a Análise Exploratória de Dados Espaciais (AEDE) e econometria espacial. Os dados utilizados foram: a taxa de crescimento do PIB *per capita* entre os anos 2000 e 2010 dos municípios do Brasil; PIB *per capita*; população residente; taxa de homicídios (1000); percentual da população de 25 anos ou mais com superior completo como *proxy* para a variável capital humano.

O segundo e terceiro ensaios apresentam análise da influência do capital humano na indústria de alimentos, que está incluído no último nível da cadeia do agronegócio, composto por uma gama de atividades, desde o simples beneficiamento até as que dependem de tecnologias complexas (ARAÚJO, 2002).

O segundo ensaio verificou os padrões geográficos das agroindústrias de alimentos dispostos nas microrregiões do Brasil para o ano de 2016, a fim de apurar se ocorre concentração/aglomeração agroindustrial em torno das microrregiões metropolitanas. O estudo dedicou-se a responder o seguinte questionamento: a indústria de alimentos se desenvolve de forma concentrada ou desconcentrada espacialmente?

O estudo teve como variável dependente o número de estabelecimentos da indústria de alimentos e como variáveis independentes Produto Interno Bruto *per capita* (PIB); participação do Valor Adicionado Bruto da Agropecuária (VABAGR); participação do Valor Adicionado Bruto da Indústria (VABIND); porcentagem de vínculos com ensino superior (CAPHUMANO); densidade demográfica (DENSID) e a *dummy* que classificou as microrregiões em metropolitanas. Da mesma forma que o primeiro ensaio, também foi utilizada a metodologia de análise exploratória de dados espaciais e econometria espacial.

Por fim, o objetivo principal do terceiro ensaio foi analisar como se distribuem espacialmente os vínculos da indústria de alimentos com maior capital humano. O questionamento respondido é se, na indústria de alimentos existe diferença na influência do capital humano?

A análise foi feita para microrregiões do Brasil através do uso da metodologia Regressão Geograficamente Ponderada (RGP). O modelo utilizou como variável dependente participação de vínculos da indústria de alimentos e como variáveis independentes: Produto Interno Bruto *per capita* (PIB); participação do Valor Adicionado Bruto da Agropecuária (VABAGR); participação do Valor Adicionado Bruto da Indústria (VABIND); porcentagem de vínculos com ensino superior (CAPHUMANO); densidade demográfica (DENSID) e a *dummy* que classificou as microrregiões em metropolitanas.

Assim sendo, a presente tese estuda temas centrais do debate da economia regional – capital humano e localização espacial – focando sua atenção em algumas questões específicas, o que permite uma contribuição à literatura. No primeiro ensaio, são utilizados os municípios do Brasil, sendo que a grande parte da literatura utiliza apenas municípios de regiões específicas ou até mesmo microrregiões. Desta forma, busca-se fazer uma análise mais completa em relação ao tema. Enquanto, no segundo e terceiro ensaio, a análise se concentra em um segmento específico do agronegócio - indústria de alimentos, um setor crucial para a economia brasileira – e busca entender seu desenvolvimento, relacionando-o aos aspectos espaciais e de capital humano.

2 EFEITOS DO CAPITAL HUMANO NO CRESCIMENTO ECONÔMICO DOS MUNICÍPIOS BRASILEIROS: UMA ANÁLISE ESPACIAL

Resumo

O capital humano, segundo a literatura, é um dos principais fatores na determinação do Produto Interno Bruto (PIB) de um país. Porém, é importante analisar as particularidades regionais para se entender com mais precisão os determinantes não apenas do crescimento, como também do desenvolvimento econômico. Desta forma, o objetivo principal do artigo é analisar a influência do capital humano sobre a taxa de crescimento dos municípios do Brasil por meio dos padrões geográficos de aglomeração espacial. Para tanto, empregou-se como metodologia a Análise Exploratória de Dados Espaciais (AEDE) e econometria espacial. Os resultados demonstraram a existência de autocorrelação espacial positiva entre os municípios do país. A constatação de dependência espacial demandou a utilização do Modelo de Erro Espacial (SEM), que indicou relação negativa entre o PIB *per capita* e população e positivo para capital humano. Concluiu-se que nos municípios da região Sul e Sudeste houve significativa importância do clusters high-high entre a taxa de crescimento e a variável proxy de capital humano, enquanto o modelo econométrico espacial mostrou que o capital humano influencia de forma positiva a taxa de crescimento do PIB *per capita* dos municípios.

Palavras-chave: Desenvolvimento regional; Capital humano; Análise Exploratória de Dados Espaciais; Econometria Espacial.

Abstract

According to the literature, human capital is one of the main factors in determining the Country's Gross Domestic Product (GDP), but it is important to analyze regional particularities to better understand the determinants of growth as well as the economic development. The main goal of the article is to analyze the influence of human capital on the growth rate of Brazilian counties through the spacial agglomeration patterns. To do that, it was used Exploratory Spatial Data Analysis (ESDA) and spatial econometrics as methodology. The results showed the existence of positive spatial autocorrelation among the counties of the country. As it was found spatial dependence, it was used the Spatial Error Model (SEM), which indicated negative sign for GDP per capita and population and positive for human capital, all variables were significant, except homicide rate. It was concluded that in the counties of the South and Southeast there was significant importance of high-high clusters between the growth rate and the proxy variable

of human capital, while the spatial econometric model showed that human capital positively influences the growth rate per capita GDP of the counties.

Keywords: Regional development; Human capital; Exploratory Spatial Data Analysis; Space Econometrics.

1 INTRODUÇÃO

O capital humano, o capital físico¹ e a produtividade não explicada diretamente pelo estoque de capital são considerados os principais fatores na determinação do Produto Interno Bruto (PIB) *per capita* das economias (CANGUSSU et al., 2010). A definição para capital humano², segundo a Organização para a Cooperação e Desenvolvimento Econômico (OCDE, 2001, p. 18), compreende “conhecimentos, aptidões, competências e atributos incorporados nos indivíduos que facilitam a criação de bem-estar pessoal, social e econômico”.

O capital humano está relacionado às habilidades do trabalhador - quanto mais qualificado, melhor serão os resultados da inovação, criação e melhoria de projetos decorrendo no aumento da produtividade. O capital humano gera externalidades positivas capazes de amenizar os rendimentos decrescentes do capital físico (GALEANO; MATA, 2009).

Além da importância do capital humano para maior crescimento e /ou desenvolvimento de uma região, outros aspectos devem ser levados em consideração. A ciência econômica apresenta como desafio explicar os determinantes do crescimento econômico de um país ou de suas regiões, sendo necessário avaliar as particularidades regionais, pois é uma das razões na ocorrência de fracassos de políticas públicas que são voltadas para o desenvolvimento (GALEANO; MATA, 2009).

A literatura em relação a análise do crescimento econômico brasileiro é vasta, porém, nem todos os trabalhos incluem a variável capital humano e/ou disparidades regionais. Enquanto, Monastério e Ávila (2004), Pimentel e Haddad (2004), Resende e Silva (2007), Barreto e Almeida (2009), Raiher e Dathein (2009), Montenegro et al. (2014) e Leivas et al. (2015) analisaram a diferença de renda nas regiões brasileiras, acrescentando a variável capital humano na análise da dependência espacial.

¹ A variável capital físico não foi utilizado no modelo, pois existe limitações em relação a variável a se utilizar como *proxy* (FIGUEIREDO, 2012; MONTENEGRO et al., 2014).

² Original: *The knowledge, skills, competencies and attributes embodied in individuals that facilitate the creation of personal, social and economic well-being* (OCDE, 2001, p. 18).

De modo pontual, estudos recentes, mostram que a desigualdade do país está relacionada com as diferenças educacionais observadas entre os indivíduos (EMILIO et al., 2004). O capital humano, a educação e o “aprender fazendo” são determinantes de acumulação de capital, sendo que o investimento proporciona externalidades positivas resultando no aumento do nível tecnológico, variável considerada como um fator acumulável e fonte de crescimento econômico (GALEANO; MATA, 2009). Diante da realidade dos municípios brasileiros, o artigo responderá o seguinte problema de pesquisa: municípios que apresentam maior capital humano influenciam a taxa de crescimento do município e dos seus vizinhos?

Conforme exposto, o objetivo principal do artigo é analisar a influência do capital humano na taxa de crescimento dos municípios do Brasil por meio dos padrões geográficos de aglomeração espacial. Além disso, busca-se analisar a importância da variável capital humano no crescimento dos municípios; analisar quais variáveis influenciam no PIB além da *proxy* de capital humano e identificar se ocorre o fenômeno de concentração/aglomeração entre os municípios vizinhos no que se refere a taxa de crescimento do PIB *per capita* e capital humano.

A fim de cumprir o propósito deste trabalho, a estrutura está dividida em cinco seções, sendo a primeira esta introdução e a segunda tratando da revisão de literatura. A terceira seção do artigo engloba a metodologia empregada a fim de se analisar os resultados que são expressos na quarta seção. Finalmente, na quinta e última seção discutem-se as considerações finais.

2 REVISÃO DE LITERATURA

As últimas teorias de crescimento econômico surgiram com Romer (1986, 1989b) e Lucas (1988) e mostraram a importância do capital humano no crescimento das regiões e dos países, relativo a *spillovers* (externalidades positivas) que podem resultar no crescimento no longo prazo.

No modelo de Lucas (1988) o capital humano é o motor do crescimento econômico, em que não beneficia somente o indivíduo mas toda a sociedade, dado que o capital humano, associado à produtividade de todos os outros fatores de produção, gera externalidade, responsável pela taxa de crescimento positiva do produto per capita no longo prazo. Apesar de não ocorrer inovações, existe a necessidade de mão de obra qualificada para empregar tecnologia. Além disso, a educação gera externalidades positivas, o que implica que o capital humano de um indivíduo particular contribui para melhorar o capital humano dos demais

indivíduos à sua volta, ao gerar capital social e a melhoria das instituições (KROTH; DIAS, 2012).

Os agentes econômicos devem investir em inovações e na acumulação de capital humano e não apenas em capital físico. Essas novas teorias de crescimento constituíram-se como o ponto de partida das discussões sobre o diferencial de crescimento de algumas regiões do mesmo país no qual ocorrem desigualdades no incentivo para acumulação de capital humano e inovações (GALEANO; MATA, 2009).

Além de abarcar o capital humano, evidências empíricas, por meio de estudos recentes sobre crescimento econômico, têm buscado levar em consideração o espaço geográfico como elemento em análise (MONTENEGRO et al., 2014). O surgimento da teoria da Nova Geografia Econômica e o aprimoramento da modelagem de econometria espacial, permitiram a “identificação de um conjunto de variáveis econômicas, sociais, ambientais e de infraestrutura urbana que podem afetar o crescimento de determinada região e seus vizinhos, a partir de efeitos de transbordamentos espaciais” (MONTENEGRO et al., 2014, p. 216).

Com a construção das variáveis de capital humano, os estudos sobre crescimento econômico começaram a avançar nas últimas décadas em nível de países e estados, tendo a análise sobre municípios preterida pela ausência de variáveis desagregadas. A maioria dos trabalhos sobre crescimento econômico municipal enfatizam o aspecto da convergência, de modo que não exploram de forma específica os fatores que determinam o crescimento dos municípios (KROTH; DIAS, 2012).

A Tabela 1 elenca os principais trabalhos sobre capital humano que analisaram a diferença de renda nas regiões brasileiras levando em consideração as disparidades regionais. São eles: Monastério e Ávila (2004), Pimentel e Haddad (2004), Resende e Silva (2007), Barreto e Almeida (2009), Raiher e Dathein (2009), Montenegro et al. (2014) e Leivas et al. (2015).

Tabela 1 – Estudos relevantes

Autor	Região / Período	Objetivo / Metodologia	Resultados
Monastério e Ávila (2004)	Rio Grande do Sul - Período 1939 e 2001.	Analisar o crescimento econômico gaúcho / Análise exploratória de dados espaciais (AEDE) e Econometria Espacial	Áreas ricas tenderam a ser circundadas por áreas ricas, e as pobres, por áreas igualmente pobres. As aglomerações de alto crescimento tenderam a se localizar na região da serra e as de baixo crescimento na região da campanha. Na econometria espacial foi utilizado os modelos de erros e de defasagens

			especialmente autocorrelacionados, sendo que ambos mostraram superiores ao modelo padrão, sendo o de erro espacial o mais apropriado. Os resultados sugeriram que a região da campanha, ao sul do estado, compõe um regime espacial distinto do restante do Rio Grande do Sul.
Pimentel e Haddad (2004)	Microrregiões mineiras – Período década de 1990	Analisar a distribuição espacial da variável renda e o fenômeno de renda per capita / Análise exploratória de dados espaciais (AEDE) e Econometria Espacial	Existência de fenômenos espaciais para a variável renda em todos os setores e a importância dos processos de autocorrelação espacial na explicação do fenômeno de convergência econômica para estas unidades regionais.
Resende e Silva (2007)	Municípios da Região Sul – Período 1991 a 2000	Analisar a taxa de crescimento da renda dos municípios da região sul do país / Análise exploratória de dados espaciais (AEDE) e Econometria Espacial	Quanto maiores os níveis de escolaridade e as taxas de urbanização, maiores as taxas de crescimento da renda do trabalho. Por outro lado, quanto menores forem o número de homicídios, a concentração de renda e os níveis iniciais da renda, maiores serão as taxas de crescimento da renda do trabalho dos municípios da região.
Barreto e Almeida (2009)	Municípios do Ceará.	Papel do capital humano para o crescimento econômico e a convergência de renda / Efeitos fixos com dependência espacial.	O modelo comprovou que ocorre convergência condicional e mostrou que o crescimento do PIB <i>per capita</i> no período de análise foi afetado negativamente pela variável densidade demográfica, enquanto, as variáveis capital humano, infraestrutura, capital social, mercado regional e externalidades espaciais foram afetadas positivamente. Os resultados evidenciaram a dupla importância do capital humano para o crescimento e para a convergência de renda <i>per capita</i> .
Raiher e Dathein (2009)	Microrregiões do Paraná / Período 1999 – 2006		O aumento do capital humano no Estado, melhora os aspectos quantitativos e qualitativos, havendo ainda diferenças significativas quanto à sua distribuição ao longo do Paraná; entretanto, se comparadas com 1999, essas diferenças se reduziram significativamente.
Montenegro et al. (2014)	Estados brasileiros - Período de 1992 e 2006	Analisar o processo de crescimento econômico dos estados brasileiros / Análise Exploratória de Dados Espaciais e Modelos de regressão espacial com dados em painel.	Alguns efeitos do crescimento econômico brasileiro foram importantes como anos de estudo, e em menor grau, os gastos do governo e a taxa de fecundidade. A taxa de crescimento dos estados não é significativamente afetada pelo crescimento dos seus estados vizinhos.

Leivas et al. (2015)	Municípios do Brasil – 2000 a 2010	Verificar a importância da geografia em termos relativos para o desempenho econômico dos municípios / Análise Exploratória de Dados Espaciais e <i>Spatial Durbin Model</i>	Municípios que possuem vizinhos com maior qualidade institucional apresentam pior desempenho em termos de desenvolvimento e crescimento econômico.
----------------------	------------------------------------	---	--

Fonte: Elaborada pela autora

Conforme supracitado, há um número considerável de trabalhos que analisam a diferença de renda e crescimento econômico, porém nem sempre as variáveis de capital humano são consideradas. Demais variáveis que impactam o crescimento econômico nos municípios brasileiros levando em consideração as particularidades regionais também não são frequentes na literatura, bem como a utilização de econometria espacial. Desse modo, esse é o principal diferencial do artigo, que utiliza a *proxy* de capital humano e a metodologia de análise exploratória de dados espaciais que apresenta os clusters de capital humano que influenciam o crescimento do PIB *per capita* bem como os modelos de econometria espacial.

3 METODOLOGIA

O objetivo da seção é apresentar a metodologia empregada na análise empírica. Primeiramente será apresentada a Análise Exploratória de Dados Espaciais (AEDE), seguida pela Economia Espacial e descrição das variáveis utilizadas no estudo.

3.1 Análise Exploratória de Dados Espaciais (AEDE)

A Análise Exploratória de Dados Espaciais está baseada nos aspectos espaciais da base de dados, tratando de forma direta das questões como dependência espacial (isto é, associação espacial) e heterogeneidade espacial (PEROBELLI et al., 2007). A análise torna-se fundamental ao estudo da econometria espacial, uma vez que lida com as complicações causadas pela interação espacial (autocorrelação espacial) e pela estrutura espacial (heterogeneidade espacial) em modelos de regressão para dados na forma de *cross-section* e painel de dados (ALMEIDA; 2012).

Com a AEDE é possível analisar medidas de autocorrelação espacial global e local, investigando a influência dos efeitos espaciais por intermédio de métodos quantitativos (ROCHA; PARRÉ, 2009). O índice global Moran's I é a estatística mais difundida e mede a correlação com base no produto dos desvios em relação à média. Esta estatística fornece a indicação formal do grau de associação linear (espacial) entre os vetores de Z_t no tempo t e a média ponderada dos valores da vizinhança, ou lags espaciais (WZ_t) (ANSELIN, 1992).

Conforme Anselin (1992) é especificado da seguinte forma:

$$I = \left(\frac{n}{\sum_i \sum_j w_{ij}} \right) \times \left(\frac{\sum_i \sum_j w_{ij} (y_i - \mu) (y_j - \mu)}{\sum_i (y_i - \mu)^2} \right) \quad (1)$$

onde n é o número de observações; W_{ij} é o elemento na matriz peso espacial correspondente às unidades espaciais i e j ; e y_i e y_j são as observações para os respectivos locais; μ representa a média de y .

O índice varia entre -1 a 1, visto que taxas próximas de zero indicam inexistência de autocorrelação espacial significativa; se o valor for positivo (negativo), a autocorrelação será positiva (negativa). No entanto, a estatística Moran's I é uma medida global, não observando a estrutura de correlação espacial em nível regional.

A matriz de pesos é a forma de expressar a estrutura espacial dos dados sendo o ponto inicial para qualquer teste estatístico ou modelo (PEROBELLI et al., 2007). A escolha da matriz de pesos é importante em uma análise AEDE, pois todos os passos subsequentes são dependentes de tal seleção. Duas matrizes de peso foram testadas: Quem, considerando diferentes ordens de contiguidade, e a matriz Rook. Observou-se maior autocorrelação espacial quando se testou apenas os vizinhos de 1ª ordem, sendo está matriz utilizada na estimação³.

Segundo Le Gallo e Ertur (2003) a escolha de um número fixo de vizinhos mais próximos, ao invés do uso de uma matriz simples de continuidade, é melhor no sentido de evitar problemas metodológicos que podem ocorrer quando há variações no número de vizinhos.

A estatística global Moran's I pode esconder padrões locais de autocorrelação espacial, através da ocorrência de três situações distintas, são elas: i) envolve a indicação de um I de Moran global insignificante, porém, pode haver indicações de autocorrelação espacial local insignificante, positiva ou negativa; ii) implica uma indicação positiva do I de Moran global, que oculta autocorrelação espacial local negativa e insignificante; e iii) denota que a evidência

³ Apêndice A1 - Determinação da matriz de peso.

de uma autocorrelação espacial global é negativa e pode acomodar indícios de autocorrelação espacial local positiva para certos grupos dos dados (PEROBELLI et al., 2007).

O I de Moran Global não é capaz de evidenciar padrões locais, pois leva em conta todas as localidades sendo incapaz de identificar fenômenos específicos de algumas regiões (ALMEIDA, 2012). Desta forma, utiliza-se o Indicador Local de Autocorrelação Espacial Local (LISA) para mostrar que ocorrem agrupamentos em função de uma vizinhança preestabelecida. Entretanto, é necessário atender dois objetivos específicos; i) permitir a identificação de padrões de associação espacial significativos; ii) a soma dos indicadores de LISA para todas as observações deve ser proporcional ao índice global da associação espacial (ANSELIN, 1995).

A estatística LISA baseada no I de Moran local pode ser especificada da seguinte forma (LE GALLO; ERTUR, 2003):

$$I_{i,t} = \frac{(x_{i,t} - u_t)}{m_0} \sum_j w_{ij} (x_{j,t} - u_t)$$

$$m_0 = \frac{(x_{i,t} - u_t)^2}{n} \quad (2)$$

onde x_{it} é a observação de uma variável de interesse na região i para o ano t ; e u_t a média das observações entre as regiões no ano t para a qual o somatório em relação a j é tal que somente os valores vizinhos de j são incluídos.

Valores positivos significam que existem *clusters* espaciais com valores similares (alto ou baixo); enquanto, valores negativos indicam que existem clusters espaciais com valores diferentes entre as regiões e seus vizinhos (PEROBELLI et al., 2007).

O passo subsequente para ratificar a presença de autocorrelação espacial no modelo econométrico é realizar o teste de I Moran nos resíduos dos Mínimos Quadrados Ordinários (MQO). Se a presença de autocorrelação espacial for confirmada será utilizado o modelo econométrico espacial. A escolha do melhor modelo será feita por meio da estratégia sugerida por Florax et al. (2003).

Florax et al. (2003) destacam os seguintes procedimentos para a escolha:

- 1) Estimar o modelo clássico de análise de regressão linear por Mínimos Quadrados Ordinários (MQO);

- 2) Testar a hipótese de ausência de autocorrelação espacial devido a uma defasagem ou a um erro por intermédio das estatísticas Multiplicador de Lagrange (ML) ρ (defasagem espacial) e Multiplicador de Lagrange (ML) λ (erro espacial);
- 3) Se ambos os testes não sejam significativos, a utilização do MQO é a mais apropriada. Caso sejam significativos, é preciso seguir para o próximo passo.
- 4) Caso ambos os testes sejam significativos, estima-se o modelo apontado como o mais significativo de acordo com as versões robustas desses testes, ou seja, Multiplicador de Lagrange Robusto (ML*) ρ (defasagem espacial) e Multiplicador de Lagrange Robusto (ML*) λ (erro espacial). Ou seja, se $ML^* \rho > ML^* \lambda$ utiliza-se o modelo com defasagem espacial, ou se ocorrer ao contrário, $ML^* \rho < ML^* \lambda$, usa-se o modelo de erro auto regressivo. Se esse passo não for satisfeito, é preciso seguir para o próximo passo.
- 5) Se o teste $ML^* \rho$ é significativo e o $ML^* \lambda$ não, adote o modelo de defasagem espacial. Caso contrário, segue para o próximo passo;
- 6) Se o teste $ML^* \lambda$ é significativo e o $ML^* \rho$ não, adote o modelo de erro espacial. Se este passo não for satisfeito, seguir para o próximo passo;
- 7) Se ambos os testes $ML^* \rho$ e $ML^* \lambda$ forem significativos estatisticamente, é preciso utilizar o modelo de defasagem espacial com erro auto-regressivo.

3.2 Econometria Espacial

Conforme os procedimentos de Florex et al. (2003), pode-se escolher entre três tipos de modelos: Modelo de Defasagem Espacial (*Spatial Autoregressive Model - SAR*), Modelo de Erro Autorregressivo Espacial (*Spatial Error Model - SEM*) e Modelo de Defasagem com Erro Autorregressivo Espacial (*Autorregressive Model With Autorregressive Errors - SAC* ou SARAR).

No Modelo de Defasagem Espacial ou Spatial Autoregressive Model (SAR⁴) a variável dependente y é influenciada por tal variável dependente, observada nas regiões vizinhas (W_y), sendo essa variável endógena, na qual implica que o valores de y nas regiões vizinhas influenciam a variável dependente no processo de causação circular (ALMEIDA, 2012). A equação (3) tem-se o modelo SAR:

⁴ Conforme Almeida (2012) o modelo SAR foi pioneiramente proposto por Whittle (1954).

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

tem-se que W_y é um vetor de n por I de defasagens espaciais para a variável dependente, ρ é o coeficiente autorregressivo espacial, e o X é uma matriz de variáveis explicativas exógenas (ALMEIDA, 2012).

O Modelo de Erro Autorregressivo Espacial ou *Spatial Error Model* (SEM⁵) revela que a dependência espacial se encontra no termo de erro e não na variável dependente. Conforme Almeida (2012) pode ser expresso por (4).

$$y = X\beta + \xi \quad (4.a)$$

$$\xi = \lambda W \xi + \varepsilon \quad (4.b)$$

onde o coeficiente λ é o parâmetro do erro autorregressivo espacial que acompanha a defasagem $W \xi$. Assim, os erros que estão associados com qualquer observação são uma média dos erros nas regiões vizinhas mais um componente de erro aleatório, conforme (5.b) (ALMEIDA, 2012).

No Modelo de Defasagem com Erro Autorregressivo Espacial (*Autorregressive Model With Autorregressive Errors - SAC* ou SARAR) ocorre através das regiões vizinhas i e j , há interação na variável de interesse (y) e no erro (ξ). Desta forma, na equação do modelo clássico em que não leva em conta as considerações de influência dos efeitos espaciais é necessário acrescentar uma defasagem espacial e um termo de erro espacialmente dependente (ALMEIDA, 2012; KELEJIAN; PRUCHA, 1998).

$$y = \rho W_1 y + X\beta + \xi \quad (5.a)$$

$$\xi = \lambda W_2 \xi + \varepsilon \quad (5.b)$$

Conforme os procedimentos de Florax et al. (2003) foi escolhido o melhor modelo para a análise.

3.3 Base de Dados e Descrição das variáveis

A amostra consiste em 5507 municípios do Brasil para o período de 2000 – 2010⁶, sendo que os dados de todas as variáveis foram obtidos no Laboratório de Ciência de Dados do

⁵ Segundo Almeida (2012) o modelo foi introduzido por Ord (1975).

⁶ O período do estudo foi escolhido em função da disponibilidade de dados.

Instituto de Pesquisa Econômica Aplicada (Ipeadata)⁷. Como variável dependente temos a taxa de crescimento do PIB *per capita* entre os anos 2000 e 2010 dos municípios do Brasil (TXCRESCIMENTO). Enquanto, as variáveis independentes são: PIB *per capita* (PIB_{2000}); população residente em 2000 (POP); taxa de homicídios em 2000 (1000) (TXHOM); percentual da população de 25 anos ou mais com superior completo (CAPHUMANO) como *proxy* para a variável capital humano.

Para as variáveis independentes foram utilizados os dados do início do período, ou seja, o ano de 2000. As variáveis do início da década de análise para as variáveis independentes são utilizadas para explicar os fatores que determinam o crescimento econômico da década, ou seja, supõe-se que essas variáveis influenciam por alguns anos as taxas de crescimento econômico dos municípios.

O sinal esperado para a variável PIB_{2000} é negativo, pois municípios com níveis iniciais mais baixos tendem a crescer mais rapidamente que os municípios com maiores níveis de renda, da mesma forma a variável taxa de homicídios. Enquanto, as variáveis POP e CAPHUMANO espera-se o sinal positivo.

O modelo a ser estimado pode ser formalmente, representado por:

$$\begin{aligned} \text{Taxa de crescimento} = & \beta_1 - \beta_2 PIB_{2000} + \beta_3 CAPHUMANO + \beta_4 POP + \\ & + \beta_5 TXHOM + \varepsilon \end{aligned} \quad (6)$$

Na Tabela 2, observa-se a estatística descritiva das variáveis do modelo.

Tabela 2 - Estatística descritiva

Variável	Mínimo	Mediana	Média	Máximo
TXCRESC	-99.854	40.9188	48.53796	2644.672
PIB 2000	0.64117	3.10339	6.089179	11.260.427
POP	795.0	10418.0	30833.334	10.434.252
TXHOM	0	0	10.11625	151.413
CAPHUMANO	0.814	4.069	4.038825	9.653

Fonte: Elaborada pela autora a partir dos dados da pesquisa.

⁷ <http://www.ipeadata.gov.br>

A metodologia AEDE e de econometria espacial foram realizadas através do *software* GeoDa e GeoDaSpace, sendo que a matriz de peso que forneceu o maior I de Moran foi a matriz *Queen* com primeira ordem.

4 ANÁLISE DOS RESULTADOS

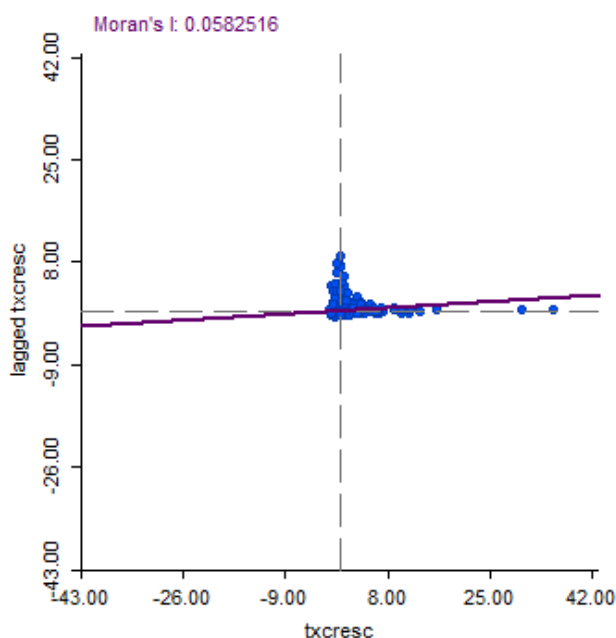
A análise dos resultados está dividida em duas subseções, na primeira, são apresentados os resultados da Análise Exploratória de Dados Espaciais, e na segunda, os resultados do modelo econométrica espacial.

4.1 Análise Exploratória de Dados Espaciais

O primeiro passo na Análise Exploratória de Dados Espaciais é verificar se ocorre a presença de autocorrelação espacial entre os agentes. A maneira mais utilizada é com a utilização da estatística I de Moran. O resultado mostrou que o I de Moran é positivo (0.0582, $\text{prob} = 0.0000$), o que indica autocorrelação espacial global positiva, ou seja, municípios com maior taxa de crescimento são vizinhos de outros municípios com as mesmas peculiaridades.

De forma complementar a interpretação da análise do I de Moran, tem-se o diagrama de dispersão de Moran, onde o eixo horizontal corresponde a variável em análise, e, o eixo vertical, a defasagem espacial (lag) da variável de interesse para o mesmo período. Com o diagrama é possível classificar os municípios de acordo com quatro diferentes regimes espaciais: *Low-High*; *High-High*; *High-Low* e *Low-Low*. A Figura 1 sugere a existência de autocorrelação espacial positiva para a taxa de crescimento dos municípios, visto que concentram no primeiro quadrante. Verifica-se que os municípios com alta (baixo) taxa de crescimento são mais propensos em ter vizinhos também com alto (baixo) crescimento.

Figura 1 - Diagrama de Dispersão de Moran para a variável dependente

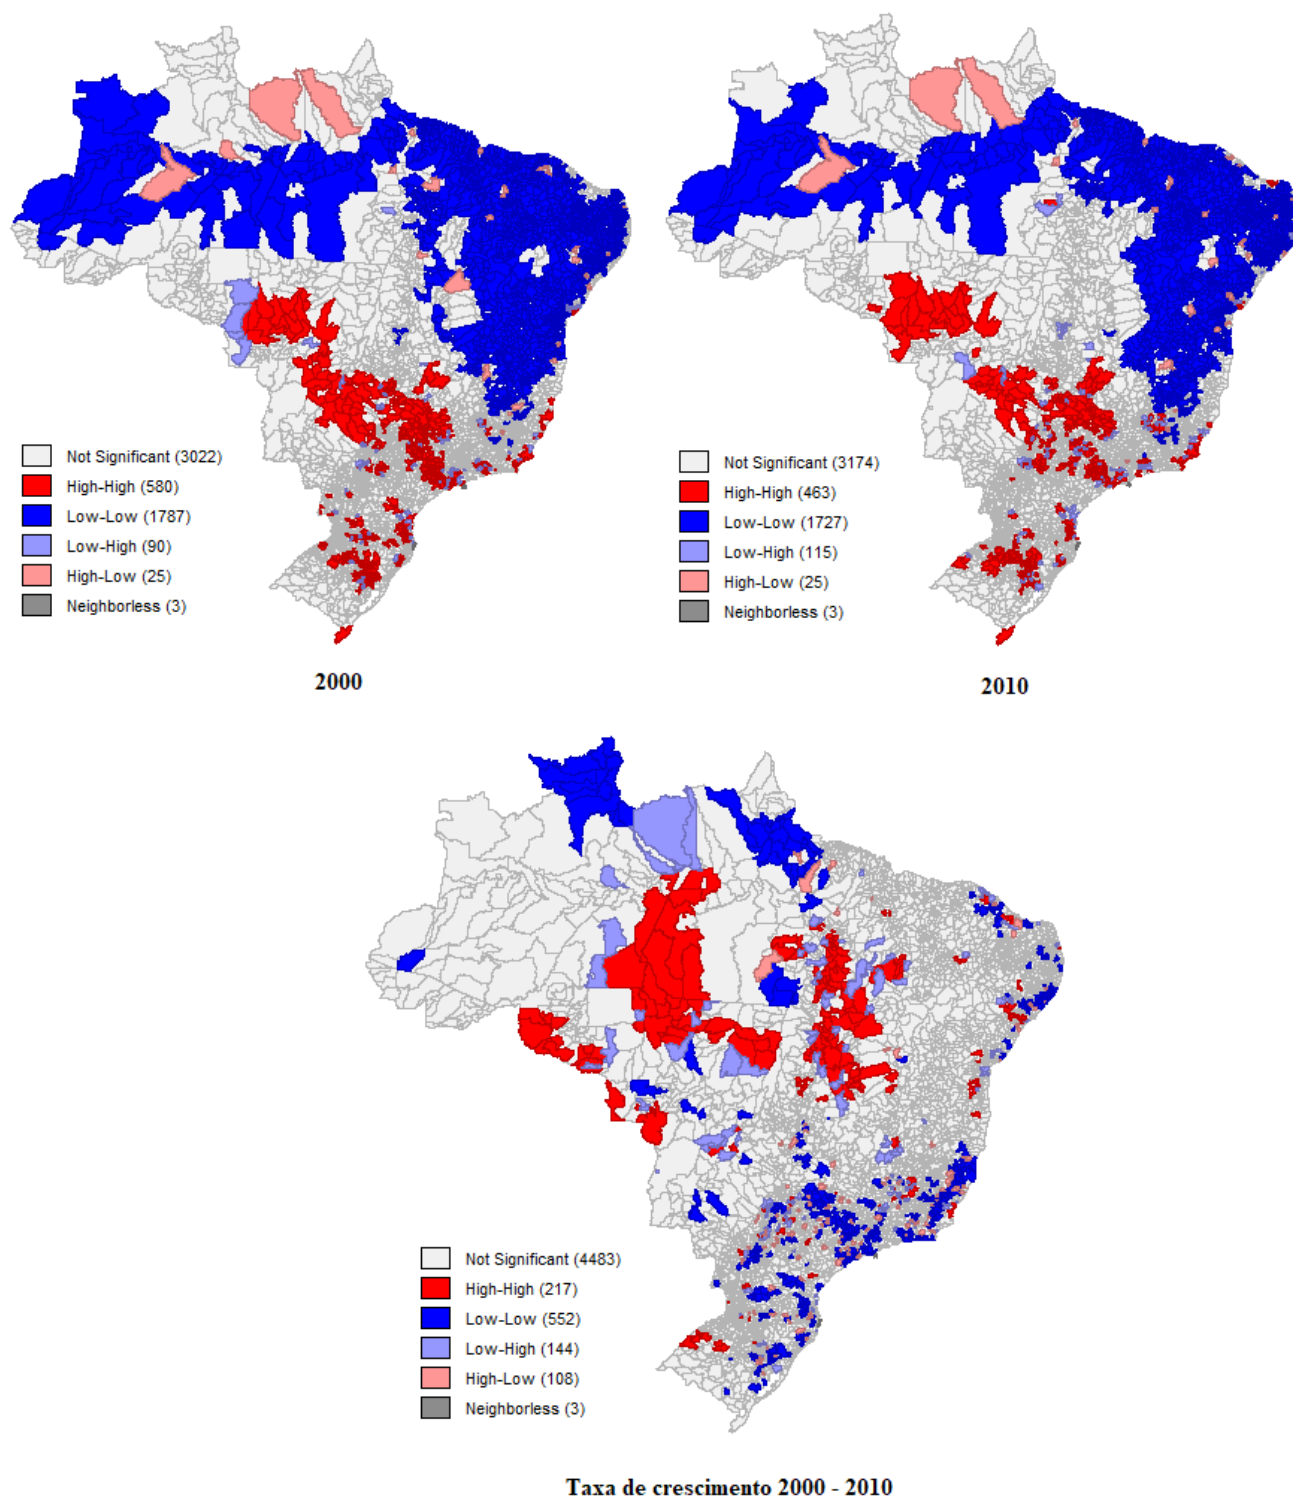


Fonte: Elaboração própria a partir do software GeoDa.

O próximo passo consiste na utilização do indicador que observa os padrões locais de associação linear e que é estatisticamente significante, sendo chamado de *Local Indicator of Spatial Association* (LISA) ou Indicador Local de Associação Espacial (ANSELIN, 1995). Na Figura 2, observa-se o LISA para o PIB per capita dos anos 2000, 2010 e para a taxa de crescimento entre os dois anos.

Os resultados mostram pouca diferença entre a aglomeração espacial do PIB *per capita* de 2000 e 2010. Nos dois anos é possível observar que o clusters alto-alto prevalecem nas regiões Sul, Sudeste e Centro-Oeste, porém o número de municípios com este tipo de *clusters* diminuiu de 2000 para 2010, sendo visível a perda no estado de Santa Catarina e Paraná. Em 2010, é possível observar *clusters High-High* na região do Nordeste, diferente de 2000 que era encontrado somente um *clusters*.

Figura 2 – Análise de Aglomeração Espacial



Fonte: Elaboração própria a partir do software GeoDa.

Nota: (a) PIB per capita de 2000 e (b) PIB per capita de 2010 e c) taxa de crescimento 2000 - 2010

Em relação a taxa de crescimento entre os dois anos observa-se número menor de municípios com *clusters* alto-alto que estão concentrados no Nordeste⁸, Centro-Oeste⁹ e Norte¹⁰ do país. Os indicadores locais de associação espacial para a taxa de crescimento dos municípios brasileiros indicaram os seguintes padrões locais de *clusters*: *High-High* (217); *Low-Low* (552); *Low-High* (144) e *High-Low* (108), enquanto os demais municípios não apresentam vizinhos com significância.

Para corroborar com os resultados foi realizado o mapa de *clusters* bivariados entre a taxa de crescimento e a variável *proxy* de capital humano. Analisando de forma geral, o *clusters Low-High* (Figura 3) prevalecem entre os municípios do país, ou seja, municípios que apresentam baixa taxa de crescimento estão cercados por municípios vizinhos que apresentam alto capital humano. O LISA identificou os seguintes padrões locais de *clusters*: *High-High* (435); *Low-Low* (809); *Low-High* (1.083) e *High-Low* (663), enquanto os demais municípios não apresentam vizinhos com significância.

Na região Norte, prevalece o *clusters Low-Low*, ou seja, municípios com baixa taxa de crescimento estão cercados por municípios com baixo capital humano. Nessa região encontra-se apenas um município que apresenta o *clusters High-High*¹¹.

Na região Nordeste, encontra-se diversos *clusters Low-Low* e *High-Low*, enquanto são encontrados apenas cinco municípios com *clusters High-High*, que estão alocados no estado¹²

⁸ Nordeste: MA: Alto Parnaíba, Antônio Almeida, Bernardo do Mearim, Carolina, Estreito, Igarapé Grande, BA: Aiquara, Barra do Rocha, Coribe, Correntina, Dário Meira, Elísio Medrado, Ibicuí, Ipiauí, Itagi, Itagiba, Itapebi, Feira da Mata, Formosa do Rio Preto, Gongogi, Pedreiras, Rafael Jambeiro. PI: Alegrete do Piauí, Bertolínia, Caldeirão Grande do Piauí, Manoel Emídio, Landri Sales, Marcos Parente, Pedro Alexandre, Ribeiro Gonçalves, Santa Brigida, Sebastião Leal, São Julião, Uruçuí. CE: Pentecoste, São Luís do Curu, Salitre, Russas. SE: Capela, Carira, Jaguaruana, Japarutuba, Maruim, Nossa Senhora Aparecida, Nossa Senhora das Dores, Poço Redondo, Pinhão. RN: Barauna. PE: Mataraca, Tupanatinga,

⁹ Centro-Oeste: MT: Alta Floresta, Alto Taquari, Araguaína, Alto Boa Vista, Apiacás, Cáceres, Castanheira, Cotriguaçu, Nova Bandeirantes, Figueirópolis D' Oeste, Juara, Querência, Marcelândia, Nova Canaã do Norte, Itaúba, Nova Guarita, Nova Monte Verde, Novo Mundo, Paranaíta, Porto dos Gauchos, Ribeirãoascalheira, Vila Bela da Santíssima Trindade, Tabaporã, União do Sul. MS: Pedro Gomes. GO: Cavalcante, Campos Verde, Damianópolis, Flores de Goiás, Guarani de Goiás, Iaciara, Mara Rosa, Mimosas de Goiás, Mambai, Monte Alegre de Goiás, Nova Iguaçu de Goiás, Pilar de Goiás, São João D'Aliança, São Domingos, Posse,

¹⁰ Norte: RO: Alto Alegre do Parecis, Chupinguaia, Corumbiara, Parecis, Pimenteiras do Oeste. AM: Apuí, Maués, Parintins. PA: Água Azul do Norte, Aveiro, Costa Marques, Curionópolis, Jacareacanga, Itaituba, Novo Progresso, Parauapebas, Santarém, São João do Araguaia, Xinguara. TO: Alvorada, Angico, Arraias, Babaçulândia, Bandeirantes do Tocantins, Barra do Ouro, Brasilândia do Tocantins, Brejinho de Nazaré, Bom Jesus do Tocantins, Conceição do Tocantins, Chapada da Natividade, Darcinópolis, Esperantina, Filadélfia, Guaraí, Goiatins, Ipueiras, Itacajá, Itapiratins, Lizarda, Maurilândia do Tocantins, Miranorte, Monte do Carmo, Mateiros, Mosquito, Natividade, NAZARÉ, Novo Acordo, Palmas, Palmeirópolis, Palmeirante, Paranã, Peixe, Presidente Kennedy, Ponte Alto do Tocantins, Recursolândia, Riachinho, Rio dos Bois, São Bento do Tocantins, São Félix do Tocantins, São Salvador do Tocantins, São Valério da Natividade, São Sebastião do Tocantins, Santa Maria do Tocantins, Santa Rosa do Tocantins, Silvanópolis, Sítio Novo do Tocantins, Sucupira, Talismã, Tocantinópolis, Tupirama, Tupiratins, Wanderlândia.

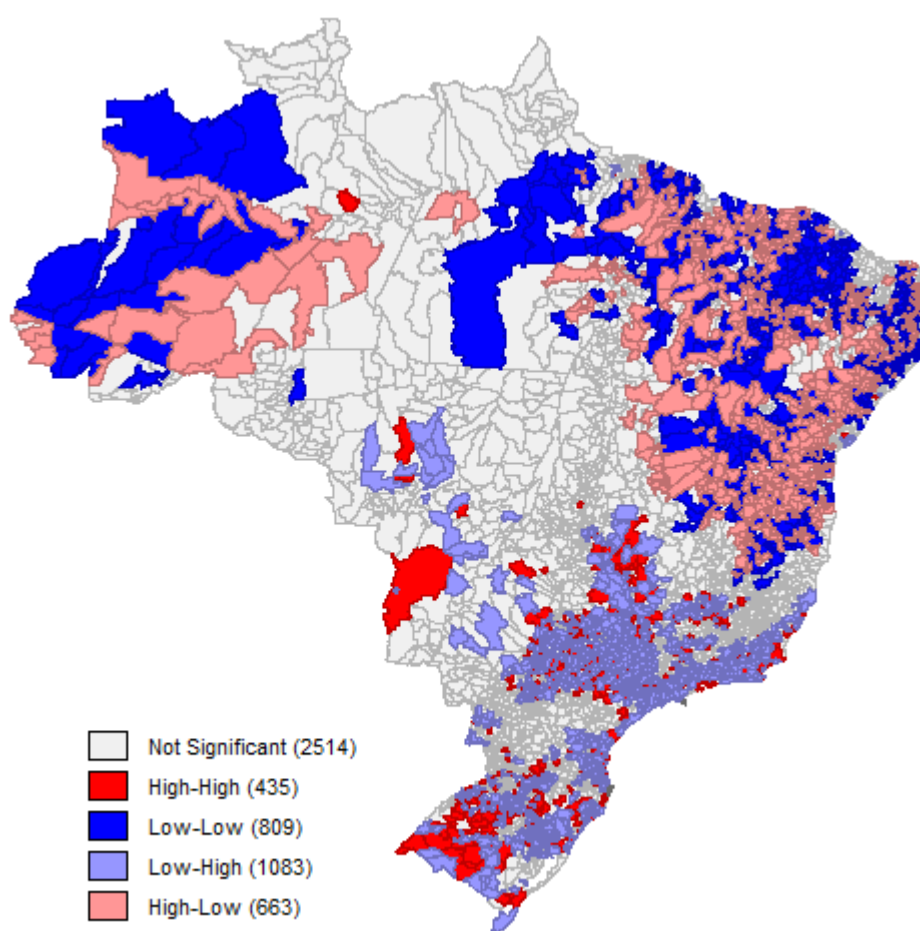
¹¹ AM: Rio Preto da Eva.

¹² BA: Candeias, Lauro de Freitas e São Sebastião do Passe. SE: Nossa Senhora do Socorro. PE: Jaboatão dos Guarapes.

da Bahia, Pernambuco e Sergipe. Na região Centro-Oeste encontram-se alguns municípios com *clusters High-High e High-Low*.

Na Região Sul e Sudeste prevalecem os *clusters Low-High e High-High*. Municípios que apresentam baixo (alto) taxa de crescimento estão cercados por municípios vizinhos com alto capital humano. Observa-se nos estados de São Paulo e Rio Grande do Sul que estão alocados a maior quantidade de *clusters High-High*, ou seja, municípios que apresentam alta taxa de crescimento estão cercados por municípios vizinhos que apresentam alto capital humano.

Figura 3 – *Cluster* bivariado entre taxa de crescimento e a variável *proxy* de capital humano



Fonte: Elaboração própria a partir do software GeoDa.

Após realizar os procedimentos de análise exploratória de dados espaciais e confirmar por meio da estatística I de Moran nos erros do modelo de Mínimos Quadrados Ordinários

(MQO), a presença de autocorrelação espacial, tem-se a justificativa para a utilização das técnicas de econometria espacial.

4.2 Resultados do Modelo Econométrico

A Tabela 3, apresenta os resultados para o modelo MQO, demonstrando que todas as variáveis são significativas, exceto taxa de homicídios. Encontrou-se sinal negativo para a variável PIB *per capita* e população, enquanto, a variável capital humano mostrou influenciar de forma positiva o modelo.

Tabela 3 – Resultados da Regressão em MQO

Variável	Coef.	Desvio-padrão	t	p-valor
Constante	110.307	9.14759	12.0586	0.00000
PIB₂₀₀₀	-15.6569	2.13036	-7.34941	0.00000
CAPHUMANO	13.9271	4.59829	3.02875	0.00247
POP	-6.87422	1.0133	-6.78401	0.00000
TXHOM	0.942949	0.750973	1.25564	0.20931
R2	0.2018			
Jarque-Bera	0.0000			
Breush-Pagan	0.0000			

Fonte: Elaboração própria a partir do software GeoDa.

No modelo de MQO, o teste *Jarque-Bera*, que analisa a normalidade dos erros, indica que os erros não seguem uma distribuição normal, podendo gerar problemas na estimação, mesmo se o teste “*Multicollinearity condition number*” apresentar valor inferior a 30 (= 27.117872), no qual indica a não existência de multicolinearidade. Enquanto, o teste *Breush-Pagan*, que apresenta como hipótese nula a homocedasticidade, tem-se a rejeição com 1% de significância da hipótese nula. Desta forma o modelo apresenta o problema¹³ da heterocedasticidade.

Com a questão espacial, o modelo clássico de regressão linear é inadequado para explicar as relações entre as variáveis, sendo necessária a estimação de modelos que considerem

¹³ Foi testado o modelo de robustez no GeodaSpace.

a dependência espacial. Com a indicação de existência de dependência espacial,¹⁴ foi utilizado o modelo econométrico espacial.

4.2.1 Modelos Econométricos Espaciais

Antes de estimar o modelo espacial é necessário detectar a ocorrência de autocorrelação espacial e verificar qual o modelo espacial mais indicado, sendo possível por meio dos resultados estimados por MQO, conforme a Tabela 4.

Tabela 4 – Diagnóstico de Dependência Espacial

Teste	Valor	Prob.
Moran's I	6.6621	0.00000
MLλ (erro)	43.4454	0.00000
ML*λ (erro robusto)	4.2947	0.03823
MLρ (defasagem)	40.5483	0.00000
ML*ρ (defasagem robusta)	1.3976	0.23713

Fonte: Elaboração própria a partir do software GeoDa.

Conforme os procedimentos de Florax et al. (2003) observa-se na Tabela 3, que os testes dos Multiplicadores de Lagrange, tanto o de erro como o de defasagem (ML λ e ML ρ) mostraram-se estatisticamente significantes a 1%. Desta forma, afirma-se que o MQO não é mais apropriado. É preciso verificar as versões robustas dos dois testes (ML* λ e ML* ρ) e escolher o modelo mais apropriado. O modelo ML* λ é significativo a 5%, enquanto o teste ML* ρ não é significativo. Desta forma, conforme os procedimentos de Florex et al. (2003) o modelo mais apropriado¹⁵ para análise é o de Erro Autorregressivo Espacial (SEM).

Os resultados para o modelo SEM (Tabela 5) mostraram que todas as variáveis são significativas, exceto taxa de homicídios, da mesma forma que ocorreu no modelo de MQO. As variáveis PIB *per capita* e população mostraram ser negativas, enquanto as demais variáveis são positivas. O coeficiente do PIB *per capita* é negativo e significativo, mostrando que os municípios com níveis iniciais mais baixos tendem a crescer mais rapidamente que os

¹⁴ O teste de Moran's I apresentou ser igual a 0.0530 (com significância de 0.0000).

¹⁵ No Apêndice B.1 e B.2 - Resultado dos modelos SAR e SAC encontra-se os resultados dos demais modelos sugeridos na metodologia.

municípios com maiores níveis de renda. Esse resultando também encontramos em demais trabalhos como Resende e Silva (2007) e Leivas et al. (2015).

Tabela 5 - Resultados da Regressão para o modelo espacial

Variável	Coef	Std. Error	z-statistic	Prob.
Constante	109.623163	9.3717530	11.6971888	0.0000000
PIB₂₀₀₀	-16.1243976	2.2081499	-7.3022206	0.0000000
CAPHUMANO	13.6844649	4.8235542	2.8370087	0.0045538
TXHOM	0.8319497	0.7710394	1.0789977	0.2805888
POP	-6.7032489	1.0511855	-6.3768468	0.0000000
Lambda	0.1323095	0.0203727	6.4944337	0.0000000
R2	0.2018			

Fonte: Elaboração própria a partir do software GeoDaSpace.

A *proxy* de capital humano, apresentou sinal positivo, no qual demonstra quanto maior for o nível de escolaridade da população, maior será a taxa de crescimento do município. Ocorrendo um aumento de 1% nessa variável, ocorrerá elevação de 13,68% da taxa de crescimento. Outro estudo que analisou os municípios do Brasil foi Leivas et al. (2015), porém diferentemente deste estudo levou em consideração a qualidade institucional. Os autores confirmaram o resultado mostrando que a *proxy* para o capital humano, mostrou-se positivo para o coeficiente, indicando que maior escolaridade média dos municípios melhora a qualidade institucional da mesma forma que impacta de forma positiva sobre o crescimento.

O resultado também está alinhado com Resende e Silva (2007) que encontraram para os municípios da Região Sul do país que a *proxy* do grau de escolaridade (número médio de anos de estudo), apresentou sinal positivo, demonstrando quanto maior for o nível de escolaridade da população, maior será a taxa de crescimento da renda do trabalho do município.

O estudo para as microrregiões do Paraná também encontrou resultados que indicam a elevação do capital humano provocou impactos positivos sobre a produtividade da economia do Paraná e, conseqüentemente, sobre o crescimento econômico da região (RAIHER; DATHEIN, 2009).

A variável população mostrou-se com sinal negativo, conforme Hanushek e Kimko (2000, p. 1190), “*The estimates of the impact of population growth on the rate of economic growth, while always negative, are quite sensitive to specification and are not significantly different from zero when quality is considered*”. Os autores acrescentam que renda mais alta

pode levar o país reduzir sua taxa de natalidade. Esse resultado foi diferente de outros da literatura, Resende e Silva (2007) encontraram coeficiente estimado positivo e estatisticamente significativo a 1%.

5 CONSIDERAÇÕES FINAIS

Com a importância do capital humano para o desenvolvimento de um país, o artigo propôs analisar a influência do capital humano sobre a taxa de crescimento dos municípios do Brasil através dos padrões geográficos de aglomeração espacial. Com a aplicação da análise exploratória verificou-se a dependência espacial positiva, no qual o resultado o I de Moran Global apresentou positivo e estatisticamente significativo.

No mapa de *clusters* bivariados entre a taxa de crescimento e a variável *proxy* de capital humano prevaleceu o *clusters Low-High* (663), ou seja, municípios que apresentam baixa taxa de crescimento econômico estão cercados por municípios que apresentam alto capital humano, seguido pelo *clusters Low-Low* (809). Na região Norte, prevalece o *clusters Low-Low*, ou seja, municípios com baixa taxa de crescimento estão cercados por baixo capital humano, nessa região encontra-se apenas um município que apresenta o *clusters High-High*.

Na região Nordeste, encontram-se diversos *clusters Low-Low* e *High-Low*, enquanto são encontrados apenas cinco municípios com *clusters High-High*, que estão alocados no estado da Bahia, Pernambuco e Sergipe. Na região Centro-Oeste predomina *clusters* não significativos, com alguns municípios *High-High* e *High-Low*. Na Região Sul e Sudeste prevalecem os *clusters Low-High* e *High-High*. Municípios que apresentam baixo (alto) taxa de crescimento estão cercados por municípios vizinhos com alto capital humano. Observa-se nos estados de São Paulo e Rio Grande do Sul que estão alocados a maior quantidade de *clusters High-High*, ou seja, municípios que apresentam alta taxa de crescimento estão cercados por municípios vizinhos que apresentam alto capital humano.

No modelo econométrico por meio do diagnóstico de dependência espacial indicou-se que o modelo SEM é o mais adequado para análise. O modelo espacial mostrou que todas as variáveis são significativas, exceto taxa de homicídios. As variáveis PIB *per capita* e população mostraram ser negativas, enquanto as demais variáveis são positivas. O coeficiente do PIB *per capita* é negativo e significativo, mostrando que os municípios com níveis iniciais mais baixos tendem a crescer mais rapidamente que os municípios com maiores níveis de renda.

A *proxy* de capital humano, apresentou sinal positivo, demonstrando quanto maior for o nível de escolaridade da população, maior será a taxa de crescimento do município. A variável *proxy* para capital humano mostrou que ocorrendo um aumento de 1% nessa variável, ocorrerá elevação de 13,68% da taxa de crescimento.

Somente a *proxy* de capital humano não é capaz de explicar o aumento da taxa de crescimento de um município, porém é uma variável importante. Por mais que no mapa de *clusters* bivariado entre taxa de crescimento e a variável *proxy* de capital humano mostrou a permanência do *clusters Low-High* entre os municípios do país, podemos observar a importância do *clusters High-High* nos municípios da região Sul e Sudeste do país. No modelo econométrico espacial também tivemos resultado positivo para o capital humano, sendo que a constante mostrou como essa variável influência de forma positiva a taxa de crescimento do PIB *per capita* dos municípios.

Esses resultados foram próximos aos encontrados na literatura, como Resende e Silva (2007), Barreto e Almeida (2009), Raiher e Dathein (2009) e Leivas et al. (2015), porém os autores citados analisaram regiões específicas do país. Em Resende e Silva (2007) os resultados demonstraram quanto maior for o nível de escolaridade da população dos municípios da região sul, maior será a taxa de crescimento da renda do trabalho do município.

Os resultados de Raiher e Dathein (2009) também foram semelhantes, porém os autores analisaram as microrregiões do Paraná. Os autores encontraram que a elevação do capital humano provocou impactos positivos sobre a produtividade da economia do Paraná e, conseqüentemente, sobre o crescimento econômico da região. Na literatura atual, somente Leivas et al. (2015) analisaram os municípios do Brasil, quando comparado os resultados referente a influencia do capital humano, os trabalhos chegam na mesma conclusão em que a *proxy* para o capital humano, mostrou-se positivo para o coeficiente, indicando que maior escolaridade média dos municípios melhora a qualidade institucional da mesma forma que impacta de forma positiva sobre o crescimento.

A literatura é vasta com trabalhos que estudam crescimento econômico por meio do aspecto de convergência, sendo que o artigo teve como objetivo analisar a influência do capital humano. Os resultados presentes no artigo não esgotam a importância da análise do capital humano sob o crescimento econômico dos municípios. Sugere-se em relação a pesquisas futuras, que além dos resultados empíricos o artigo traga respostas em relação a políticas públicas que possam ajudar o país investir em capital humano.

REFERÊNCIAS

ALMEIDA, Eduardo. **Econometria Espacial Aplicada**. Campinas, SP: Editora Alínea; 2012.

ANSELIN, L. **SpaceStat Tutorial: A Workbook for Using SpaceStat in the Analysis of Spatial Data**. 1992. Disponível em: http://www.spacestat.com.docs/spacestat_tutorial.pdf. Acesso em: 12 jul. 2017.

ANSELIN, L. Local indicators of spatial association – LISA. **Geographical Analysis**, v. 27, n. 2, p. 93-115, 1995.

ATLAS DO DESENVOLVIMENTO HUMANO NO BRASIL. Disponível em: <http://atlasbrasil.org.br/2013/pt/download/>. Acesso em: 20 maio. 2019.

BARRETO, R. C. S.; ALMEIDA, E. S. A contribuição do capital humano para o crescimento econômico e convergência espacial do PIB per capita no Ceará. *In*: M. C. Holanda, E. B. S. Carvalho & M. P. Barbosa. **Economia do Ceará em Debate 2008**, Fortaleza: IPECE; 2009.

CANGUSSU, R. C.; SALVATO, M. A.; NAKABASHI, L. Uma análise do capital humano sobre o nível de renda dos estados brasileiros: MRW Versus Mincer. **Revista Estudos Econômicos**, São Paulo; v. 40, n. 1, p. 153-183, 2010.

EMILIO, D. R.; BELLUZZO, W. J.; ALVEZ, D. C. O. Uma análise econométrica dos determinantes do acesso à universidade de São Paulo. **Pesquisa e Planejamento Econômico**, v. 34, n. 2, 2004.

FIGUEIREDO, L. Decomposição de nível para os estados brasileiros: 1970-2010. Belo Horizonte: UFMG/Cedeplar, 2012. (Texto para Discussão, n. 466), 2012.

FLORAX, R.; FOLMER, H.; REY, S. Specification searches in spatial econometrics: the relevance of Hendry's methodology. **Regional Science Urban Economics**, v. 22, n. 5, p. 557-579, 2003.

GALEANO, E. A. V.; MATA, H. T. da. C. Diferenças regionais no crescimento econômico: uma análise pela Teoria do Crescimento Endógeno. **REN**, Documento técnico-científicos, v. 40, n. 04, out-dez. 2009.

HANUSHEK, E. A. KINKO D.D. Schooling, labor-force quality and growth of nations. **American Economic Review**, v. 90, n. 3, 2000.

INSTITUTO DE PESQUISA ECONOMICA APLICADA – IPEADATA. Dados macroeconômicos e regionais. Disponível em: < <http://www.ipeadata.gov.br>>. Acesso em: 10 abr. 2018.

KELEJIAN, H. H.; PRUCHA, I. R. A Generalized Spatial Two-Stage Least Squares Procedure for Estimating a Spatial Autoregressive Model with Autoregressive Disturbances. **Journal of Real Estate Finance and Economics**, v. 17:1, 99-121, 1998.

KROTH, D. C.; DIAS, J. Os efeitos dos investimentos público e privado em capitais físico e humano sobre o produto per capita dos municípios da região sul: uma análise em painéis de dados dinâmicos. **Nova Economia**; Belo Horizonte; 22 (3); p. 621-649; set-dez. 2012.

LE GALLO, J.; ERTHUR, C. Exploratory spatial data analysis of the distribution of regional per capita. GDP in Europe, 1980-1995. **Papers in Regional Science**, v. 82, n. 2, p 175-201. 2003.

LEIVAS, P. H. S.; MENEZES, G. R.; CRAVO, T. A.; SANTOS, A. M. A. A geografia das instituições: uma abordagem espacial para os municípios brasileiros. **Revista Brasileiras de Estudos Regionais e Urbanos**, v. 09, n. 2, p. 169-185, 2015.

LUCAS, R.E. On the mechanics of economic development. **Journal of Monetary Economics**, v. 22, p. 3-42, 1988.

MONASTERIO, L.M.; ÁVILA, R. P. Uma análise espacial do crescimento econômico do Rio Grande do Sul (1939-2001). **Anais**; XXXI Encontro Nacional de Economia ANPEC, 2004 Disponível em: <http://www.anpec.org.br/encontro2004/artigos/A04A113.pdf>.

MONTENEGRO, R. L.G.; LOPES, T. H. C. R.; RIBEIRO, L. C. de S.; CRUZ, I. S.; ALMEIDA, C. P. C de. Efeitos do crescimento econômico sobre os estados brasileiros (1992-2006). **Economia aplicada**; v. 18, n. 2, p. 215-241; 2014.

ORGANIZAÇÃO PARA A COOPERAÇÃO E DESENVOLVIMENTO ECONÔMICO - OCDE. *The Well-Being of Nations: The Role of Human and Social Capital. Education and Skills*. OCDE, Paris, 2001.

PEROBELLI, F. S.; ALMEIDA, E. S. de; ALVIM, M. I. da S.; FERREIRA, P. G. C. Produtividade do setor agrícola brasileiro (1991-2003): uma análise espacial. **Nova economia**, v. 17, n.1, p.65-91, 2007.

PIMENTEL, E. A.; HADDAD, E. A. Análise da Distribuição Espacial da Renda dos Municípios de Minas Gerais: uma abordagem setorial. Texto para discussão, NEREUS 02-2004; São Paulo; 2004.

RAIHER, A. P.; DATHEIN, R. Análise espacial e intertemporal do capital humano nas microrregiões paranaenses. **Revista Paranaense de Desenvolvimento**, Curitiba, n. 116, p. 33-68, 2009.

RESENDE, G. M.; SILVA, A. M. A. Crescimento Econômico dos Municípios da Região Sul do Brasil: uma análise espacial. **Ensaio FEE**, Porto Alegre, v. 28, n. 2, p. 549-576, 2007.

ROCHA, C. B.; PARRÉ, J. L. Estudo da distribuição espacial do setor agropecuário do Rio Grande do Sul. **Análise Econômica**, Porto Alegre, v. 27, n. 52, p. 139-160, 2009.

ROMER, P. M. Increasing returns and long-run growth. **The Journal of Political Economy**, Chicago: University of Chicago Press, v. 94, n. 5, p. 1002-1037, 1986.

ROMER, P. M. Human capital and growth: theory and evidence. **NBER, Working Paper**, Cambridge: National Bureau of Economic Research, n. 3173, 1989.

APÊNDICE A**A1 – Determinação da matriz de peso****I de Moran para escolha da matriz de peso**

		I
Quem	1 ^a	0.0585
	5 ^a	0.0215
Rook		0.0580

APÊNDICE B

B.1 – Resultado do modelo SAR

Resultados do Modelo de Defasagem Espacial (SAR)

Variável	Coef	Std. Error	z-statistic	Prob.
Constante	127.464315	14.926834	8.53922731	0.0000000
<i>PIB</i> ₂₀₀₀	-16.98195	2.349569	-7.227708	0.000000
CAPHUMANO	14.113021	4.685788	3.011878	0.002596
TXHOM	0.995844	0.765829	1.300347	0.193482
POP	-7.323219	1.076368	-6.803638	0.000000
W_txcresc	-0.247505	0.168216	-1.471351	0.141196
R2	0.2021			

Fonte: Elaboração própria a partir do software GeoDaSpace.

B.2 - Resultado do modelo SAC

Resultados do Modelo de Defasagem Espacial com Erro Autorregressivo Espacial (SAC)

Variável	Coef	Std. Error	z-statistic	Prob.
Constante	129.280602	13.945206	9.270613	0.000000
<i>PIB</i> ₂₀₀₀	-17.730643	2.327221	-7.618806	0.000000
CAPHUMANO	11.142574	5.392631	2.066259	0.038804
TXHOM	0.669016	0.789034	0.847891	0.396498
POP	-6.387624	1.118277	-5.712026	0.000000
Lambda	0.420217	0.137113	3.064745	0.002179
W_txcresc	-0.365493	0.196981	-1.855474	0.063529
R2	0.2022			

Fonte: Elaboração própria a partir do software GeoDaSpace.

3 PADRÕES GEOGRÁFICOS DAS AGROINDÚSTRIAS DE ALIMENTOS: UMA ANÁLISE DAS MICRORREGIÕES DO BRASIL PARA O ANO 2016

Resumo

O presente estudo propõe verificar os padrões geográficos das indústrias de alimentos dispostos nas microrregiões do Brasil a fim de apurar se ocorre o fenômeno de concentração/aglomeração agroindustrial em torno das cidades metropolitanas. Como base metodológica utilizou-se a Análise Exploratória de Dados Espaciais (AEDE) e econometria espacial por meio das variáveis explicativas PIB *per capita*, participação do VAB agropecuário e industrial, educação, densidade populacional e uma *dummy* para região metropolitana. Os resultados demonstraram a existência de autocorrelação espacial positiva, ou seja, com a existência de dependência espacial o modelo mais adequado é o Modelo de Defasagem Espacial com Erro Autorregressivo Espacial (SAC). Pode-se concluir que a indústria de alimentos favorece um desenvolvimento mais concentrado onde estão alocadas a maior população, mão-de-obra qualificada e o mercado consumidor.

Palavras-chave: Desenvolvimento regional; Agroindústrias; Microrregiões; Análise Exploratória de Dados Espaciais; Econometria Espacial.

Abstract

The present study proposes to verify the geographic patterns of the food industries arranged in the microregions of Brazil in order to ascertain whether the phenomenon of agro-industrial concentration / agglomeration around metropolitan cities occurs. The methodological basis was based on Exploratory Spatial Data Analysis (ESDA) and spatial econometrics through the explanatory variables GDP per capita, agricultural and industrial GVA participation, education, population density and a dummy for the metropolitan or non-metropolitan region. The results demonstrated the existence of positive spatial autocorrelation. As spatial dependence was found, the Spatial Autoregressive Error Spatial Lag Model (SAC) was used. It can be concluded that the food industry favors more concentrated development where the larger population, qualified labor and the consumer market are located.

Keywords: Regional development; Agribusiness; Microregions; Exploratory Spatial Data Analysis; Space Econometrics.

1 INTRODUÇÃO

O agronegócio é um conjunto de atividades derivadas e dependentes da produção da agricultura e da agropecuária, que representa uma cadeia produtiva que envolve desde a fabricação de insumos até o seu consumo final (GASQUES et al., 2004). O estudo do agronegócio é dividido em três partes: a primeira, “dentro da porteira” que trata os negócios agropecuários propriamente ditos, por meio dos próprios produtores rurais (pequenos, médios ou grandes produtores). A segunda parte, é a “pré-porteira” ou os negócios à montante da agropecuária, sendo representada pela indústria e comércio que fornecem os insumos necessários para a produção rural; e a terceira parte, “pós-porteira” à jusante dos negócios agropecuários, ou seja, onde estão a compra, transporte, beneficiamento e venda dos produtos até o consumidor final (LOURENÇO; LIMA, 2009).

A reestruturação produtiva do país ocorreu a partir do fim da década de 1980 decorrente da abertura econômica, formação do Mercosul, desregulamentação estatal e o processo de estabilização econômica no câmbio e taxa de juros. Com essa estruturação foi possível a formação de um ambiente competitivo interferindo no sistema agroindustrial brasileiro resultando, dessa forma, na obtenção de maiores ganhos de produtividade e maior eficiência dos recursos produtivos (ALVIM, 2003).

O agronegócio representa um dos principais e mais dinâmicos setores de atividade econômica no país. Em 2016, apresentou um crescimento acumulado de 4,48%, enquanto o PIB brasileiro registrou um recuo de 3,6%, justificativa pela valorização acumulada dos preços, especialmente para os setores primários (CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA - CEPEA, 2017). O resultado positivo é confirmado por meio do valor bruto da produção agropecuária, que em 2016, foi de R\$ 527,9 bilhões. A agropecuária também fortalece as divisas, sendo que em 2016, as exportações do complexo representaram 45,9% do total das exportações, gerando um saldo de US\$ 71,3 bilhões para a Balança Comercial (BRASIL, 2017).

Conforme a Associação Brasileira da Indústria de Alimentos (ABIA, 2016), o ano de 2016, foi marcado pela recuperação da confiança no cenário político e econômico. O cenário positivo trouxe como resultado a elevação do faturamento nominal em 9,3%, sendo que a indústria da alimentação correspondeu ao maior faturamento da indústria de transformação, R\$ 614,3 bilhões e o setor que mais empregou com 1,6 milhão de funcionários.

Com a importância econômica da produção agroindustrial e principalmente com a produção da indústria de alimentos tem-se que os espaços urbanos próximos ao espaço agrícola precisam atender suas principais demandas para fornecer de forma eficiente “aporte técnico, financeiro jurídico, de mão de obra e de todos os demais produtos e serviços necessários à sua realização” (ELIAS, p. 159, 2011).

Em função da importância o agronegócio para a economia brasileira e os espaços urbanos, este estudo dedica-se a responder o seguinte questionamento: a indústria de alimentos se desenvolve de forma concentrada ou desconcentrada espacialmente? A pergunta central deste estudo tem como motivação a constatação da hipótese na literatura clássica (Weber, 1929) que as agroindústrias tendem a ser uma atividade com orientação geográfica aos insumos, ou seja, suas plantas estão concentradas próximas às matéria-prima.

Ao diagnosticar a importância das agroindústrias no Brasil, o estudo apresenta como objetivo principal verificar os padrões geográficos das agroindústrias de alimentos dispostos em todas as microrregiões do Brasil para o ano de 2016, a fim de apurar se ocorre o fenômeno de concentração/aglomeração agroindustrial em torno das microrregiões metropolitanas. Esta hipótese se contrapõe à ideia segundo a qual os insumos atraem geograficamente a produção agroindustrial, como mencionado acima.

O artigo está dividido em cinco seções. A primeira traz introdução, que é seguida pela teoria da localização industrial. A terceira seção engloba a metodologia empregada a fim de se analisar os resultados que são expressos na quarta seção. Finalmente, na quinta e última discutem-se as considerações finais.

2 TEORIA DA LOCALIZAÇÃO INDUSTRIAL

Alfred Weber (1929) com seu trabalho de localização industrial tornou-se a principal referência para os desenvolvimentos posteriores, originando a chamada Teoria Clássica da Localização. A partir da racionalidade econômica por parte dos agentes e se detendo na análise de três conjuntos de fatores para explicar as escolhas locacionais das firmas: os custos de transporte das matérias-primas e do produto final, os fatores relacionados com a mão-de-obra e os fatores aglomerativos e desaglomerativos (ARAÚJO, 2002).

As teorias da localização originadas pelos trabalhos de Weber (1929) e Lösch (1954) possuem como hipótese comum, que as indústrias escolhem sua localização em relação a possibilidade de maior lucro. Entre as vertentes neoclássicas, Alfred Weber determina as

normas de localização de uma empresa e August Lösch busca leis para o equilíbrio espacial. As principais características da escola são: “a) encontrar a melhor localização para a instalação de uma empresa; b) minimizar os custos totais; c) o fator determinante é o custo de transporte, buscando-se aquelas localizações onde este seja menor” (BRAGA, p. 169, 2008).

Em relação aos custos de transporte, em Weber (1909), as indústrias instalam-se onde os custos de transporte de matérias-primas e dos produtos finais sejam mínimos com objetivo de determinar a localização “ótima”. “Como dados a localização dos mercados consumidores (considerados perfeitamente elásticos), das fontes de matéria-prima (considerada infinitamente elástica a um preço dado) e da mão-de-obra (considerada também infinitamente elástica a uma taxa de salários dada)” (CAVALCANTE, p. 15, 2015).

Além dos fatores que influenciam a localização, Weber acrescentou as forças aglomerativas e desaglomerativas que estão relacionadas com as vantagens/ desvantagens por meio da concentração da produção em um determinado ponto. Nas forças aglomerativas temos como vantagens as economias de escala (economias internas) e as economias resultantes da aproximação de outras indústrias e melhores condições de infraestrutura urbana (economias externas). Enquanto, nas forças desaglomerativas as desvantagens das aglomerações que são derivadas do alto custo da terra, maior congestionamento, entre outros (ARAÚJO, 2002). É vantajoso que duas ou mais empresas se localizem no mesmo lugar, pois essa proximidade pode gerar economias de escala para reduzir os custos de transporte e criar condições positivas de infraestrutura urbana.

Outro autor importante na teoria da localização industrial é Lösch (1954), que aborda a localização ótima individual das firmas, que devem priorizar a maximização dos lucros. A principal contribuição de Lösch foi a análise de um sistema de cidades e a distribuição de atividades no espaço em forma de centros, que apresentam diferentes bens, economias de escala e custos de transporte, compondo uma rede complexa (AZZONI, 1982).

Na agropecuária, o fenômeno da dependência espacial é bastante presente, pois os produtores rurais têm facilidade para observar como os seus vizinhos estão produzindo. Acrescenta-se que as culturas agropecuárias apresentam forte dependência de recursos naturais, que estão concentrados no espaço geográfico no qual reforçam o efeito em que a produção ocorre na forma de agrupamentos (*clusters*), que estão espalhados pelo espaço econômico (ALMEIDA, 2005).

A localização ótima das agroindústrias é regida por inúmeros fatores e costuma se concentrar em determinados locais que expressam vantagens competitivas em razão de sua aglomeração. A literatura é vasta em relação ao agronegócio, sendo que os principais trabalhos

que identificam a localização espacial da produção agropecuária e das agroindústrias trazem contribuições significativas na consideração dos efeitos da localização espacial. A Tabela 1 elenca os principais autores.

Tabela 1 - Estudos relevantes sobre distribuição espacial

Autor	Região / Período / Produto	Objetivo / Metodologia	Resultados
Vidigal et al. (2011)	Municípios do Estado de Minas Gerais / Período 1990 a 2007 / cana-de-açúcar	Analisar a distribuição espacial da produtividade da cana de açúcar nos municípios do Estado de Minas Gerais / Análise Exploratória de Dados Espaciais	Os municípios com maiores índices de produtividade estavam alocados principalmente no Triângulo Mineiro e nas regiões Central Mineira, Sul/Sudoeste de Minas e Campo das Vertentes, com a existência de autocorrelação espacial positiva entre os municípios e o prevailecimento de um cluster alto-alto (AA) no Triângulo Mineiro. Os autores concluíram que os elevados índices de produtividade nessa região são influenciados por fatores edafoclimáticos, melhorias tecnológicas e localização geográfica favorável.
Souza e Salgueiro (2007)	Microrregiões / Período 1991 a 2003 / Café	Analisar o setor de café com o objetivo de estudar a distribuição espacial entre as 558 microrregiões brasileiras, no período de 1991 a 2003 / Quociente locacional e Análise Exploratória de Dados Espaciais.	A estrutura espacial da produção do café é espacialmente concentrada, principalmente nos estados de Minas Gerais e Espírito Santo, no qual contribuíram com 70,66% da produção nacional, e em microrregiões do estado de Rondônia que apresentou quocientes locacionais muito elevado na produção.
Araújo (2002)	Rio Grande do Sul / Alimentos	Analisar a indústria de alimentos no estado do Rio Grande do Sul com o objetivo de verificar a evolução da distribuição espacial e suas relações com as fontes de matérias primas, mercado consumidor e com as economias / deseconomias de aglomeração / Análise Exploratória de Dados Espaciais	A distribuição espacial desse setor tende a seguir a distribuição das fontes de matérias-primas de origem agropecuária situando-se nos centros que apresentam as melhores condições de infraestrutura e facilidades de acesso aos mercados.

Oliveira e Rodrigues (2019)	Regiões Produtivas do Agronegócio (RPAs) / Agronegócio	Identificar e comparar a estrutura produtiva dos <i>clusters</i> do agronegócio presentes no interior do Brasil / Estatística espacial	As principais Regiões Produtivas do Agronegócio e posteriormente aplicaram análise multivariada de forma a ordenar a amostra em grupos menores de acordo com suas características espaciais. Os resultados encontrados foram que a configuração urbana é o principal fator em que gerou os <i>clusters</i> .
Buhse et al. (2018)	Municípios da Região Sul / Agroindústrias	Verificar os padrões geográficos das agroindústrias / Análise Exploratória de Dados Espaciais e Econometria espacial	Ocorre dependência espacial entre os municípios sendo realizado o modelo econométrico de Defasagem Espacial com Erro Autorregressivo Espacial (SAC), no qual indicaram que as agroindústrias estão se concentrando nos principais centros, ou seja, as empresas estão próximas de locais com maior população onde está o mercado consumidor.
Raiher et al. (2016)	Microrregiões da Região Sul / Agropecuária	Analisar a evolução da produtividade agropecuária identificando a existência de um processo de convergência / Análise Exploratória de Dados Espaciais e econometria espacial.	As microrregiões com elevada (baixa) produtividade são rodeadas por microrregiões com alta (baixa) produtividade. O mapa de <i>clusters</i> mostrou agrupamentos locais principalmente no Rio Grande do Sul. No modelo empírico confirmou-se que existe um processo de convergência, absoluta e condicional, da produtividade da terra na Região Sul.

Fonte: Elaborada pela autora

3 METODOLOGIA

Nessa seção é apresentada a metodologia empregada. O primeiro passo é a Análise Exploratória de Dados Espaciais com o objetivo de identificar a distribuição espacial das agroindústrias. Posteriormente, é apresentado o modelo econométrico espacial, com o objetivo de fornecer o modelo, fonte dos dados e variáveis utilizadas.

3.1 Análise Exploratória de Dados Espaciais (AEDE)

A análise exploratória de dados espaciais é uma coleção de técnicas para descrever e visualizar distribuições espaciais, identificar *outliers* espaciais, descobrir *clusters* espaciais e referenciar diferentes regimes espaciais e outras formas de instabilidade espacial (ANSELIN, 1999). Para a utilização de um modelo espacial a partir da AEDE é necessário passar por algumas fases. Primeiramente, é necessário, a adoção de uma matriz de ponderação espacial

(W), sendo uma matriz quadrada de ordem n por n , em que os elementos mostram o grau de conexão espacial (ALMEIDA, 2012).

A matriz de pesos espaciais é utilizada para identificar a interdependência entre unidades espaciais. Entre suas características é destacada por ser quadrada e não estocástica, na forma em que seus elementos w_{ij} demonstram a intensidade da associação existente entre cada par de unidades i e j (LOBÃO; SILVA, 2018). Os pesos da matriz podem ser representados por medidas de distância ou de contiguidade (vizinhança). A escolha de um número fixo de vizinhos mais próximo ao invés do uso de uma matriz simples de contiguidade é melhor, em função de evitar problemas metodológicos que podem ocorrer quando há variações no número de vizinhos (LE GALLO; ERTUR, 2003).

O critério de contiguidade reflete a posição de uma unidade em relação às demais unidades no espaço, sendo que os dois critérios mais utilizados são a “Rainha” e a “Torre”. Em relação a dependência espacial pressupõe-se que regiões vizinhas apresentam um grau maior de dependência espacial do que as demais (SILVA et al., 2013).

Para a interpretação da matriz (W) é necessário a padronização dos seus valores para que cada elemento seja dividido pela soma total da linha à qual pertence, de forma que a soma de cada linha da matriz padronizada seja igual a 1 (ANSELIN, 1988). A matriz de peso pode ser expressa por:

$$I = \left(\frac{Z'_t W Z_t}{Z'_t Z_t} \right) \quad (1)$$

onde $t = 1, 2, \dots, n$

Existem várias formas de matriz de pesos, porém as do tipo Rainha (Queen) e Torre (Rook) são as mais utilizadas (ALMEIDA, 2012).

Formalmente, apresentamos considerando-se N regiões:

$$W = \begin{matrix} W_{11} & \dots & W_{1N} \\ W_{N1} & \dots & W_{NN} \end{matrix} \quad (2)$$

onde W_{ij} é a influência que a microrregião i exerce sobre a microrregião j .

Após ter a matriz de pesos é possível analisar medidas de autocorrelação espacial global e local, investigando a influência dos efeitos espaciais por intermédio de métodos quantitativos (ROCHA; PARRÉ, 2009). A presença de autocorrelação espacial é medida usualmente por estatísticas globais, como o índice global Moran's I, que é a estatística mais difundida e mede a correlação a partir do produto dos desvios em relação à média. Esta estatística fornece a

indicação formal do grau de associação linear (espacial) entre os vetores de Z_t no tempo t e a média ponderada dos valores da vizinhança, ou lags espaciais (WZ_t) (ANSELIN; 1992).

Valores de I maiores (ou menores) do que o valor esperado $E(I) = -1 / (N - 1)$ significa que há autocorrelação positiva (ou negativa). Enquanto, se os valores de I forem próximo de zero indicam a ausência de um padrão espacial entre os dados (ALMEIDA et al. 2008).

Podemos expressar ao I de Moran Global (univariado) através da equação (3).

$$I = \left(\frac{n}{S_o} \right) \left(\frac{Z'_t W Z_t}{Z'_t Z_t} \right) \quad t = 1, 2, \dots, n \quad (3)$$

onde Z_t é o vetor de n observações para o ano t na forma de desvio em relação à média; W é a matriz de pesos espaciais, sendo que os elementos w_{ij} na diagonal são iguais a zero e os elementos w_{ij} indicam a forma como a região i está espacialmente associada com a região j ; e o termo S_o é um escalar igual a soma de todos os elementos de W .

A autocorrelação espacial positiva (negativa) indica que microrregiões que apresentam alto (baixo) concentração de estabelecimentos são vizinhas de outras microrregiões que também apresentam alto (baixo) concentração de estabelecimentos agroindustriais.

Apesar de sua eficiência, a autocorrelação global pode negligenciar alguns padrões locais de autocorrelação espacial (ALMEIDA, 2012). O I de Moran Global pode esconder padrões locais ou ser influenciado por eles, sendo necessário a utilização de indicador de autocorrelação espacial local para verificar a formação de clusters (ANSELIN, 1995).

Por essa razão, as pesquisas empíricas, também, utilizam-se o I de Moran local univariado (I_i). A identificação dos padrões de localização espacial dos estabelecimentos é realizada através do local Moran I (LISA) no qual fornece um meio de visualizar e identificar diferentes padrões de distribuição espacial entre os estabelecimentos. Para capturar os padrões locais de autocorrelação espacial, Anselin (1995) propôs o *Local Indicator of Spatial Association* (LISA) que é utilizado para mostrar que ocorrem agrupamentos em função de uma vizinhança preestabelecida. O LISA deve satisfazer a dois critérios: “a capacidade, para cada observação, de indicar clusters espaciais, significativos estatisticamente; e a propriedade de que o somatório dos indicadores locais, para todas as regiões, é proporcional ao indicador de autocorrelação espacial global correspondente” (ALMEIDA, 2012, p. 125 - 126).

O coeficiente I_i de Moran Local é definido pela equação (4).

$$I_i = z_i \sum_{j=1}^n w_{ij} z_j \quad \text{para todos } j \neq i \quad (4)$$

sendo que $z_i = (y_i - \bar{y})$ e $z_j = (y_j - \bar{y})$

onde z_i corresponde o número de estabelecimentos agroindustriais de alimentos das microrregiões i padronizada; w_{ij} é o elemento da matriz de ponderação espacial (W) e z_j é o número de estabelecimentos das agroindústrias da microrregião j padronizada.

O LISA destaca-se em função de duas aplicações: o diagrama de dispersão (*scatter plot de Moran*) e o mapa de significância das medidas de associação local. O diagrama de dispersão de Moran visa identificar a associação através da correlação linear entre valores da variável de interesse que são defasados espacialmente W_z e os valores que são observados em cada unidade espacial z (ANSELIN, 1995).

De forma similar, o mapa de clusters LISA indica as correlações espaciais locais significantes por meio de quadrantes. São eles: *High-High*; *Low-Low*; *High-Low* e *Low-High*. Os agrupamentos *High-High* e *Low-Low* indicam a ocorrência de autocorrelação espacial positiva, enquanto os agrupamentos *High-Low* e *Low-High* denotam a presença de autocorrelação espacial negativa (ALMEIDA, 2012).

Além do índice de Moran local univariado, é possível analisar a autocorrelação espacial para variáveis distintas, ou seja, o relacionamento entre os valores de uma variável observada em uma região com valores de outra variável observada em outra região. Isso é possível através do I de Moran bivariado. A estatística bivariada indica o grau de associação linear entre o valor de uma variável no município i em relação a outra variável nos municípios vizinhos (ALMEIDA, 2012).

O passo subsequente para ratificar a presença de autocorrelação espacial no modelo econométrico é realizar o teste de I Moran nos resíduos dos Mínimos Quadrados Ordinários (MQO). Se a presença de autocorrelação espacial for confirmada será utilizado o modelo econométrico no qual sugere dois modelos como consta na subseção seguinte.

3.2 Econometria Espacial

A econometria tradicional e a econometria espacial têm como diferença o padrão da interação socioeconômica entre os agentes e as características da estrutura do sistema no espaço, no qual geram efeitos espaciais nos vários processos econômicos. Dentro do espaço econômico, “o padrão da interação tem uma natureza multidirecional que produz efeitos espaciais que violam o pressuposto vital do modelo clássico de regressão linear” (ALMEIDA; HADDAD;

2004, p. 513-514). O modelo econométrico tradicional sofre limitações, pois não controla os efeitos espaciais.

Na econometria espacial, o modelo a ser especificado depende dos aspectos teóricos e empíricos em que envolvem o processo espacial, sendo que as defasagens espaciais incorporadas no modelo devem capturar os efeitos que tomam as variáveis defasadas espacialmente, como W_y , W_x , W_ξ , e /ou W_ε ; variáveis que controlam a dependência espacial (ALMEIDA, 2012).

Para decidir qual o modelo econométrico espacial é mais apropriado, Florax et al. (2003) destacam os seguintes procedimentos para a escolha:

- 1) Estimar o modelo clássico de análise de regressão linear por Mínimos Quadrados Ordinários (MQO);
- 2) Testar a hipótese de ausência de autocorrelação espacial devido a uma defasagem ou a um erro por intermédio das estatísticas Multiplicador de Lagrange (ML) ρ (defasagem espacial) e Multiplicador de Lagrange (ML) λ (erro espacial);
- 3) Se ambos os testes não sejam significativos, a utilização do MQO é a mais apropriada. Caso sejam significativos, é preciso seguir para o próximo passo.
- 4) Caso ambos os testes sejam significativos, estima-se o modelo apontado como o mais significativo de acordo com as versões robustas desses testes, ou seja, Multiplicador de Lagrange Robusto (ML*) ρ (defasagem espacial) e Multiplicador de Lagrange Robusto (ML*) λ (erro espacial). Temos que: se $ML^* \rho > ML^* \lambda$ utiliza-se o modelo com defasagem espacial, ou se ocorrer ao contrário, $ML^* \rho < ML^* \lambda$, usa-se o modelo de erro auto regressivo. Se esse passo não for satisfeito, é preciso seguir para o próximo passo.
- 5) Se o teste $ML^* \rho$ é significativo e o $ML^* \lambda$ não, adote o modelo de defasagem espacial. Caso contrário, segue para o próximo passo;
- 6) Se o teste $ML^* \lambda$ é significativo e o $ML^* \rho$ não, adote o modelo de erro espacial. Se este passo não for satisfeito, seguir para o próximo passo;
- 7) Se ambos os testes $ML^* \rho$ e $ML^* \lambda$ forem significativos estatisticamente, é preciso utilizar o modelo de defasagem espacial com erro auto-regressivo.

Na próxima subseção serão apresentados os três modelos auto-regressivos espaciais que serão testados no estudo: o modelo de defasagem espacial, o modelo de erro espacial, e por fim o modelo de defasagem espacial com erro auto-regressivo.

3.2.1 Modelo de Defasagem Espacial (*Spatial Autoregressive Model - SAR*)

A estrutura auto-regressiva espacial pode ser combinada com um modelo de regressão convencional para produzir uma extensão espacial do modelo de regressão linear que é denominado por SAR (LESAGE, PACE; 2009). No modelo SAR a variável dependente y é influenciada por tal variável dependente, observada nas regiões vizinhas (W_y), sendo essa variável endógena, no qual implica que o valores de y nas regiões vizinhas influenciam a variável dependente no processo de causação circular (ALMEIDA, 2012). Expresso pela equação (5):

$$y = \rho W_y + X\beta + \varepsilon \quad (5)$$

onde W_y é um vetor de n por I defasagens espaciais para a variável dependente, ρ é o coeficiente autorregressivo espacial, e o X é uma matriz de variáveis explicativas exógenas.

3.2.2 Modelo de Erro Autorregressivo Espacial (*Spatial Error Model - SEM*)

Conforme Lesage e Pace (2009) pode-se utilizar defasagens espaciais para refletir dependência no processo de perturbação. O modelo SEM revela que a dependência espacial se encontra no termo de erro e não na variável dependente (ALMEIDA, 2012). Expresso pela equação (6a):

$$y = X\beta + \xi \quad (6.a)$$

$$\xi = \lambda W \xi + \varepsilon \quad (6.b)$$

onde o coeficiente λ é o parâmetro do erro autorregressivo espacial que acompanha a defasagem $W \xi$. Os erros que estão associados com qualquer observação são uma média dos erros nas regiões vizinhas mais um componente de erro aleatório, conforme (6.b) (ALMEIDA, 2012).

3.2.3 Modelo de Defasagem Espacial com Erro Autorregressivo Espacial (*Spatial Autorregressive model with Autorregressive Errors - SAC*)

O modelo SAC é uma combinação dos modelos SAR e SEM em que engloba tanto o coeficiente de defasagem espacial (ρ) quanto parâmetro do termo de erro autorregressivo (λ).

Segundo Lesage e Pace (2009) a matriz W_1 pode ser definida como W_2 , sendo que o modelo contém dependência espacial na variável dependente e nos distúrbios. A equação que (7.a) representa o modelo SAC:

$$y = \rho W_1 y + X\beta + \xi \quad (7.a)$$

$$\xi = \lambda W_2 \xi + \varepsilon \quad (7.b)$$

Após a descrição dos modelos espaciais, a subseção seguinte apresenta a descrição das variáveis utilizadas no modelo e a fonte dos dados.

3.3 Descrição das variáveis e fonte dos dados

O estudo tem como variável dependente estabelecimentos da indústria de alimentos que são classificados, de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE) em nove itens¹⁶. Como variáveis explicativas temos: Produto Interno Bruto *per capita* (PIB); participação do Valor Adicionado Bruto da Agropecuária (VABAGR); participação do Valor Adicionado Bruto da Indústria (VABIND); porcentagem de vínculos com ensino superior (CAPHUMANO); densidade demográfica (DENSID) e a variável binária (*dummy*).

A *dummy* assume o valor de 0 ou 1, com o objetivo de classificar as microrregiões em metropolitanas e não metropolitanas. Ou seja, 1, para a microrregião que está localizada em uma região metropolitana, e 0 para a microrregião que não está localizada na região metropolitana.

Segue a equação (8) com a representação do modelo, referente a distribuição de estabelecimentos:

$$Estab = \alpha + \beta_1 \ln PIB + \beta_2 \ln VABAGR + \beta_3 \ln VABIND + \beta_4 \ln CAPHUMANO + \beta_5 \ln DENSID + \beta_6 dummy + \varepsilon \quad (8)$$

¹⁶ CNAE: 10 - Fabricação de produtos alimentícios: abate e fabricação de produtos de carne; preservação do pescado e fabricação de produtos do pescado; fabricação de conservas de frutas, legumes e outros vegetais; fabricação de óleos e gorduras vegetais e animais; laticínios; moagem, fabricação de produtos amiláceos e de alimentos para animais; fabricação e refino de açúcar; torrefação e moagem de café; e fabricação de outros produtos alimentícios.

Para a análise foram utilizadas 557 microrregiões¹⁷ do Brasil, sendo que os dados de estabelecimentos, capital humano e densidade foram coletados do Relatório Anual de Informações Sociais (RAIS). As variáveis PIB, VABAGR e VABIND foram coletados do Instituto de Pesquisa Econômica Aplicada (IPEADATA). Todos os dados utilizados foram colocados em logaritmo e são do ano de 2016. Na Tabela 2, observa-se a estatística descritiva das variáveis do estudo.

Tabela 2 – Estatística descritiva

Variável	Mínimo	Mediana	Média	Máximo
ESTAB	2	405	819.314	15.912
PIB	5.637	20.130	22.569	92.332
VABAGR	0.009	12.299	14.376	55.788
VABIND	2.799	15.471	17.766	63.465
CAPHUMANO	1.729	4.256	8.477	91.438
DENS	0.414	33.116	110.158	6.287

Fonte: Elaborado pelos autores.

Os modelos SAR, SEM e SAC apresentaram ser significantes para o modelo proposto, porém através dos procedimentos de Florax et al. (2003) o modelo espacial econométrico que apresentou ser mais apropriado para a análise feita foi o SAC (lag + erro) sendo estimado pelo método *Spatial Two-Stage Least Squares* (S2SLS). Foi necessário estimar pelo método S2SLS por causa que os erros da regressão podem não possuir uma distribuição normal (KELEJIAN; PRUCHA, 1998). A metodologia AEDE e de econometria espacial foram realizadas através do *software* GeoDa e GeoDaSpace, sendo que a matriz de peso que forneceu o maior I de Moran foi a matriz Quem.

4 ANÁLISE DOS RESULTADOS

A análise dos resultados será apresentada de forma dividida. Na subseção 4.1 são apresentados os procedimentos e os resultados para a análise exploratória de dados espaciais, enquanto na subseção seguinte, o modelo que apresentou os melhores resultados para a análise econométrica espacial.

¹⁷ Divisão geográfica regional do país vigente entre 1989 e 2017, segundo a composição elaborada pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2017).


4.1 Análise Exploratória de Dados Espaciais

O primeiro passo para análise espacial é verificar qual a matriz de pesos espacial melhor se adapta ao modelo proposto. Foram estimadas diferentes matrizes no qual verificou-se que a matriz Quem 1 apresenta maior coeficiente do I de Moran Global, portanto, é essa matriz de pesos que será utilizada nos demais testes, além da estimação dos modelos econométricos.

O diagrama de dispersão do I de Moran Global (Figura 1) demonstra a presença de autocorrelação espacial positiva entre os agentes e o I de Moran de 0,3877, ou seja, rejeita-se a hipótese nula de que a distribuição dos estabelecimentos agroindustriais nas microrregiões do Brasil segue uma distribuição aleatória. Assim, ocorre a existência da dependência espacial, sendo que os valores observados em uma microrregião dependem dos valores observados nas regiões vizinhas.

No diagrama de dispersão de Moran, tem-se que o eixo horizontal corresponde a variável em análise, e, o eixo vertical, a defasagem espacial (lag) da variável de interesse para o mesmo período. Com o diagrama é possível classificar os municípios de acordo com quatro diferentes regimes espaciais: *Low-High*; *High-High*; *High-Low* e *Low-Low*. A Figura 1 sugere a existência de autocorrelação espacial positiva para os estabelecimentos, visto que concentram no primeiro e terceiro quadrantes. Verifica-se que as microrregiões com alto (baixo) número de estabelecimentos são vizinhos de microrregiões com alto (baixo) número de estabelecimentos.

Figura 1 - Diagrama de Dispersão de Moran para a variável dependente



Fonte: Elaboração própria a partir do software GeoDa.

O próximo passo consiste na utilização do indicador que observa os padrões locais de associação linear e que é estatisticamente significativa. Na Figura 2, pode-se observar os *clusters* das microrregiões que apresentam o comportamento do tipo *High-High* (alto-alto), formados por 102 microrregiões que estão situadas principalmente Sudeste¹⁸, Sul¹⁹, Centro-Oeste²⁰ e três microrregiões do Nordeste²¹. Também é possível verificar a existência de 60 microrregiões que apresentam o padrão do tipo *Low-Low* (baixo-baixo) que estão situadas exclusivamente no Norte²² e Nordeste²³ do país, e uma única microrregião²⁴ no Sudeste no estado de Minas Gerais. Os indicadores locais de associação espacial (LISA) apresentaram os seguintes padrões locais de *clusters*: *High-High* (102); *Low-Low* (60); *Low-High* (12) e *High-Low* (19), enquanto as demais microrregiões não apresentam vizinhos com significância.

¹⁸ MG: Ituiutaba, Uberlândia, Patrocínio, Frutal, Araxá, Bom Despacho, Para de Minas, Belo Horizonte, Ouro Preto, Caratinga, Piui, Divinópolis, Formiga, Passos, São Sebastião do Paraíso, Alfenas, Varginha, Poços de Caldas, Pouso Alegre, Santa Rita do Sapucaí, São Lourenço, Andrelândia, Barbacena, Viçosa, Muriaé, Uba, Juiz de Fora, Cataguases. SP: Barretos, São Joaquim da Barra, Ribeirão Preto, Batatais, Jau, Botucatu, Araraquara, São Carlos, Rio Claro, Limeira, Piracicaba, Pirassununga, São João da Boa Vista, Moji-Mirim, Campinas, Amparo, Tupã, Assis, Sorocaba, Jundiaí, Bragança Paulista, Osasco, Guarulhos, Itapeverica da Serra, Moji das Cruzes. RJ: Três Rios, Macacu-Caceribu.

¹⁹ RS: Frederico Westphalen, Erechim, Sananduva, Guaporé, Vacaria, Caxias do Sul, Lajeado-Estrela, Gramado-Canela, São Jerônimo, Osório, Camaquã. SC: São Miguel do Oeste, Chapeco, Xanxerê, Concórdia, São Bento do Sul, Joinville, Blumenau, Itajaí, Tijucas, Criciúma, Araranguá. PR: Umuarama, Goioerê, Astorga, Porecatu, Toledo, Francisco Beltrão, Pato Branco, Paranaguá.

²⁰ GO: Anápolis, Anicuns, Goiânia, Vale do Rio dos Bois, Meia Ponte, Pires do Rio, Catalão. MS: Nova Andradina, Iguatemi.

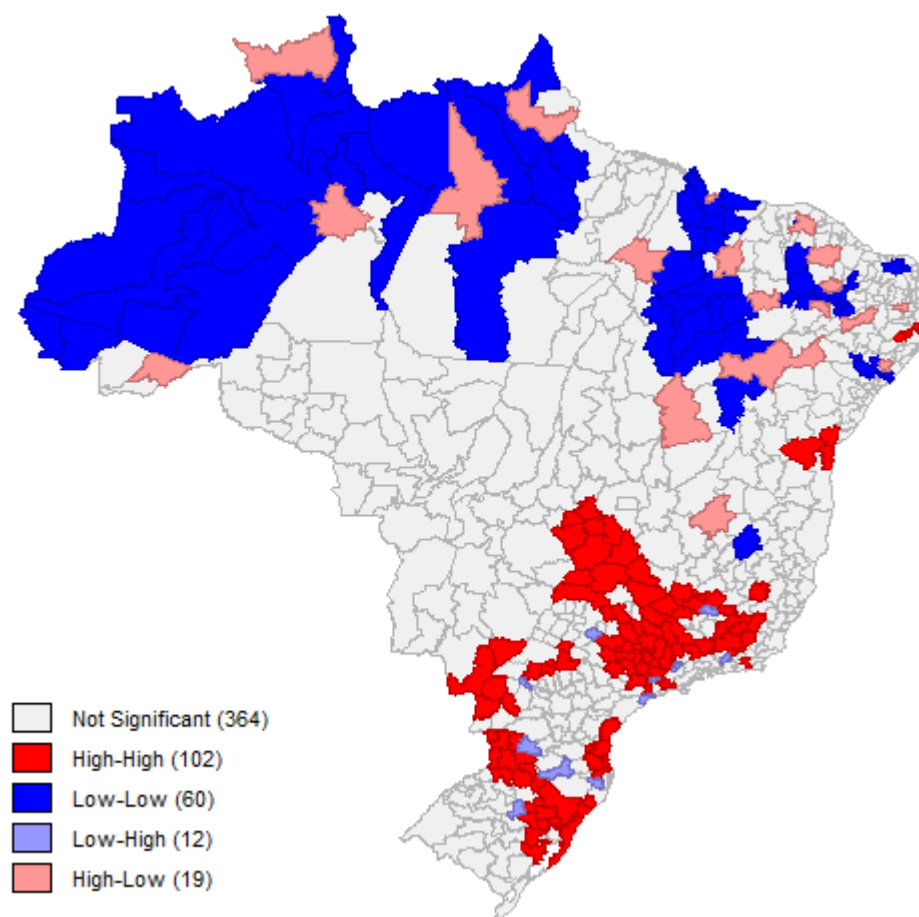
²¹ PE: Brejo Pernambucano, Vitória de Santo Antão, Suape.

²² AC: Cruzeiro do Sul, Tarauacá. AM: Rio Negro, Japurá, Alto Solimões, Juruá, Tefé, Coari, Rio Preto da Eva, Parintins, Boca do Acre, Purus. RR: Nordeste de Roraima, Caracará, Sudeste de Roraima. PA: Óbidos, Almeirim, Portel, Furos de Breves, Altamira. AP: Oiapoque, Mazagão.

²³ MA: Rosário, Lençóis Maranhenses, Baixada Maranhense, Itapecuru Mirim, Médio Mearim, Alto Mearim e Grajau, Chapadinha, Chapadas do Alto Itapecuru, Gerais de Balsas, Chapadas das Mangabeiras. PI: Alto Parnaíba Piauiense, Bertolínia, Floriano, Alto Médio Gurgueia, São Raimundo Nonato, Pio IX. CE: Meruoca, Sertão de Crateús, Sertão de Inhamuns, Várzea Alegre, Lavras da Mangabeira, Chapada do Araripe, Caririaçu, Barro. RN: Pau dos Ferros, Angicos, Baixa Verde, Cajazeiras, Itaporanga. AL: Alagoana do Sertão do São Francisco, Batalha, Penedo. SE: Sergipana do Sertão do São Francisco, Própria. BA: Barra.

²⁴ MG: Capelinha.

Figura 2 – Mapa de *clusters* para os estabelecimentos agroindustriais



Fonte: Elaboração própria a partir do software GeoDa.

Para corroborar com a análise, foi realizado o mapa de *clusters* bivariados entre estabelecimentos agroindustriais e as variáveis educação e a *dummy* de microrregião em região metropolitana ou não metropolitana.

Na Figura 3. a, entre as microrregiões que apresentam ser significativas, predomina o clusters *High-High* (87 microrregiões). Microrregiões com alto número de estabelecimentos agroindustriais são vizinhos de microrregiões que apresentam alto número de vínculos com maior nível educacional. Os *clusters* são encontrados com destaque nas microrregiões do Sudeste²⁵ nos estados de São Paulo (SP) e Minas Gerais (MG) e Centro-Oeste²⁶ nos estados do

²⁵ SP: São Paulo, Itapeverica da Serra, Osasco, Sorocaba, Campinas, Bragança Paulista, Piracicaba, Paranavaí, Rio Claro, Limeira, Presidente Prudente, Tupa, Marília, Assis, Tatui, Andradina, Ribeirão Preto, São Joaquim da Barra, Barretos, Catanduva, São José do Rio Preto, Jales, Franca, Jaboticabal, Bauru, Jau, Birigui, Lins, Botacatu, Araraquara, São João da Boa Vista, Pirassumunga, Moji-Mirim, Amparo, Dracena, Adamantina. MG: Pouso Alegre, Poço de Caldas, Ituiuba, Uberlândia, Frutal, Uberaba, Araxa, Piauí, Alfenas, Varginha.

²⁶ MS: Alto Taquari, Campo Grande, Paranaíba, Nova Andradina, Dourados, Iguatemi. MT: Cuiabá, Aripuanã, Alta Floresta, Colíder, Alto Teles Pires, Sinop, Camarana, Tangara da Serra, Jauru. GO: Rio Vermelho, Sudoeste de Goiás, Meia Ponte, Quirinópolis.

Mato Grosso do Sul (MS), Mato Grosso (MT) e Goiás (GO). Com menos destaque nas regiões Sul²⁷ compostas nos estados Rio Grande do Sul (RS), Santa Catarina (SC) e Paraná (PR), e na região Norte²⁸ nos estados de Rondônia (RO), Pará (PA) e Tocantins (TO).

Os *clusters High-High* destacam-se nas regiões em que existe maior influência no desenvolvimento de capital humano como as microrregiões de São Paulo. Também se destaca a região Centro-Oeste com as microrregiões que estão nos estados de Mato Grosso do Sul, Mato Grosso e Goiás em que o agronegócio é intensivo em tecnologia e, desta forma, necessita de capital humano mais intenso.

Destacam-se também os *clusters Low-Low* (83 microrregiões), em que microrregiões com baixo número de estabelecimentos agroindustriais são vizinhos de microrregiões que apresentam baixos vínculos com maior especialização. Podemos destacar as microrregiões da região Nordeste²⁹ do país com os estados do Maranhão (MA), Piauí (PI), Ceará (CE), Rio Grande do Norte (RN), Paraíba (PB), Pernambuco (PE), Alagoas (AL), Sergipe (SE) e Bahia (BA), seguido pela região Norte³⁰ com os estados do Acre (AC), Amazonas (AM), Roraima (RR), Pará (PA) e Amapá (AP). Também se encontra microrregiões do Sudeste³¹ em Minas Gerais e Rio de Janeiro (RJ).

Nos *clusters Low-Low* encontra-se com mais intensidade as microrregiões do Nordeste do país, identificando que as microrregiões com baixo número de estabelecimentos agroindustriais são vizinhos de microrregiões que apresentam baixo número de vínculos com maior nível educacional. Para confirmar esse resultado, verifica-se que a região não apresentou nenhum *cluster High-High*.

²⁷ RS: São Jerônimo, Ijuí, Carazinho, Três Passos, Frederico Westphalen, Erechim, Sananduva, Vacaria. SC: Criciúma, Tubarão, Chapeco, São Miguel do Oeste. PR: Cornélio, Procópio, Porecatu.

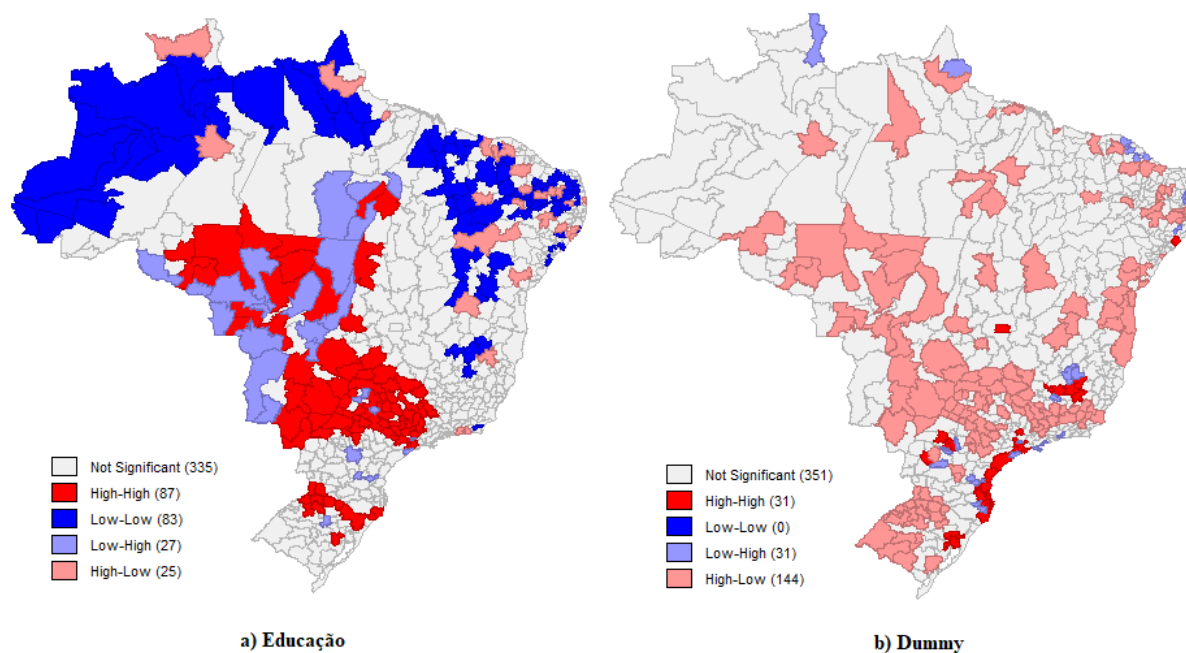
²⁸ RO: Ji-Paraná, Cacoal, Vilhena. PA: Redenção. TO: Araguaína, Rio Formoso.

²⁹ MA: Rosário, Baixada Maranhense, Itapecuru Mirim, Pindaré, Médio Mearim, Presidente Dutra, Baixo Parnaíba Maranhense, Chapadinha, Coelho Neto, Chapadas do Alto Itapecuru. PI: Campo Maior, Médio Parnaíba Piauiense, Bertolínia, Floriano, São Raimundo Nonato, Alto Médio Caninde. CE: Ipu, Coreau, Santa Quitéria, Sertão de Crateús, Sertão de Inhamuns, Serra do Pereira, Várzea Alegre, Chapada do Araripe, Barro. RN: Médio Oeste, Vale do Acu, Pau dos Ferros, Umarizal, Angicos, Borborema Potiguar, Agreste Potiguar. PB: Catolé da Rocha, Cajazeiros, Piancó, Itaporanga, Serra do Teixeira, Seridó Ocidental Paraibano, Seridó Oriental Paraibano, Cariri Ocidente, Cariri Oriental, Cutinatau Ocidental, Guarabina, Itabaiana. PE: Salgueiro. AL: Palmeira dos Índios, Litoral Norte Alagoano, Penedo. SE: Nossa Senhora das Dores, Estância; BA: Barra, Bom Jesus da Lapa, Jacobina, Seabra, Livramento do Brumado.

³⁰ AC: Cruzeiro do Sul, Tarauacá. AM: Rio Negro, Japurá, Alto Solimões, Juruá, Tefé, Coari, Rio Preto da Eva, Boca do Acre. RR: Caracaraí, Sudeste de Roraima. PA: Óbidos, Almeirim, Portel, Furos de Breves, Cameté. AP: Oiapoque, Mazagão.

³¹ MG: Bocaiuva, Capelinha, Araçuaí, Guanhães. RJ: Bacia de São João.

Figura 3 - Mapa de *clusters* bivariados



Fonte: Elaboração própria a partir do software GeoDa.

Nota: a) Educação – vínculos com ensino superior; b) *Dummy* – Região Metropolitana ou não metropolitana.

Na literatura, é verificado que as indústrias geralmente se desenvolvem nas proximidades das unidades fornecedoras de matérias-primas; em contrapartida, a instalação desses centros industriais assegura a continuidade das atividades nas unidades produtivas, intensificando o elo agricultura/indústria para a região. Na Figura 3.b, é apresentado o mapa de *clusters* bivariado para a variável dependente e a *dummy* de região metropolitana.

Destaca-se que entre os *clusters* significativos, ocorre o predomínio do *clusters High-High*, em que as microrregiões com alto número de estabelecimentos agroindustriais são vizinhas de microrregiões que estão alocadas em microrregiões metropolitanas. As microrregiões³² que apresentam *clusters High-High* estão alocadas nos estados do Rio Grande do Sul, Santa Catarina, Paraná, São Paulo, Minas Gerais, Brasília, Alagoas e Pernambuco.

O resultando vem ao encontro de Araújo (2002) que encontrou em sua análise para o Rio Grande do Sul em que a distribuição espacial tende a seguir a distribuição das fontes de

³² RS: Porto Alegre, Montenegro e Gramado-Canela. SC: Tubarão, Florianópolis, Tijucas, Itajaí, Blumenau, Joinville, São Bento do Sul. Paraná: Apucarã, Londrina, Astorga, Goioerê, Paranaguá. São Paulo: Registro, Itapeverica da Serra, São Paulo, Osasco, Santos, Guarulhos, Jundiaí, Amparo. Minas Gerais: Ponte Nova, Ipatinga, Itabira, Belo Horizonte, Para de Minas. Brasília. AL: São Miguel dos Campos. PE: Mata Setentrional Pernambucana.

matérias-primas situando-se nos centros que apresentam as melhores condições de infraestrutura e facilidades de acesso aos mercados.

Após realizar os procedimentos de análise exploratória de dados espaciais e confirmar a presença de autocorrelação espacial por meio da estatística I de Moran nos erros do modelo de Mínimos Quadrados Ordinários, tem-se a justificativa para a utilização das técnicas de econometria espacial.

4.2 Resultados do Modelo Econométrico Espacial

Os resultados em MQO (Tabela 3) indicaram sinal positivo para todas as variáveis, ou seja, o aumento de estabelecimentos agroindustriais reflete no aumento das variáveis em estudo. Todas as variáveis mostraram-se significativas a 1%, exceto participação do VAB agropecuário que mostrou significativo a 5%, e a *dummy*, a 10%. Enquanto, a participação do VAB industrial não foi significativo.

Tabela 3 - Resultado da Regressão em MQO

Variável	Coef	Std. Error	z-statistic	Prob.
Constante	1.06554	0.276618	3.85202	0.00013
PIB	0.785648	0.0988055	7.95146	0.00000
VABAGR	0.0982631	0.0464989	2.11312	0.03503
VABIND	0.118408	0.0813384	1.45574	0.14604
CAPHUMANO	0.275788	0.0442905	6.22681	0.00000
DENSID	0.452209	0.0369894	12.2254	0.00000
Dummy	0.197775	0.1177440	1.67971	0.09358
R2	0.60			

Fonte: Elaboração própria a partir do software GeoDa.

O resultado da regressão em MQO indicou com o teste R^2 que as variáveis explicativas explicam 60% dos estabelecimentos agroindustriais. O teste Jarque-Bera, que analisa a normalidade dos erros, indica que os erros não seguem uma distribuição normal e podem ocorrer problemas na estimação, o teste “*Multicollinearity condition number*”, que apresentar valor inferior a 30 (= 21.883257), indica a não existência de multiconinearidade. O teste Breush-Pagan, que apresenta como hipótese nula a homocedasticidade, rejeitou com 10% de

significância a hipótese nula. Dadas as evidências o modelo apresenta o problema heterocedasticidade³³.

Com a questão espacial³⁴, o modelo clássico de regressão linear é inadequado para explicar as relações entre as variáveis, sendo necessário estimar modelos que considerem a dependência espacial. Antes da estimação, entretanto, é necessário detectar a ocorrência de autocorrelação espacial e verificar qual o modelo mais indicado por meio dos resultados estimados por MQO (Tabela 4).

Tabela 4 - Diagnóstico de Dependência Espacial

Teste	Valor	Prob.
Moran's I	6.9953	0.00000
MLλ (erro)	3.1804	0.07453
ML*λ (erro robusto)	21.1169	0.00000
MLρ (defasagem)	44.1776	0.00000
ML*ρ (defasagem robusta)	62.1141	0.00000

Fonte: Elaboração própria a partir do software GeoDa.

Pela Tabela 4, observa-se que o I Moran, é estatisticamente significativo a um nível de significância de 1%, ou seja, confirma-se a ocorrência de autocorrelação espacial. Da mesma forma, que os teste dos Multiplicadores de Lagrange, tanto o de erro como o de defasagem (ML λ e ML ρ) mostraram-se estatisticamente significativos a 1% e 10%, respectivamente, ou seja, o MQO não é apropriado.

É preciso verificar as versões robustas dos dois testes (ML* λ e ML* ρ) para escolher o modelo econométrico espacial mais apropriado. Como ambos os modelos ML* λ e ML* ρ são significantes a 1%, é preciso utilizar o modelo de defasagem espacial com erro auto-regressivo (SAC ou SARAR). Como os dois modelos SAR e SEM mostraram significativos a Tabela 5, apresenta os resultados encontrados.

³³ O modelo em MQO não apresentou multicolinearidade, porém apresentou heretocedasticidade, no qual foi utilizado o programa GeoDa Space para resolver o problema.

³⁴ O teste de Moran's I apresentou ser igual a 0.1730 (com significância de 0.0000).

Tabela 5 - Resultados da Regressão para o modelo espacial SAR e SEM

	SAR				SEM			
	Coef	Std. Error	z-statistic	Prob.	Coef	Std. Error	z-statistic	Prob.
Constant	1.6184314	0.3173016	5.1006082	0.000	0.9920120	0.3503572	2.8314303	0.0046
PIB	1.0293298	0.1181823	8.7096770	0.0000	0.7807294	0.1140333	6.8465061	0.0000
VABAG	0.2009953	0.0543174	3.7003854	0.0002	0.0523660	0.0517838	1.0112428	0.3119
VABIND	0.1423063	0.0853330	1.6676583	0.0954	0.1017593	0.0822587	1.2370644	0.2161
CAPHUMANO	0.3092415	0.0470248	6.5761406	0.0000	0.2411322	0.0429810	5.6102098	0.0000
DENSID	0.5685473	0.0473750	12.0010088	0.0000	0.5277835	0.0484148	10.9012742	0.0000
Dummy	0.1875343	0.1232829	1.5211698	0.1282	0.1619569	0.1175626	1.3776226	0.1683
W_inestab	-0.3376389	0.0792142	-4.2623521	0.0000				
Lambda					0.4394106	0.0432861	10.1512979	0.0000
R²	0.6132				0.5928			

Fonte: Elaboração própria a partir do software GeoDaSpace.

O modelo SAC (= SARAR) engloba tanto o coeficiente de defasagem espacial (ρ) quanto parâmetro do termo de erro autorregressivo (λ), sendo este o modelo mais apropriado para o estudo. O resultado para o modelo SAC (Tabela 6) demonstra que as variações dos estabelecimentos agroindustriais entre as microrregiões são explicadas 60,62% pelo modelo proposto, sendo que exercem influência positiva e significativas as variáveis independentes PIB *per capita*, participação do VAB agropecuário, educação e densidade. As variáveis participação do VAB da indústria e a *dummy* não são significativas.

Tabela 6 - Resultados da Regressão para o modelo espacial SAC

Variável	Coef	Std. Error	z-statistic	Prob.
Constante	2.3140810	0.6140715	3.7684228	0.0002
W_inestab	-0.3835384	0.0929190	-4.1276624	0.0000
PIB	0.8273871	0.1200032	6.8947099	0.0000
VABCAGR	0.1327900	0.0538330	2.4667053	0.0136
VABIND	0.1264171	0.0771583	1.6384115	0.1013
CAPHUMANO	0.2134771	0.0393888	5.4197429	0.0000
DENSID	0.6930523	0.0546365	12.6847961	0.0000
Dummy	0.1623880	0.1075547	1.5098185	0.1311
Lambda	0.6990255	0.0500221	13.9743404	0.0000
R²	0.6062			

Fonte: Elaboração própria a partir do software GeoDaSpace.

O novo coeficiente, $W_Inestab$, mostrou-se estatisticamente significativo, porém, devido ao seu coeficiente negativo, a variável de defasagem espacial (W_Inpib), indicou que estabelecimentos agroindustriais nas localidades vizinhas impacta de forma negativa na incidência de um maior número de estabelecimentos nas microrregiões do Brasil. Desta forma, por meio do modelo SAC não é possível afirmar que o coeficiente da defasagem espacial dos estabelecimentos se relaciona de forma direta com os estabelecimentos das microrregiões vizinhas.

O resultado pode ser confirmado através da confirmação da ABIA (2012) que vem ocorrendo uma tendência de concentração industrial no mercado de alimentos, porém não pode ser confundida com concentração espacial. É o resultado de fusões e aquisições que promovem a diminuição do número de empresas participantes do mercado, porém, não o número de estabelecimentos.

Na forma funcional log-log, os coeficientes estimados de cada variável são entendidos como elasticidades, exceto no caso da *dummy*. O modelo destacou a importância para as variáveis PIB *per capita* e densidade populacional, sendo que o aumento de 1% na variável causará a elevação de 0.83 e 0.69, respectivamente, no número de estabelecimentos. Outra variável importante para o modelo é o nível educacional dos funcionários, ou seja, o aumento de 1% na variável causará a elevação de 0.21 no número de estabelecimentos. Na AEDE as regiões Sudeste, Centro-Oeste e Sul os dados mostraram que o número de vínculos com ensino superior é significativo e interfere no número de estabelecimentos.

5 CONSIDERAÇÕES FINAIS

O artigo se propôs a verificar os padrões geográficos das indústrias de alimentos dispostos nas microrregiões do Brasil, a fim de apurar se ocorre o fenômeno de concentração/aglomeração agroindustrial em torno das cidades metropolitanas.

Com a análise exploratória de dados espaciais, foi possível observar como os estabelecimentos se comportam espacialmente. Por meio do I de Moran's constatou-se a existência da dependência espacial, ou seja, os valores que são observados em uma microrregião dependem dos valores observados nas microrregiões vizinhas. Com a dependência espacial foi realizado o mapa de *clusters* em que apresentou o comportamento do tipo *High-High*, ou seja, 102 microrregiões com estabelecimentos agroindustriais são vizinhos de microrregiões que também apresentam alto número de estabelecimentos.

Os *clusters High-High* estão concentrados com maior intensidade na região Sudeste, Sul e Centro-Oeste, ou seja, as principais regiões econômicas do Brasil. Para confirmar esse resultado foi feito o mapa de *clusters* bivariados entre a variável estabelecimentos e a *dummy* região metropolitana no qual confirmou o resultado inicial. Destacou-se no mapa que entre os *clusters* que apresentaram ser significativos, ocorreu o predomínio do *clusters High-High*, em que as microrregiões com alto número de estabelecimentos agroindustriais são vizinhas de microrregiões que estão alocadas em microrregiões metropolitanas.

As microrregiões estão alocadas nos estados do Rio Grande do Sul, Santa Catarina, Paraná, São Paulo, Minas Gerais, Brasília, Alagoas e Pernambuco, ou seja, estão concentradas nas principais microrregiões do país, onde estão localizados maior população, ou seja, o mercado consumidor, desta forma apresentam vantagens logísticas com fácil acesso as demais regiões.

Essa informação foi confirmada com o mapa de *clusters* bivariado entre estabelecimentos e a variável educação que mostra a porcentagem dos trabalhadores com ensino superior. Os *clusters* são encontrados com destaque nas microrregiões do Sudeste com significativa importância dos estados de São Paulo e Minas Gerais, seguido pelo Centro-Oeste (Mato Grosso do Sul, Mato Grosso e Goiás), Sul (Rio Grande do Sul, Santa Catarina e Paraná) e na região Norte (Rondônia, Pará e Tocantins).

Destacam-se regiões em que existe maior influência no desenvolvimento de capital humano principalmente nas microrregiões do estado de São Paulo e a região Centro-Oeste com as microrregiões em que o agronegócio é intensivo a tecnologia, com a necessidade de capital humano mais intenso.

Após realizar os procedimentos de análise exploratória de dados espaciais e confirmar através da estatística I de Moran nos erros do modelo de Mínimos Quadrados Ordinários, a presença de autocorrelação espacial confirmou-se a justificativa para a utilização das técnicas de econometria espacial. Após verificar as versões robustas dos dois testes escolheu-se o modelo espacial mais apropriado, o Modelo de Defasagem Espacial com Erro Autorregressivo Espacial.

O modelo destacou a importância para as variáveis PIB *per capita* e densidade populacional, sendo que o aumento de 1% na variável causará a elevação de 0.83 e 0.69, respectivamente, no número de estabelecimentos. Outra variável importante para o modelo é o capital humano, ou seja, o aumento de 1% na variável causará a elevação de 0.21 no número de estabelecimentos.

Os resultados contrapõem a teoria clássica em que as agroindústrias estão próximas dos insumos, pois os resultados mostram que atualmente outros fatores são importantes para a indústria de alimentos além de estar próximo da matéria-prima. Podemos citar fatores como mão de obra qualificada, acesso ao mercado consumidor, e a clusterização para o ganho de produtividade.

Os resultados estão alinhados com o trabalho de Araújo (2002) que analisou a indústria de alimentos para o Rio Grande do Sul. Para o autor as atividades tendem a concentrar-se em pontos que oferecem condições de infraestrutura adequada e algum nível de economias de aglomeração, desta forma na indústria alimentícia não basta apenas a disponibilidade de matérias-primas para atrair indústrias, mas também existem outros fatores importantes.

O presente estudo buscou contribuir com a análise espacial dos estabelecimentos agroindústrias em relação as microrregiões brasileiras do país, de forma a não ficar concentrado o estudo em uma única região como é visto regularmente. Para trabalhos futuros é possível incluir variáveis que façam referências aos custos de transporte e demais fatores que possam captar as principais motivações na instalação de agroindústrias em determinadas regiões.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS DA ALIMENTAÇÃO – ABIA. **Relatório Anual 2016**. Disponível em: <https://www.abia.org.br/vsn/temp/z2017417RELATORIOANUAL2016.pdf>. Acesso em: 24 out. 2019.

ALMEIDA, E. Função de Produção Agropecuária Espacial. In: XLIII CONGRESSO DA SOBER. Ribeirão Preto, 2005. Disponível em: <http://www.sober.org.br/palestra/2/649.pdf>. Acesso em: 22 out. 2019.

ALMEIDA, E. **Econometria espacial aplicada**. Campinas: Alinea, 2012. 498 p.

ALMEIDA, E. S. de. HADDAD, E. A. MEECA: um Modelo Econométrico Espacial para Projeção Consistente de Culturas Agropecuárias. **RER**, Rio de Janeiro, v. 42, n. 03, p. 507-527, jul/set 2004.

ALMEIDA, E.; PEROBELLI, F. S.; e FERREIRA, P. G. C. Existe convergência espacial da produtividade agrícola no Brasil? **Revista de Economia e Sociologia Rural**; v. 46; n. 01; p. 31-52; jan./mar. 2008.

ALVIM, M. I. S. A. **Competitividade da produção de soja nos sistemas de plantio direto e plantio convencional em Mato Grosso do Sul**. 2003. 148p. Tese (Doutorado em Economia Aplicada) – Universidade Federal de Viçosa, Viçosa, 2003.

ANSELIN, L. **Spatial econometrics: methods and models**. Kluwer Academic, Boston, 1988.

ANSELIN, L. SpaceStat Tutorial: A Workbook for Using SpaceStat in the Analysis of Spatial Data. Mimeo, University of Illinois, 1992.

ANSELIN, L. **Local indicators of spatial association – LISA**. *Geographical Analysis*, v. 27, n. 2, p. 93-115, 1995.

ANSELIN, L. The future of spatial analysis in the social sciences. **Geographic Information Sciences**, v. 5, n. 2, p. 67-76, 1999.

ARAÚJO, N. C. M. Origens e evolução espacial da indústria de alimentos do Rio Grande do Sul. [online]. In: 1º Encontro de Economia Gaúcha. Porto Alegre: PUC/FACE, 2002. Disponível em: http://cdn.fee.tche.br/eeg/1/mesa_10_araujo.pdf. Acesso em: 22 out. 2019.

AZZONI, C. R. **Teoria da localização: análise crítica a partir das evidências empíricas no Estado de São Paulo**. 1982. 287 p. Tese (Doutorado), Universidade de São Paulo, São Paulo.

BRAGA, R. Tendências e perspectivas das teorias locacionais no Capitalismo contemporâneo. **Geografares**, n. 6, 2008.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Estatísticas de Comércio Exterior do Agronegócio Brasileiro**. Disponível em: <http://indicadores.agricultura.gov.br/index.htm>. Acesso em 14 out. 2019.

BUHSE, A. P; PELEGRINI, T; FOCHEZATTO, A. Análise espacial das agroindústrias da Região Sul: um estudo a nível municipal para o ano 2010. **Geosul**, Florianópolis, v. 33, n. 68, p.116-136, set./dez. 2018.

CAVALCANTE, L. R. M. T. Produção teórica em economia regional: uma proposta de sistematização. **Revista Brasileira de Estudos Regionais e Urbanos**, v. 2, n. 1, fev. 2015.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA - CEPEA. **PIB do Agronegócio Brasileiro - 2017**. Disponível em: <<http://cepea.esalq.usp.br/pib/>>. Acesso em: 14 out. 2019.

ELIAS, D. Agronegócio e novas regionalizações no Brasil. **RBEUR**, Recife: v. 13, n. 2, p. 153-167, nov. 2011.

FLORAX, R. J. G. M., FOLMER, H., REY, S. J. Specification searches in spatial econometrics: The relevance of Hendry's methodology. **Regional Science and Urban economics**. v. 33, n.5, p. 557-79, 2003.

GASQUES, J. G.; REZENDE, G. C.; VERDE, C. M. V.; SALERMO, M. S.; CONCEIÇÃO, J. C. P. R.; CARVALHO, J. C. S. Desempenho e crescimento do agronegócio no Brasil. Texto para discussão nº 1009. IPEADATA, Brasília, 2004. 40p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Divisão Regional do Brasil. Disponível em: http://web.archive.org/web/20170822164417/http://www.ibge.gov.br/home/geociencias/geografia/default_div_int.shtm. Acesso em: 19 fev. 2020.

KELEJIAN, H. H.; PRUCHA, I. R. A Generalized Spatial Two-Stage Least Squares Procedure for Estimating a Spatial Autoregressive Model with Autoregressive Disturbances. **Journal of Real Estate Finance and Economics**, v. 17:1, 99-121, 1998.

LE GALLO, J.; ERTHUR, C. Exploratory spatial data analysis of the distribution of regional per capita GDP in Europe, 1980-1995. **Papers in Regional Science**; v. 82; n. 2; p. 175- 201; 2003.

LESAGE, J. P.; PACE, R. K. **Introduction to spatial econometrics**. London: CRC Press/ Taylor & Francis, 2009.

LOBÃO, M. S. P.; SILVA, R. G. da. *Spillovers* espaciais no desenvolvimento educacional dos municípios da Amazônia clássica brasileira. **Redes** – Santa Cruz do Sul: Universidade de Santa Cruz do Sul, v. 23, n. 2, p. 290-315, maio-agosto, 2018.

LÖSCH, A. **The economics of location**. New Haven: Yale University Press, 1954.

LOURENÇO, C. J.; LIMA, C. E. B. Evolução do agronegócio brasileiro, desafios e perspectivas. Observatório de Economia Latino-Americana, 2009. Disponível em: <http://www.eumed.net/coursecon/ecolat/br/09/clbl.htm>. Acesso em: 25 out. 2019.

OLIVEIRA, T. J. A; RODRIGUES, W. Uma análise espacial da estrutura produtiva no interior do Brasil: os clusters do agronegócio. **Rev. Econ. NE**, Fortaleza, v. 50, n. 1, p. 153-170, jan./mar., 2019.

PEROBELLI, F. S.; ALMEIDA, E. S. de.; ALVIM, M. I. S.; FERREIRA, P. G. C. Produtividade do setor agrícola brasileiro (1991 - 2003): uma análise espacial. **Nova economia**, Belo Horizonte, v.17, n.1, p. 65-91, 2007.

PIMENTEL, E. A.; HADDAD, E. A. Análise da distribuição espacial da renda no estado de Minas Gerais: uma abordagem setorial. **Texto de Discussão**, Nereus, 02 – 2004.

RAIHER, A. P.; OLIVEIRA, R. A. de; CARMO, A. S. S. do; STEGE, A. L. Convergência da produtividade agropecuária do sul do Brasil: uma análise espacial. **Rev. Econ. Sociol. Rural**; Piracicaba-SP; v. 54; n. 03, p. 517-536, 2016.

RELATÓRIO ANUAL DE INFORMAÇÕES SOCIAIS – RAIS. Rais Estabelecimentos. Disponível em: <http://bi.mte.gov.br/bgcaged/inicial.php>. Acesso em: 20 fev.2019.

ROCHA, C. B.; PARRÉ, J. L. Estudo da distribuição espacial do setor agropecuário do Rio Grande do Sul. **Análise Econômica**; Porto Alegre; v. 27; n. 52; p. 139-160; 2009.

SILVA, L. N. S. da., BORGES, M. J., PARRÉ, J. L. Distribuição espacial da pobreza no Paraná. **Revista de Economia**, v. 39, n. 3 (ano 37), p. 35-58, set./dez. 2013.

SOUZA, R. M. P.; SALGUEIRO, F. Diagnóstico espacial da concentração produtiva de café no Brasil, no período de 1991 a 2003. **Revista de Economia e Agronegócio**, vol. 5 (3), p. 1-24, 2007.

VIDIGAL, V. G.; GOMES, M. F. M.; VIDIGAL, C. B. R.; SILVEIRA, G. F. Análise espacial da produtividade da cana-de-açúcar em Minas Gerais, 1990 a 2007. **Revista de Economia e Administração**, v.10, n.2, p. 241-261, abr./jun. 2011.

WEBER, A. **Theory of the Location of Industries**. University of Chicago Press, 1929.

4 VARIAÇÕES NA INFLUÊNCIA DO CAPITAL HUMANO NA INDÚSTRIA DE ALIMENTOS: UMA ANÁLISE A PARTIR DA REGRESSÃO GEOGRAFICAMENTE PONDERADA PARA AS MICRORREGIÕES BRASILEIRAS

Resumo

O estudo analisa como se distribuem espacialmente os vínculos da indústria de alimentos com maior capital humano através da Regressão Geograficamente Ponderada (RGP), pois como o segmento caracteriza-se como receptor de tecnologia, principalmente no manuseio de máquinas e equipamento, é necessária maior qualificação. Os resultados mostraram que o capital humano influencia fortemente a participação dos vínculos nas microrregiões que estão alocadas na Região Sudeste (Espírito Santo, Rio de Janeiro, São Paulo e Minas Gerais) e Sul (Santa Catarina e Paraná), além de alguns Estados no Nordeste (Ceará e Bahia) e Norte (Amapá e Roraima). As indústrias de alimentos que estão aglomeradas nas microrregiões do Sudeste e Sul apresentam vínculos com maior capital humano, ou seja, nas regiões brasileiras que já são mais desenvolvidas economicamente e que ao mesmo tempo a população já apresenta mais facilidades em adquirir maiores níveis de escolaridade e de competências.

Palavras-chave: Capital humano; Indústria de Alimentos; RGP; Microrregiões.

Abstract

The study analyzes how the food industry links with greater human capital are spatially distributed through Geographically Weighted Regression (GWR), because as the segment is characterized as a technology receiver, mainly in the handling of machines and equipment greater qualification is needed. The results showed that human capital strongly influences the participation of ties in the micro-regions that are allocated in the Southeast (Espírito Santo, Rio de Janeiro, São Paulo and Minas Gerais) and the South (Santa Catarina and Paraná), in addition to some states in the Northeast (Ceará and Bahia) and North (Amapá and Roraima). The food industries that are agglomerated in the Southeast and South microregions have links with greater human capital, that is, in the Brazilian regions that are already more economically developed and that at the same time the population already has more facilities in acquiring higher levels of education and skills.

Keywords: Human Capital; Food industry; GWR; Microregions.

1 INTRODUÇÃO

O agronegócio cada vez mais tem ocupado importante posição no âmbito do contexto brasileiro e tornou-se um setor dinâmico da economia por meio de um processo de inter-relações entre os diversos segmentos que o compõem (BEGNIS et al., 2005). O agronegócio inclui basicamente as atividades que estão ligadas ao fornecimento de insumos, máquinas e equipamentos para a agropecuária, a produção agropecuária propriamente dita, a agroindústria, processamento secundário, o transporte e a comercialização dos produtos primários e processado (AMARAL; GUIMARÃES, 2017).

A indústria de alimentos é um dos setores mais dinâmicos do agronegócio brasileiro. Em 2016, o faturamento estimado do segmento foi de R\$ 614,3 bilhões, representando cerca de 10% do Produto Interno Bruto (PIB) (AMARAL; GUIMARÃES, 2017). Segundo os dados da Associação Brasileira da Indústria de Alimentos (ABIA; 2017) destacam-se a produção de derivados da carne (28%), o beneficiamento de café, chá e cereais (14%), laticínios (10%), óleo e gorduras (10%), açúcares (10%), derivados de trigo (7%), derivados de frutas e vegetais (6%) e outros (15%).

O setor corresponde ao último nível da cadeia do agronegócio, que engloba um conjunto de atividades bastante heterogêneo, desde o beneficiamento de produtos agropecuários, até atividades tecnologicamente complexas e de maior agregação de valor às matérias-primas agropecuárias (ARAÚJO, 2002).

A indústria de alimentos caracteriza-se como receptora de tecnologia, e apresenta especificidades tanto nos processos de produção como na estrutura de mercado, em que novas tecnologias proporcionam impactos diferenciados nos segmentos. As primeiras inovações tecnológicas que ocorreram dentro da fábrica foram a incorporação de novas máquinas e equipamentos, enquanto, em um segundo momento, a diferenciação do produto e a adição de serviços passaram a ser os direcionadores das inovações tecnológicas (SATO, 1998).

De acordo com Santos (2016), as empresas devem buscar obter capital humano que possa lhes proporcionar as condições para que aprofundem suas competências e as oriente para ações criativas na busca das inovações. O autor completa ainda, que na teoria do capital humano tem-se a importância das habilidades e das competências humanas no interior das empresas, das regiões e das nações para o aumento da produtividade e do crescimento econômico.

As firmas que não possuem capital humano de qualidade têm dificuldade de sobrevivência e crescimento. De forma estratégica, este é um fator relevante e depende de fatores que são externos às firmas, ou seja, de um sistema educacional que possa suprir a

carência de profissionais especificamente qualificados para atuarem em determinados segmentos econômicos (BEGNIS et al.;2005).

Por meio da diferença das regiões brasileiras, o artigo responderá o seguinte problema de pesquisa: Na indústria de alimentos existe diferença na influência do capital humano entre as microrregiões brasileiras? Como o país apresenta muitas peculiaridades por causa da sua grande extensão territorial, o artigo responderá se em todas as microrregiões do país os vínculos da indústria de alimentos apresentam a mesma influência no capital humano, sendo possível através da metodologia de Regressão Geograficamente Ponderada (RPG) em que o método permite analisar as observações através de coeficientes locais para cada ponto do espaço.

O objetivo principal do artigo é analisar como se distribuem espacialmente os vínculos da indústria de alimentos com maior capital humano. A análise será realizada para as microrregiões do Brasil através do uso da metodologia Regressão Geograficamente Ponderada que tem como base o ajustamento de um modelo de regressão para cada ponto no conjunto de dados, ponderando as observações em razão da distância a este ponto (CARVALHO et al.; 2006).

O artigo está dividido em cinco seções. A primeira está a introdução, seguida pela revisão de literatura. Em seguida, a metodologia empregada e os resultados que são apresentados nas seções três e quatro. Finalmente, na quinta e última discutem-se as considerações finais.

2 REVISÃO DE LITERATURA

A metodologia Regressão Geograficamente Ponderada (RGP ou em inglês *Geographically Weighted Regression - GWR*) é bastante difundida na literatura, e aplicada para diversos setores, porém não se encontram trabalhos para a indústria de alimentos no Brasil.

Ao utilizar RGP (ou GWR), Fotheringham et al., (2002) analisam um conjunto de dados que leva em consideração os preços das habitações em Londres, juntamente com variáveis independentes hedônicas, onde os modelos GWR são calibrados com métricas de distância euclidiana, distância da rede de estradas e tempo de viagem. Os resultados indicaram que uma métrica não euclidiana pode melhorar o ajuste do modelo e fornecer informações adicionais e úteis sobre a natureza do relacionamento variado no conjunto de dados dos preços das habitações.

Patridge et al. (2008) analisa a diversidade geográfica no crescimento não metropolitano dos Estados Unidos. A heterogeneidade espacial é uma das explicações para o crescimento da área local, especialmente o crescimento do emprego, sendo difícil através de abordagens convencionais detectar esses efeitos, desta forma é utilizado a metodologia GWR. Os resultados encontrados indicaram que ocorre heterogeneidade significativa nos coeficientes de regressão em todo o país e as ações de pós-graduação. Os resultados também mostraram que variações locais significativas sugerem limitações de uma abordagem única para descrever o crescimento e informar políticas públicas.

Na área da segurança, Gomes et al. (2017) estudaram os determinantes do crime nos municípios do estado de Minas Gerais. Os principais resultados mostraram que os crimes contra a pessoa são mais frequentes e áreas economicamente menos desenvolvidas, enquanto, crimes contra o patrimônio são mais comuns em regiões ricas, onde ocorrem alvos viáveis para os autores dos delitos, por fim, a concentração de população com 15 a 24 anos em determinada região influencia positivamente a criminalidade.

Por mais que a literatura em relação a indústria de alimentos e a metodologia GWR seja pouco explorada, encontram-se artigos na literatura em que mostram o reflexo do maior capital humano. Raiher e Dathein (2009) analisaram a evolução do capital humano nas microrregiões paranaenses entre 1999 e 2006 caracterizando sua distribuição espacial e sua evolução. Os resultados do estudo demonstram que ocorreu aumento do capital humano, com melhora nos seus aspectos quantitativos e qualitativos, resultando nas diferenças significativas quanto à sua distribuição ao longo do estado.

A influência do capital humano na concentração regional também foi motivo de estudo para Lima e Viana (2009) no qual teve como objetivo analisar o crescimento econômico paranaense no início do século 21. Os resultados mostraram que as mesorregiões que apresentaram maior crescimento econômico também foram as que alcançaram maior coeficiente para o capital humano. Porém, a variável obteve maior desempenho nas mesorregiões em que houve maior interação com o capital social concluindo que o nível de escolaridade (capital humano) e de associação e cooperação da população (capital social) estão entre os principais determinantes do crescimento econômico.

Como na literatura não é explorada a influência do capital humano nas indústrias de alimentos e não utilizam a metodologia GWR nesse segmento, esse torna-se a principal contribuição do presente estudo.

3 METODOLOGIA

3.1 Regressão Geograficamente Ponderada (RPG - *Geographically Weighted Regression* GWR)

Por meio da análise econométrica identificamos a relação entre variáveis em diferentes unidades espaciais. Assume-se, a partir de parâmetros estimados, um valor constante para todo o espaço analisado, no qual pode ser questionado em diversas circunstâncias. Desta forma, pode-se assumir que as relações entre as variáveis se diferenciam ao longo das unidades espaciais (GOMES et al., 2017).

A Regressão Geograficamente Ponderada ou *Geographically Weighted Regression* é uma técnica não estacionária que modela relações espacialmente variáveis (FOTHERINGHAM et al., 2002). O método estende uma versão local da análise de regressão linear no qual permite variações locais nas taxas de variação, ou seja, observações ponderadas pela distância geográfica permitem a obtenção dos coeficientes locais para cada ponto do espaço.

O modelo GWR estabelece que os parâmetros estimados podem variar de um local para outro, sendo que as relações podem variar de maneira significativa através do espaço, de modo que a análise global esconde importantes relações geográficas (FOTHERINGHAM et al., 2002).

O modelo básico de GWR é apresentado por Fotheringham et al., (2002) na expressão (1).

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i) x_{ik} + \varepsilon_i \quad (1)$$

onde (u_i, v_i) representa as coordenadas do ponto i no espaço e $\beta_k(u_i, v_i)$ é o coeficiente local no ponto i . O termo de erro aleatório segue distribuição normal com média zero e variância constante.

Cada observação da amostra é ponderada conforme sua distância para o ponto em que se baseia a regressão; as observações mais próximas possuem um peso maior, e as observações mais distantes, um peso menor (ALMEIDA, 2012). A ponderação é feita por meio da função Kernel espacial, função real, contínua e simétrica, cuja integral soma um, semelhante uma função densidade de probabilidade (CAMERON; TRIVEDI, 2005; ANSELIN; LOZANO-GARCIA, 2009). Kernel usa a distância (d_{ij}) entre dois pontos geométricos representando duas

regiões, e um parâmetro da largura da banda (b), para determinar um peso entre essas duas regiões, que é inversamente relacionada à distância geográfica (w_{ij}).

O Kernel espacial permite fazer a calibragem do modelo para n amostras em torno do ponto de regressão i , resultando na formação de “janelas móveis”. Cada subamostra é definida por Kernel espacial, sendo que sua calibragem pode ser feita para qualquer ponto definido no espaço. A abordagem GWR é uma forma de interpolação espacial de dados, que prevê valores sobre a variável dependente (y) para regiões onde não há essa informação (ALMEIDA, 2012).

Com a especificação do Kernel espacial é possível obter a matriz de ponderação espacial local diagonal apresentada na expressão (2):

$$W(u_i, v_i) = \begin{matrix} W_{i1} & 0 & \dots & 0 \\ 0 & W_{i2} & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & W_{in} \end{matrix} \quad (2)$$

onde W_{in} designa o peso dado no ponto n na calibragem do modelo em volta do ponto de regressão i .

A especificação de Kernel espacial depende de três elementos: a distância entre dois pontos (d_{ij}); uma largura de banda (b) e uma função matemática que tem como *inputs* a distância e a largura da banda (ALMEIDA, 2012).

3.2 Descrição das variáveis e fonte dos dados

O estudo tem como variável dependente participação de vínculos da indústria de alimentos³⁵ no total dos vínculos das microrregiões brasileira. Como variáveis explicativas temos: Produto Interno Bruto *per capita* (PIB); participação do Valor Adicionado Bruto da Agropecuária (VABAGR); participação do Valor Adicionado Bruto da Indústria (VABIND); porcentagem de vínculos com ensino superior (CAPHUMANO); densidade demográfica (DENSID) e a variável binária (*dummy*) que assume o valor 1, para a microrregião que está

³⁵ Classificação CNAE: 10 - Fabricação de produtos alimentícios: abate e fabricação de produtos de carne; preservação do pescado e fabricação de produtos do pescado; fabricação de conservas de frutas, legumes e outros vegetais; fabricação de óleos e gorduras vegetais e animais; laticínios; moagem, fabricação de produtos amiláceos e de alimentos para animais; fabricação e refino de açúcar; torrefação e moagem de café; e fabricação de outros produtos alimentícios.

localizada em uma região metropolitana, e 0 para a microrregião que não está localizada na região metropolitana.

Para a análise foram utilizadas 557 microrregiões³⁶ do Brasil, sendo que os dados de vínculos, capital humano e densidade foram coletados do Relatório Anual de Informações Sociais (RAIS) e as variáveis PIB, VABAGR e VABIND do Laboratório de Ciência de Dados do Instituto de Pesquisa Econômica Aplicada (Ipeadata)³⁷. Todos os dados utilizados, exceto a variável dependente, foram colocados em logaritmo e são referente ano de 2016. Enquanto, o *software* usado foi o R.

4 ANÁLISE DOS RESULTADOS

O objetivo da seção é apresentar a análise empírica do estudo. Primeiramente será apresentada alguns pontos sobre capital humano na indústria de alimentos, seguida pelos resultados da Regressão Geograficamente Ponderada.

4.1 Capital humano na Indústria de Alimentos

A indústria de alimentos, como parte integrante do sistema agroalimentar no Brasil, é um setor beneficiador e processador de produtos agropecuários, tendo se tornado um setor de transformação industrial bastante complexo com ramificações nas suas cadeias produtivas, com padrões diferenciados de competitividade e de estruturas de mercado (SATO, 1998).

Segundo a Associação Brasileira da Indústria de Alimentos (ABIA - 2018), 9,8% do Produto Interno Bruto (PIB) brasileiro é representado pela indústria de alimentos sendo um dos principais empregadores dentro da indústria brasileira. Conforme os dados da RAIS (2016), o Brasil apresenta 454.719 estabelecimentos na indústria de alimentos, totalizando 1.479.198 vínculos no setor.

Apesar da representatividade no número de vínculos na indústria de alimentos somente 12,39% dos vínculos apresentam ensino superior. A microrregião (Figura 1) que apresenta maior porcentagem de escolaridade é Lapa (PR) com 91,44% dos vínculos com ensino superior,


³⁶ Divisão geográfica regional do país vigente entre 1989 e 2017, segundo a composição elaborada pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2017).

³⁷ <http://www.ipeadata.gov.br>

seguido por São Miguel de Araguaia (MT), Arinos (MT), Alvorada Doeste (RO) e Médio Araguaia (MT) com 89,23%, 83,85%, 81,77% e 80,50%, respectivamente.

Outras microrregiões (Figura 1)³⁸ destacam-se por possuir mais que 50% dos vínculos na indústria de alimentos com ensino superior. As principais microrregiões estão concentradas nos estados de Mato Grosso, Mato Grosso do Sul, Rondônia, Pará, São Paulo, Paraná e Santa Catarina.

Figura 1 – Microrregiões com maior porcentagem de capital humano na indústria de alimentos



Fonte: RAIS (2016).

A educação desempenha papel importante para que as empresas do setor de alimentação desenvolvam atividades inovativas, tanto de processo ou produto. Os gastos referentes a pesquisa e desenvolvimento (P&D) também apresentam efeito positivo, e estatisticamente significativo, para a probabilidade da firma adotar inovações (CONCEIÇÃO; ALMEIDA, 2005). As empresas, cadeias produtivas e pessoas competitivas são a força do agronegócio, são as pessoas que fazem as organizações eficientes, reduzem custos, promovem inovações e a diferenciação de produtos, sendo que desenvolver capital humano deveria ser uma das prioridades brasileiras (WEDEKIN; CASTRO, 2002).

³⁸ Norte Araguaia (MT – 74,58%), Vilhena (RO – 73,92%), Parecis (MT – 73,48%), Alto Guaporé (MT – 71,78%), Conceição do Araguaia (PA – 71,03%), Cassilândia (MS – 69,82%), Amparo (SP – 60,92%), Lins (SP – 60,36%), São Miguel do Oeste (PR – 59,39%), Campo Grande (MS – 57,54%), Alta Floresta (MT – 57,08%), Criciúma (SC – 56,17%), Jauru (MT – 55,84%), Marabá (PA – 53,35%) e Aquidauana (MS – 51,79%).

Os segmentos que assimilaram inovações tecnológicas são os que hoje são compostos de grandes empresas, competitivas quanto aos padrões internacionais. Dentro da indústria de alimentos destacam-se a indústria de suco concentrado de laranja, de óleos e gorduras vegetais, de carnes industrializadas e de laticínios. Nesses segmentos, ao longo dos anos, foram incorporadas inovações que foram viabilizadas através de pesquisa e desenvolvimento realizados nas duas pontas, no setor agrícola e no setor processador (indústria alimentícia), via incentivos governamentais (SATO, 1998).

4.2 Resultados para Regressão Geograficamente Ponderada

Os resultados para o MQO (Tabela 1), demonstraram uma relação positiva para todas as variáveis, exceto o intercepto e a *dummy*, que também apesentou não ser significativo, enquanto as demais variáveis mostraram-se significativas a 1 ou 5%. O aumento dos vínculos da indústria de alimentos reflete no aumento significativo do PIB *per capita*, participação do VAB agropecuário e da educação.

Tabela 1 – Resultado do MQO

Variável	Estimate	std. Error	T	pr (> /t/)
Intercepto	-1.46379	0.18667	-7.842	0.00000
PIB	0.21931	0.06668	3.289	0.00107
VABAGR	0.36225	0.03138	11.544	0.00000
VABIND	0.16673	0.05489	3.038	0.00250
CAPHUMANO	0.25091	0.02989	8.395	0.00000
DENSID	0.17359	0.02496	6.954	0.00000
Dummy	-0.01918	0.07946	-0.241	0.80935

Fonte: Elaboração própria a partir dos resultados do estudo.

Quando analisado os coeficientes para o modelo de Regressão Geograficamente Ponderada (Tabela 2) temos que o mínimo para o intercepto foi de -6.97, enquanto o máximo foi de 0.47, observa-se que ocorre diferença regional entre os valores estimados. A variável PIB *per capita* apresenta maior impacto no máximo no qual é de 0.91 e o mínimo de -0.83, enquanto a variável capital humano apresenta mínimo de -0.22 e máximo de 0.47.

Tabela 2 – Estatísticas dos coeficientes estimados no modelo RGP

	Mínimo	Mediana	Máximo	Global
X.Intercept	-6.97298495	-1.78515563	0.47330654	-1.4638
PIB	-0.83455284	0.27746534	2.09096791	0.2193
VABAGRO	0.02938524	0.39461731	0.90951385	0.3622
VABIND	-0.17167571	0.17281115	0.80224826	0.1667
CAPHUMANO	-0.21753730	0.24557610	0.47211614	0.2509
DENSID	-0.00059581	0.19237412	0.73348290	0.1736
Dummy	-0.76774824	-0.00742004	0.59509963	-0.0192

Fonte: Elaboração própria a partir dos resultados do estudo.

A Figura 2, desagrega a análise do modelo RGP, através de coeficientes locais da variável explicativa - capital humano - referente a variável dependente - participação de vínculos da indústria de alimentos no total dos vínculos das microrregiões. A cor preta representa maior influência da educação na participação de vínculos na indústria de alimentos, seguido por vermelho, enquanto, a cor verde apresenta menor influência. Observa-se os vínculos com capital humano estão concentrados nas regiões economicamente mais desenvolvidas com a prevalência dos estados da Região Sudeste e Sul.


Em linhas gerais, o capital humano influencia fortemente a participação dos vínculos na faixa que vai de Santa Catarina, Paraná, São Paulo, Rio de Janeiro, Espírito Santo e algumas microrregiões de Minas Gerais. Na região do nordeste destacam-se microrregiões da Bahia e Ceará, enquanto na região norte do país, encontra-se pontos nas microrregiões do Amapá e Roraima.

Em relação ao capital humano, segundo Dalla Corte e Moraes (2018) os estados mencionados apresentam destaque no aumento dos anos de estudo da população. Enquanto, a média do Brasil é de 7,18 anos, os estados de São Paulo, Rio de Janeiro, Santa Catarina, Amapá e Paraná, apresentam 8.16, 8.2, 7.8, 7.7 e 7,55 anos de estudos, respectivamente, sem contar que o Distrito Federal que mantém a média de 9 anos de estudo.

Coefficientes locais da variável capital humano com maior intensidade não é observado em grande parte do Rio Grande do Sul, estados do centro-oeste e nordeste. Conforme Viana (2016) a distribuição geográfica da indústria de alimentos apresenta certa relação com a distribuição da população brasileira, pois alguns setores têm forte viés de descentralização da produção de acordo com a distribuição do mercado consumidor. A mesma observação é feita para os empregos, sendo que entre os dez estados que apresentam maior número de empregos ocorre concentração no estado de São Paulo (26%) em comparação com o número de

estabelecimentos (16,7%), sinalizando que predominam empresas de maior porte na indústria de alimentos.

Figura 2 – Coeficientes locais da variável capital humano do modelo RPG referente a variável



Fonte: Elaboração própria a partir do software R

Na Região Sul, as microrregiões dos estados de Santa Catarina e Paraná, apresentam alta influência do capital humano sob os vínculos da indústria de alimentos. Cunha (1992) apresenta algumas explicações para o sucesso da indústria catarinense que permanecem sendo atuais como: recursos humanos que são capacitados para suas atividades produtivas, tanto no setor rural que está ligado as agroindústrias como o setor industrial; as economias de

aglomeração nos pólos industriais de Joinville e Blumenau; os conglomerados industriais tornando-se fatores determinantes da dinamização da indústria através dos ganhos de escalas e maior capacidade de absorção e desenvolvimento tecnológico; e a influência das universidades, estabelecimentos de ensino superior e escolas técnicas.

No estado do Paraná, na década de 2000, segundo Raiher e Dathein (2009), ocorreu uma melhora significativa no capital humano, sendo que 97% das microrregiões elevaram a média de anos de estudo, 62% aumentaram o nível de treinamento por trabalhador, e 21% diminuíram a taxa de rotatividade da mão de obra. Apesar dos resultados não serem somente da indústria de alimentos, mostram que o estado vem investindo no aumento do capital humano no qual resulta no aumento da produtividade de toda uma economia. Ou seja, vem ocorrendo aumento significativo da habilidade e do conhecimento dos paranaenses, notadamente com relação à qualidade desse capital humano formado.

Lima e Viana (2009) confirmaram a importância do capital humano para o crescimento econômico do Estado do Paraná, sendo que os autores demonstraram que essa variável é fundamental para o desempenho das economias regionais, pois seu coeficiente foi preponderante em todas as mesorregiões, com exceção da Mesorregião Noroeste paranaense. Os autores também encontraram que o capital humano é fundamental ao bom desempenho econômico, pois foi uma das variáveis mais significativas no maior crescimento obtido pelas mesorregiões Metropolitana e Centro-Oriental paranaenses.

Na Região Nordeste, as microrregiões dos estados da Bahia e Ceará que apresentam maior capital humano na indústria de alimentos. Conforme o Programa para Resultados (2015) tem-se que o desenvolvimento da economia cearense deve ocorrer a partir do fortalecimento do seu setor produtivo apoiado em inovação e capital humano. Um primeiro passo nesta direção é aumentar o estoque de capital humano, melhorando os níveis de qualificação da força de trabalho. Uma mão de obra adequadamente qualificada cria as bases para a formação de um ambiente inovador e amplia a produtividade da economia, além de favorecer uma melhor distribuição da renda e maior mobilidade social.

O mapa de centralização regional no Brasil contemporâneo do estudo de Parreira e Vieira (2019) mostrou-se ser bastante similar com os resultados deste estudo. O autor mostra que ocorre uma continuidade da concentração regional que foi herdada desde a industrialização brasileira que apresenta melhores posicionamentos das regiões Sul (78%), Sudeste (67%) e Centro-Oeste (21,7%) em oposição às regiões Norte (19%) e Nordeste (17%).

A variável capital humano no estudo de Parreira e Vieira (2019) mostrou ter impacto nos estados de Santa Catarina, Paraná, São Paulo, Rio de Janeiro, Espírito Santo, Rio Grande do Norte, Tocantins, Roraima, Amazonas e Distrito Federal. A região Norte equiparou-se à região Sudeste tendo ambas 30% representatividade nacional, seguidas da região Sul (20%) e Nordeste e Centro-Oeste com 10%. Em termos de representatividade regional o destaque ficou para a região sudeste que teve três dos seus estados (RJ, SP e ES - 75%) pontuado entre os dez melhores do *ranking*, seguidos pela região sul (SC e PR - 67%). O primeiro lugar ficou para o Distrito Federal no Centro-Oeste.

5 CONSIDERAÇÕES FINAIS

O artigo propôs analisar como se distribuem espacialmente os vínculos da indústria de alimentos com maior capital humano (ensino superior). Apesar da representatividade do número de vínculos nesse segmento, somente 12,39% apresentam ensino superior, sendo que a microrregião que apresenta maior porcentagem de escolaridade é Lapa (PR) com 91,44%, seguido por São Miguel de Araguaia (MT), Arinos (MT), Alvorada Doeste (RO) e Médio Araguaia (MT) com 89,23%, 83,85%, 81,77% e 80,50%, respectivamente.

Através da metodologia de Regressão Geograficamente Ponderada pode-se observar pontos específicos no qual os resultados apontaram que o capital humano influencia fortemente a participação dos vínculos com maior intensidade nas microrregiões que estão distribuídas espacialmente nos estados de Santa Catarina, Paraná, São Paulo, Rio de Janeiro, Espírito Santo e Minas Gerais. Na região do nordeste destaca-se microrregiões da Bahia e Ceará, enquanto na região norte, encontra-se microrregiões do Amapá e Roraima.

Da mesma forma que o estudo de Parreira e Vieira (2019), os resultados mostraram que as indústrias de alimentos que estão aglomeradas nas microrregiões do Sudeste e Sul apresentam vínculos com maior capital humano. Conclui-se que as microrregiões estão alocadas nas regiões que são mais desenvolvidas economicamente e que a população apresenta facilidades em adquirir maiores níveis de escolaridade e de competências.

Por mais que outros trabalhos supracitados não utilizem a mesma metodologia, os resultados estão consistentes com autores que mostram a influência dos vínculos que apresentam maior capital humano na indústria em geral. A falta de literatura que analisa a distribuição espacial no setor de alimentos tornou-se a principal limitação em relação a comparação dos resultados.

Desta forma, o presente estudo buscou contribuir com a análise da distribuição espacial da indústria de alimentos, segmento pouco explorado na literatura, de forma não ficar concentrado em setores da economia que já estão batidos. Para trabalhos futuros é possível incluir demais variáveis que são importantes na influência do capital humano, sendo ela quantitativas ou qualitativas.

REFERÊNCIAS

ALMEIDA, Eduardo. **Econometria Espacial Aplicada**. Campinas, SP: Editora Alínea; 2012.

AMARAL, G. F.; D. D, GUIMARÃES. Panoramas setoriais 2030 – Alimentos. In: **Panoramas setoriais 2030: desafios e oportunidades para o Brasil**. Rio de Janeiro: BNDES, 2017, 225 p.

ANSELIN, L.; LOZANO-GARCIA, N. Errors in variables and spatial effects in hedonic house price models of ambientair quality. In: ARBIA, G.; BALTAGI, B. H. (ed), **Spatial Econometrics: methods and applications**. Heidelberg: Ed. Phisica Verlag, 2009.

ARAÚJO, N. C. M. Origens e evolução espacial da indústria de alimentos do Rio Grande do Sul. [online]. In: 1º Encontro de Economia Gaúcha. Porto Alegre: PUC/FACE, 2002. Disponível em: http://cdn.fee.tche.br/eeg/1/mesa_10_araujo.pdf. Acesso em: 22 out. 2019.

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ALIMENTOS - ABIA. **Faturamento**. Disponível em: <https://www.abia.org.br/vsn/anexos/faturamento2019.pdf>. Acesso em: 25 fev. 2019.

BEGNIS, H. S. M.; ESTIVALETE, V. F. B.; SILVA, T. N. Ensino, Pesquisa e Capital Humano na Qualificação de Profissionais do Agronegócio no Brasil. Evento: Anpad, 2005. Disponível em: http://www.anpad.org.br/diversos/down_zips/9/enanpad2005-epqa-0711.pdf. Acesso em: 26 mar. 2020.

CAMERON, A. C.; TRIVEDI, P. D. **Microeconomics: methods and applications**. Cambridge University Press, Cambridge, 2005.

CARVALHO, L. E. X.; SILVA, H. N.; LOUREIRO, C. F. G.; MENEZES H. B. Regressão Linear Geograficamente Ponderada em ambiente SIG. **Transportes**, v. 14, n. 2, p. 18-26, 2006.

CONCEIÇÃO, J. C. P. R.; ALMEIDA, M. Inovação na indústria de alimentos no Brasil: identificação dos principais fatores determinantes. In: NEGRI, J. A.; SALERNO, M. (Orgs). Inovações, padrões tecnológicos e desempenho das firmas industriais brasileiras. Brasília: IPEA, 2005. Cap. 15, p. 599-651.

CUNHA, I. J. O salto da indústria catarinense: Um exemplo para o Brasil. Florianópolis: Paralelo 27, 1992.

DALLA CORTE, G. M.; MORAES, M. L. Dinâmica industrial e inovação no Estado do Paraná entre 2004 e 2014. **Revista Gestão Industrial**, Ponta Grossa, v. 14, n. 4, p. 196-221, out./dez. 2018.

FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. Geographically weighted regression: the analysis of spatially varying relationships. John Wiley and Sons, West Sussex, 2002.

GOMES, C. E.; EVANGELISTA, T. F.; LIMA, R. L., PARRÉ, J. L. Determinantes do crime nos municípios de Minas Gerais e seus possíveis *spillovers* espaciais. **Economia-Ensaio**, Uberlândia, v. 31, n. 2, p. 201-228, 2017.

INSTITUTO DE PESQUISA ECONOMICA APLICADA – IPEADATA. Dados macroeconômicos e regionais. Disponível em: < <http://www.ipeadata.gov.br>>. Acesso em: 10 abr. 2018.

LIMA, F. L.; VIANA, G. Capital Humano e Crescimento Econômico: o caso da economia paranaense no início do século XXI. **Revista Paranaense de Desenvolvimento**, Curitiba, n.116, p.139-167, 2009.

PARREIRA, K. M.; VIEIRA, J. C. Mapa da (des)centralização regional no Brasil contemporâneo. Anais: IX Seminário Internacional sobre Desenvolvimento regional. Santa Cruz do Sul - RS, 2019.

PARTRIDGE, M. D.; RICKMAN, D. S.; ALI, K.; OLFERT, M. R. The geographic diversity of U.S. Nonmetropolitan Growth Dynamics: A Geographically Weighted Regression Approach. **Land Economics**, v. 84, n. 2, p. 241-266, 2008.

PROGRAMA PARA RESULTADOS – PforR. Estratégia de Desenvolvimento Econômico para o estado do Ceará a partir do fortalecimento do setor produtivo, apoiada em inovação e com foco na formação de capital humano. Ceará, 2015. Disponível em: http://www2.ipece.ce.gov.br/pforr/programas/Programa_para_Resultados_PforR2015.pdf. Acesso em: 03 abr. 2020.

RAIHER, A. P.; DATHEIN, R. Análise espacial e intertemporal do capital humano nas microrregiões paranaenses. **Revista Paranaense de Desenvolvimento**, Curitiba, n. 116, p. 33-68, 2009.

RELATÓRIO ANUAL DE INFORMAÇÕES SOCIAIS – RAIS. Rais Vínculos. Disponível em: <http://bi.mte.gov.br/bgcaged/inicial.php>. Acesso em: 20 fev.2019.

SANTOS, G. **Produtividade do trabalho na indústria de transformação nordestina: qual a importância do capital humano e do progresso tecnológico?** 2016. Dissertação (Mestrado em Economia) - Programa de Pós-graduação em Economia-PROPEC da Universidade Federal de Sergipe.

SATO, G. S. **Estratégia e estrutura organizacional na Indústria de Alimentos: o caso Sadia**. 1998. Tese (Tese em Administração de empresas) – Escola de Administração de empresas São Paulo – Fundação Getúlio Vargas, p. 196.

WEDEKIN, I.; CASTRO, P. R. Políticas para expansão do agribusiness no Brasil até 2010. In: **Anais I Congresso Brasileiro de Agribusiness**. ABAG – Associação Brasileira de Agribusiness. São Paulo, 2002.

VIANA, F. L. E. Indústria de alimentos. Caderno Setorial ETENE, ano 1, n. 4, 2016.

5 CONCLUSÃO

Autores como Lucas (1988), Romer (1986, 1989, 1990) e Mankiw, Romer e Weil (1992) mostram a importância que o capital humano tem em relação ao crescimento econômico das regiões e dos países, sendo que através de maior capital humano os indivíduos adquirem maiores habilidades e conhecimentos resultando em maior nível de produção.

De modo geral, a tese abordou a influência do capital humano no crescimento econômico dos municípios do Brasil e a aglomeração agroindustrial dos vínculos da indústria de alimentos na distribuição espacial das microrregiões brasileiras. Como mencionado ao longo do texto, o capital humano ganhou destaque como fator determinante no crescimento econômico, inferindo que maior nível educacional da população resulta em indivíduos com maiores habilidades e conhecimentos.

No primeiro ensaio, a *proxy* de capital humano (percentual da população de 25 anos ou mais com superior completo) demonstrou que quanto maior for o nível de escolaridade da população, maior será a taxa de crescimento do município, sendo que um aumento de 1% nessa variável gera uma elevação de 13,68% na taxa de crescimento. Percebe-se que somente o capital humano não é capaz de explicar o aumento da taxa de crescimento de um município, porém consiste em uma variável importante no modelo desenvolvido e na literatura correntemente difundida.

Após analisar a importância do capital humano para o crescimento regional, trabalhou-se com o objetivo de entender a relação entre a localização e a influência do capital humano dentro de um setor específico da economia. Subsidiado pela *proxy* de capital humano (porcentagem de vínculos com ensino superior), o segundo e o terceiro ensaio, mostraram a importância da variável na indústria de alimentos.

No segundo ensaio, o objetivo foi verificar os padrões geográficos das agroindústrias de alimentos dispostos nas microrregiões do país. A mesma encontra-se em todas as regiões do país, porém, quando analisado a influência da *proxy*, observa-se que os vínculos com maior capital humano estão aglomerados nas regiões sul, sudeste e no centro-oeste, ou seja, regiões em que é muito presente o agronegócio intensivo em tecnologia, sendo necessário maior conhecimento.

Os resultados contrapõem a teoria clássica em que as agroindústrias tendem a ser uma atividade com orientação geográfica aos insumos, pois os resultados mostram que atualmente outros fatores como mão de obra qualificada, acesso ao mercado consumidor, e a clusterização

para o ganho de produtividade são importantes para a indústria de alimentos além de estar próximo da matéria-prima.

O terceiro ensaio analisou como se distribuem espacialmente os vínculos da indústria de alimentos com maior *proxy* capital humano (participação de vínculos da indústria de alimentos no total dos vínculos das microrregiões). Diferente da metodologia do segundo ensaio, que mostra a influencia de um município em relação aos seus vizinhos, no terceiro, é possível observar pontos específicos (microrregiões) onde ocorrem influencia dos vínculos com maior capital humano, sendo possível através da metodologia de Regressão Geograficamente Ponderada.

Os resultados mostraram que os vínculos com maior capital humano influenciam com maior intensidade as microrregiões que estão distribuídas espacialmente nos estados de Santa Catarina, Paraná, São Paulo, Rio de Janeiro, Espírito Santo e Minas Gerais. Na região nordeste destacam-se as microrregiões da Bahia e Ceará, enquanto na região norte, encontram-se microrregiões do Amapá e Roraima.

Diferente do ensaio 2, no terceiro, as aglomerações prevalecem na região sul e sudeste, de forma que os vínculos com maior capital humano na região centro-oeste não interferem a indústria de alimentos com tanta significância. A partir da metodologia utilizada que obtém os coeficientes locais para cada ponto do espaço destaca-se que os vínculos da indústria de alimentos com maior influencia de capital humano estão alocados nos estados de Santa Catarina, Paraná e Espírito Santo regiões em que esse setor apresenta ser bastante difundido com grandes indústrias alimentícias.

Assim sendo, a tese se propôs a responder de forma geral a influência do capital humano na taxa de crescimento dos municípios do Brasil; e, posteriormente, por meio da análise específica da indústria de alimentos, verificar se ocorre aglomeração agroindustrial no setor e como se apresenta a distribuição espacial dos vínculos nas microrregiões do Brasil com maior capital humano.

Conclui-se que o problema de pesquisa foi respondido, de forma que a influência do capital humano no crescimento econômico dos municípios mostrou aglomerações principalmente nas regiões que são mais desenvolvidas, ou seja, nas regiões sudeste e sul. Porém, também é possível encontrar aglomerações em estados específicos do centro-oeste. Quando analisado um setor específico da economia, os resultados se mantiveram semelhantes, destacando as regiões sul, sudeste, centro-oeste, porém com alguns locais isolados em estados da região nordeste e norte.

Os resultados mostraram a importância do capital humano para os indivíduos adquirirem maiores habilidades e conhecimentos que resultariam em setores mais produtivos. Em suma, observa-se que o capital humano sozinho não é capaz de aumentar o crescimento econômico de um país ou mesmo mostrar que indústrias de alimentos são mais produtivas com o aumento de vínculos com maior grau de escolaridade, porém é o caminho para uma economia mais desenvolvida e setores mais produtivos. O capital humano é importante, porém, além do aumento da educação dos indivíduos são necessários outros fatores correlacionados, tais como qualidade da educação.

A presente tese contribui com a literatura a partir de dois pontos, o primeiro, em relação ao ensaio 1, busca-se fazer uma análise mais completa em relação ao tema, utilizando os municípios do Brasil, pois grande parte da literatura utiliza apenas municípios de regiões específicas ou até mesmo microrregiões. Porém, ao trabalhar com todos os municípios do país encontra-se com limitação variáveis desatualizadas, no qual acaba sendo necessário utilizar um período menos atual. O segundo e o terceiro ensaio analisam a indústria de alimentos, segmento pouco explorado na literatura espacial, desta forma torna-se difícil comparar os resultados com demais autores.

6 REFERÊNCIAS

ARAÚJO, N. C. M. Origens e evolução espacial da indústria de alimentos do Rio Grande do Sul. [online]. In: 1º Encontro de Economia Gaúcha. Porto Alegre: PUC/FACE, 2002. Disponível em: http://cdn.fee.tche.br/eeg/1/mesa_10_araujo.pdf. Acesso em: 22 out. 2019.

BECKER, G. S. **Human capital**: a theoretical and empirical analysis, with special reference to education. New York: Columbia University Press, 1964.

BECKER, G. S. **Human capital**: a theoretical and empirical analysis, with special reference to education. 3.rd ed. New York: National Bureau of Economic Research, 1993.

EMILIO, D. R.; BELLUZZO, W. J.; ALVEZ, D. C. O. Uma análise econométrica dos determinantes do acesso à universidade de São Paulo. **Pesquisa e Planejamento econômico**, v. 34, n. 2, 2004.

GALEANO, E. A. V.; MATA, H. T. da. C. Diferenças regionais no crescimento econômico: uma análise pela Teoria do Crescimento Endógeno. **REN**, Documento técnico-científicos, v. 40, n. 04, 2009.

LUCAS, R.E. On the mechanics of economic development. **Journal of Monetary Economics**, v. 22, p. 3-42, 1988.

LIMA, F. L.; VIANA, G. Capital Humano e Crescimento Econômico: o caso da economia paranaense no início do século XXI. **Revista Paranaense de Desenvolvimento**, Curitiba, n. 116, p. 139-167, 2009.

MANKIW, N. G; ROMER, D.; WEIL, D. A contribution to the empirics of growth. **NBER Working Paper Series**, Cambridge: National Bureau of Economic Research, n. 3541, 1992.

MINCER, J. Investment in human capital and personal income distribution. **The Journal of Political Economy**, v. 66, n. 4, p. 281-302, 1958.

NAKABASHI, L. **Três ensaios sobre o capital humano e renda por trabalhador**. Belo Horizonte, 2005. Tese (doutorado em Economia) - Centro de Desenvolvimento e Planejamento Regional, Universidade Federal de Minas Gerais.

RAIHER, A. P.; DATHEIN, R. Análise espacial e intertemporal do capital humano nas microrregiões paranaenses. **Revista Paranaense de Desenvolvimento**, Curitiba, n. 116, p. 33-68, 2009.

ROMER, P. M. Human capital and growth: theory and evidence. **NBER, Working Paper**, Cambridge: National Bureau of Economic Research, n. 3173, 1989.

ROMER, P. M. Increasing returns and long-run growth. **The Journal of Political Economy**, Chicago: University of Chicago Press, v. 94, n. 5, p. 1002-1037, 1986.

ROMER, P. M. Endogenous Technological Change. **Journal of Political Economy**, v. 98, n. 5, p. 71-99, 1990.

SCHULTZ, T. W. **Investindo no povo**: o segredo econômico da qualidade da população. Rio de Janeiro: Forense Universitária, 1987.

SCHULTZ, T. W. **O capital humano**: investimentos em educação e pesquisa. Rio de Janeiro: Zahar, 1973.

SCHULTZ, T. W. **O valor econômico da educação**. Rio de Janeiro: Zahar, 1964.

SOLOW, R. A. A contribution of the Theory of economic growth. **Quarterly Journal of Economics**, Cambridge: Harvard University, v. 70, n. 1, p. 65-94, 1956.



Pontifícia Universidade Católica do Rio Grande do Sul
Pró-Reitoria de Graduação
Av. Ipiranga, 6681 - Prédio 1 - 3º. andar
Porto Alegre - RS - Brasil
Fone: (51) 3320-3500 - Fax: (51) 3339-1564
E-mail: prograd@pucrs.br
Site: www.pucrs.br