

## ANÁLISE DOS EFEITOS DOS GASTOS PÚBLICOS ESTADUAIS EM EDUCAÇÃO SOBRE A CRIMINALIDADE NOS MUNICÍPIOS DO RIO GRANDE DO SUL

Adelar Fochezatto<sup>1</sup>

Jacó Braatz<sup>2</sup>

Guilherme Petry<sup>3</sup>

Henrique Romão Marcondes<sup>4</sup>

### Resumo

A criminalidade tem sido um dos principais problemas das sociedades modernas. No Brasil, nos últimos anos, ela vem aumentando significativamente e influenciando negativamente a qualidade de vida das pessoas, podendo ocasionar perdas de vida humana e outros custos diretos e indiretos como a extinção de patrimônio e prejuízos no desempenho escolar. Há, no Brasil, uma concentração de crimes na faixa etária entre 15 e 19 anos, o que naturalmente liga o tema da criminalidade com o da educação. Vários autores defendem que investimentos na primeira infância para promover a aprendizagem são fundamentais, pois é neste período da vida que a pessoa desenvolve suas primeiras habilidades e as noções de moralidade e civilidade. Estas habilidades acumulam capital humano ao longo do ciclo de vida e promovem melhores oportunidades, diminuindo a propensão a cometer crimes. O acesso à escola, a retenção do aluno e o seu rendimento escolar dependem de investimentos em infraestrutura e em recursos humanos na área da educação. Por isso, uma via alternativa para estudar a relação entre educação e criminalidade é através dos gastos na função educação. Este estudo procura identificar relações entre o crime e as características socioeconômicas dos municípios do Rio Grande do Sul. Mais especificamente, utilizando um modelo de econometria espacial, o objetivo é verificar se os gastos públicos em educação nos municípios influenciam as taxas de criminalidade. Os resultados obtidos permitem afirmar que um aumento dos gastos públicos em educação tende a diminuir a criminalidade nos municípios.

**Palavras-chave:** Educação; Criminalidade; Econometria espacial; Rio Grande do Sul.

**Área EEG:** Macroeconomia Regional, Setor Externo, Finanças Públicas

---

<sup>1</sup> Doutor em Economia. Professor Titular da PUCRS. Pesquisador do CNPq. E-mail: adelar@pucrs.br

<sup>2</sup> Doutor em Economia do Desenvolvimento. Auditor-Fiscal da Receita Estadual. E-mail: jacob@sefaz.rs.gov.br

<sup>3</sup> Mestrando no PPGE/PUCRS. Auditor-Fiscal da Receita Estadual. E-mail: guilhermecp@sefaz.rs.gov.br

<sup>4</sup> Mestrando no PPGE/PUCRS. E-mail: henrique.marcondes@hotmail.com.br

## 1. Introdução

A criminalidade tem sido um dos principais problemas das sociedades modernas. No Brasil, nos últimos anos, ela vem aumentando significativamente. Segundo Cerqueira *et al* (2017), em 2015, houve, no Brasil, uma taxa de 28,9 homicídios por 100 mil habitantes. Este número representa um aumento de 4% em relação a 2010, que foi de 27,8 homicídios por 100 mil habitantes. No mesmo período, no Rio Grande do Sul (RS), a taxa aumentou 34,2%, passando de 19,5 para 26,2 homicídios por 100 mil habitantes (ver Anexo 3).

O aumento da criminalidade não ocorreu apenas nos homicídios, mas também em outros tipos de crime. No RS, considerando as estatísticas da Secretaria de Segurança Pública (SSP), o número total de crimes aumentou 7% entre 2010 e 2015, passando de 2.677 para 2.865 ocorrências de crimes para cada 100 mil habitantes. Entre os tipos de crimes, os mais importantes são roubos e furtos, que aumentaram 7,5% no período, passando de 2.280 para 2.452 ocorrências para cada 100 mil habitantes.

A criminalidade afeta negativamente a qualidade de vida das pessoas, podendo ocasionar perdas de vida humana e outros custos diretos e indiretos como a extinção de patrimônio, prejuízos no desempenho escolar, entre outros. De acordo com Cerqueira *et al* (2017), o problema da criminalidade tem implicações na saúde e na dinâmica demográfica e, por conseguinte, no desenvolvimento econômico e social. Um dado impressionante que ilustra esta questão é a participação da juventude masculina nas taxas acima referidas. Se for considerada a faixa etária entre 15 e 29 anos, os jovens do sexo masculino corresponderam a 47,8% do total de óbitos em 2015. Na faixa entre 15 e 19 anos, a participação masculina é ainda maior, chegando a 53,8% do total. Em vista disso, o combate à criminalidade tem sido um dos principais alvos de políticas públicas.

A concentração de crimes nessa faixa etária naturalmente liga o tema da criminalidade ao da educação. Cunha *et al* (2005) evidenciaram que há períodos críticos no ciclo de vida das pessoas, que são cruciais para o desenvolvimento de suas habilidades. Os autores defendem que investimentos na primeira infância para promover a aprendizagem são fundamentais, pois é neste período da vida que a pessoa desenvolve suas primeiras habilidades e as noções de moralidade e civilidade. Estas habilidades potencializam a acumulação de capital humano ao longo do ciclo de vida e promovem melhores oportunidades para o indivíduo, tornando-o menos propenso a cometer crimes (BECKER, 2012).

Vários estudos aplicados ao caso brasileiro apontam para a existência de uma relação inversa entre níveis de escolaridade da população e níveis de criminalidade. Fajnzlber e Araújo Jr. (2001) encontraram uma relação positiva entre analfabetismo e taxas de homicídios. Kume (2004) e Santos (2009) indicaram uma relação negativa entre escolaridade média (anos de estudo) e criminalidade. Resende (2007) apontou uma relação negativa entre o número de adolescentes entre 15 e 17 anos na escola e homicídios. Scorzafave e Soares (2009) observaram uma relação negativa entre a taxa de matrículas e crimes não pecuniários. Teixeira (2011) assinalou uma relação positiva entre o abandono escolar e homicídios.

O acesso à escola, a retenção do aluno na escola e o seu rendimento escolar dependem de investimentos em recursos humanos e em infraestrutura na área da educação. Por isso, uma via alternativa para estudar a relação entre educação e criminalidade é através dos gastos na área da educação. Neste sentido, Becker (2012), utilizando dados socioeconômicos dos estados brasileiros, encontrou uma elasticidade negativa entre gastos em educação (defasados em um período) e criminalidade.

O objetivo deste estudo é tentar identificar relações entre o crime e as características socioeconômicas no RS no período de 2010 a 2015. Mais especificamente, seguindo o trabalho de Becker (2012), o objetivo é verificar se os gastos públicos estaduais em educação nos municípios têm influência sobre as taxas locais de criminalidade. Dado que, em geral, os crimes não acontecem de forma aleatória no espaço geográfico, é utilizada a metodologia de análise exploratória de dados espaciais e de econometria espacial. O conhecimento de onde ocorrem as concentrações criminais, em cada momento do tempo, e as relações com as características socioeconômicas dos lugares pode ajudar nas decisões sobre a alocação de recursos escassos na área da segurança.

O trabalho está estruturado como segue. Na seção dois, é feita uma revisão de trabalhos que se dedicaram a descobrir os possíveis determinantes da criminalidade. Na seção três são apresentados os procedimentos metodológicos. Na seção quatro é feita a análise dos resultados. Por fim, aparecem os comentários conclusivos do trabalho.

## **2. Revisão bibliográfica**

Analisando a bibliografia teórica sobre o tema da criminalidade, é possível destacar três dimensões estratégicas como determinantes diretos ou indiretos dos níveis de criminalidade na sociedade: a família, a escola e a cidade. Muitos dos fatores que levam as pessoas a se envolverem com a criminalidade decorrem de situações que aconteceram durante a sua infância. Esses fatores incluem laços fracos com a família e laços fortes com amigos ou colegas antissociais e delinquentes. Farrington (1987) afirma que aumentam as chances de se tornarem infratores jovens que vêm de famílias em que: a disciplina é inconstante e errática; os pais pouco se preocupam com os filhos; os próprios pais têm problemas com drogas e crimes.

De acordo com Waiselfisz (1998), pelo fato de intervir diretamente na formação das pessoas desde os primeiros anos de vida, a escola é outra dimensão relevante, principalmente pela forte ligação entre a juventude e a violência. Soares (2007) diz que a educação é um escudo contra a criminalidade, especialmente no Brasil. Tauchen *et al* (1994) afirma que, indo à escola ou ao trabalho, reduz-se a probabilidade de os jovens se envolverem em atividades criminosas.

A urbanização, o tamanho da cidade e a densidade demográfica são variáveis determinantes da criminalidade. De acordo com Beato (1998), a localização dos crimes pode ser explicada pelas oportunidades e pela chance de identificação e captura. Em locais mais densamente povoados há uma diminuição na probabilidade de captura do agente infrator, favorecendo o comportamento delinquente. Grandes cidades oferecem, portanto, mais incentivos para o indivíduo cometer o delito, dado o possível anonimato. Case e Katz (1991) descobriram, também, que o comportamento de bairros vizinhos afeta substancialmente o comportamento juvenil. Portanto, residir em bairro ou próximo de bairro em que uma grande proporção de jovens está envolvida em crimes aumenta a probabilidade da pessoa se envolver com a criminalidade.

Araujo Jr e Fajnzylber (2000) analisaram as tendências longitudinais e espaciais das taxas de crimes em Minas Gerais e estimaram os determinantes das taxas de criminalidade nas microrregiões do estado. Para tanto, utilizaram variáveis representativas dos níveis educacionais médios, da desigualdade na distribuição de renda, do grau de urbanização, do grau de desorganização social e da participação de jovens na população. Os principais resultados foram: maiores níveis educacionais implicam menores taxas de crime contra a pessoa e maiores taxas de crimes contra a propriedade; a desigualdade de renda encontra-se associada a maiores taxas de homicídios e homicídios tentados; e a menores taxas de roubos

de veículos; microrregiões mais urbanizadas tendem a ter maiores taxas de estupro; a desorganização social, medida pela taxa de separações, está associada a maiores taxas para todos os crimes; uma maior proporção de jovens na população implica maiores taxas de crimes, particularmente aqueles contra a pessoa.

Oliveira (2008) fez uma análise espacial da criminalidade no Estado do RS. Para este fim, foi apresentado um modelo econométrico espacial para os determinantes da criminalidade. O modelo seguiu as contribuições da economia do crime, porém, acrescentou as contribuições da abordagem ecológica e as teorias do aprendizado social. No modelo, a criminalidade em cidades pode ser explicada por características locais em que o ambiente, a vizinhança e o histórico do indivíduo afetam a criminalidade. Foram utilizados dados municipais agregados para homicídios, roubos e furtos no ano de 2000. Os testes realizados mostraram a existência de dependência espacial em roubos e furtos e independência espacial em homicídios. No artigo, ficaram destacados os papéis da desigualdade de renda e das aglomerações urbanas como fatores que potencializaram a criminalidade em cidades. Foram discutidas também as importâncias da família e da escola na explicação da criminalidade. Os resultados obtidos mostraram que problemas na estrutura familiar e a ineficiência do ensino afetaram positivamente a criminalidade. Neste artigo, os benefícios do crime e os custos de oportunidade foram divididos, o que permitiu concluir que o crescimento econômico não implicou diretamente o aumento da criminalidade. Isto porque, se houvesse um aumento da renda dos mais pobres, a criminalidade diminuiria.

Freitas *et al* (2015) criaram um indicador geral de criminalidade com base em 14 tipologias de crimes extraídas das estatísticas oficiais da Secretaria de Segurança Pública do Rio Grande do Sul para os 496 municípios gaúchos e para o ano de 2013. O indicador foi denominado de IGcrime e seu valor variou de *zero* a *um*, onde *um* representava um baixo nível de criminalidade e *zero* um alto nível de criminalidade. O IGcrime agrupou todas as tipologias de crimes realizando uma ponderação com base nas penas atribuídas pelo Código Penal Brasileiro. Ademais, o IGcrime de cada município foi calculado utilizando um critério bayesiano empírico que promoveu um ajustamento das taxas brutas dos crimes a fim de diminuir o efeito aleatório daqueles ocorridos em municípios de população pequena. O IGcrime calculado para o RS mostrou que os piores índices estavam concentrados em sete municípios na Região Metropolitana de Porto Alegre e em três municípios do interior.

Kleinschmitt *et al* (2012) analisaram a distribuição espacial dos homicídios no Estado do Paraná e a sua relação com as variáveis socioeconômicas, demográficas e de infraestrutura urbana. O método de Análise Exploratória de Dados Espaciais (AEDE) foi utilizado para medir o grau de autocorrelação espacial entre as variáveis estudadas, a partir das características dos municípios do Estado. Os resultados demonstraram a existência da autocorrelação espacial das taxas de homicídio entre os municípios paranaenses. Ao considerar os mapas de *clusters*, verificou-se a presença de quatro grandes *clusters* do tipo Alto-Alto (AA) e quatro grandes *clusters* do tipo Baixo-Baixo (BB).

Farias *et al* (2008) verificaram a existência de *clusters* entre os municípios mineiros e determinaram um índice de criminalidade municipal, usando variáveis representativas de crimes violentos. Consideraram as similaridades apresentadas entre as taxas de crimes e a existência de possíveis padrões espaciais. Os resultados permitiram inferir que existem sete grupos de municípios distintos em Minas Gerais, conforme nível de criminalidade. Identificaram também que há dependência espacial nas taxas de criminalidade no Estado e que existem *clusters* distintos para crimes violentos contra o patrimônio e contra pessoas.

Kleinschmitt *et al* (2010) analisaram a evolução temporal e o perfil da mortalidade por homicídios no Estado do Paraná, bem como, avaliaram a distribuição espacial destes

homicídios no espaço. Constataram que as vítimas de homicídio, em sua grande maioria, eram do sexo masculino, jovens e solteiros, sendo as mortes provocadas por armas de fogo. O método de AEDE foi utilizado para verificar a presença de autocorrelação espacial das taxas de homicídio entre os municípios do Estado. Os resultados demonstraram a existência da autocorrelação espacial das taxas de homicídio entre os municípios paranaenses. Ao considerar os mapas de *clusters*, verificou-se a presença de três grandes *clusters* do tipo Alto-Alto (AA) no período de 1997 e 2001 e quatro grandes *clusters* do tipo AA no período 2002-2006. As maiores taxas de homicídio foram encontradas nos *clusters* constituídos por municípios situados na Mesorregião Metropolitana de Curitiba, na Mesorregião Norte Central, na Mesorregião Oeste e num conjunto de municípios das Mesorregiões Centro-Sul, Centro Ocidental, Oeste e Sudoeste.

Becker (2012) utilizou dados socioeconômicos dos estados brasileiros para estimar a relação entre os gastos públicos com educação e a criminalidade. Usou um painel de dados dos 26 estados brasileiros e do Distrito Federal, observados entre os anos de 2001 a 2009, compondo uma amostra de 243 observações. A variável *gasto em educação* entrou no modelo com dados defasados em um período. O estudo encontrou uma elasticidade negativa entre as duas variáveis, indicando que a atuação pública na área de educação pode contribuir para reduzir o crime.

### 3. Metodologia

Os crimes não acontecem de forma aleatória no espaço geográfico. O mesmo pode ser dito em relação aos criminosos, pois, em geral, eles vêm de lugares diferentes de onde cometerem o crime. O espaço geográfico, portanto, desempenha um papel vital na compreensão da dinâmica espacial da criminalidade e na definição de estratégias para combatê-la. Os estudos sobre criminalidade têm tradicionalmente sido objeto de estudo de disciplinas como a Sociologia e a Psicologia. Com os estudos da escola de Chicago na década de 1930, a geografia começou a ganhar importância na compreensão da criminalidade. A partir do final dos anos 1990, a polícia norte-americana começou a usar teorias e técnicas da análise espacial para a compreensão e combate ao crime (Chainey e Ratcliffe, 2005). Entre as técnicas de análise espacial utilizadas em estudos da criminalidade destacam-se: a identificação de padrões espaciais dos crimes; identificação de relações entre criminalidade e características socioeconômicas; e avaliação da eficácia e da efetividade de programas de redução do crime.

Para analisar as relações entre a criminalidade e as variáveis que potencialmente podem influenciá-la, são utilizadas técnicas de autocorrelação e de econometria espacial. A análise de autocorrelação espacial serve para mostrar se o valor de um determinado indicador depende de sua localização nas diferentes unidades espaciais. Em outras palavras, ela mostra se o valor de um determinado indicador segue ou não um padrão espacial aleatório. Quando uma determinada unidade espacial e suas unidades espaciais vizinhas têm comportamentos semelhantes, significa que há autocorrelação espacial positiva e quando elas têm comportamentos diferentes, ela é negativa. Se não há um padrão definido, significa que não há autocorrelação e que, portanto, a distribuição espacial da variável de interesse é aleatória. O principal índice usado para fazer essa mensuração é o I de Moran, que é definido por:

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\left( \sum_{i=1}^n \sum_{j=1}^n w_{ij} \right) \sum_{i=1}^n (x_i - \bar{x})^2} \quad (1)$$

onde:  $I$  é o índice de correlação espacial global (I de Moran);  $n$  é o número de unidades espaciais;  $x_i$  é o valor da variável de interesse na unidade espacial  $i$ ;  $x_j$  é o valor da variável na unidade espacial  $j$ ;  $\bar{x}$  é a média da variável  $x$ ; e  $w_{ij}$  é uma matriz de pesos espaciais que indica a relação de contiguidade entre as unidades espaciais  $i$  e  $j$ . Se  $i$  e  $j$  compartilham fronteira, então  $w_{ij} = 1$ , senão,  $w_{ij} = 0$ .

O I de Moran é um índice de autocorrelação espacial global, ou seja, considerando todo o conjunto das unidades espaciais. No entanto, é possível que haja autocorrelação espacial entre algumas unidades espaciais e não entre outras, configurando a formação de *clusters* espaciais. Para verificar a existência de *clusters* espaciais utiliza-se o indicador Local Indicators of Spatial Association (LISA), o qual é definido por:

$$I_i = (x_i - \bar{x}) \sum_{j=1}^n w_{ij} (x_j - \bar{x}) \quad (2)$$

Para a modelagem econométrica visando estimar o efeito do gasto estadual em educação sobre a criminalidade nos municípios do RS, adota-se a seguinte estratégia: primeiro estima-se um modelo padrão sem dependência espacial, ativando os testes para verificar se a especificação poderia ser melhorada incorporando defasagens espaciais. Estes testes indicam também onde incorporar a defasagem espacial, se na variável endógena (*spatial lag model* - modelo SAR), nos resíduos (*spatial error model* – modelo SEM) ou em ambas (modelo SAC). Para essas três situações, os modelos apresentam, respectivamente, as seguintes especificações:

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

$$y = X \beta + \mu$$

$$\mu = \lambda W \mu + \varepsilon$$

$$y = X \beta + (I - \lambda W)^{-1} \varepsilon \quad (4)$$

$$y = \rho W y + X \beta + (I - \lambda W)^{-1} \varepsilon \quad (5)$$

onde:  $y$  é um vetor de valores da variável dependente;  $X$  é uma matriz de valores das variáveis independentes;  $\varepsilon$  é um vetor de erros da regressão (com média zero, distribuição normal e variância constante);  $\beta$  é um vetor de parâmetros associados às variáveis independentes;  $\rho$  é um coeficiente auto-regressivo que mede a proporção da variação total da variável dependente que é explicada pela autocorrelação espacial dessa variável (pela média dos seus valores nas unidades espaciais vizinhas);  $W$  é uma matriz de pesos espaciais (matriz de vizinhança);  $\lambda$  é um coeficiente auto-regressivo para os erros da regressão que mede a influência dos resíduos das unidades espaciais vizinhas;  $\mu$  é um vetor de erros espacialmente autocorrelacionados;  $I$  é uma matriz identidade.

A econometria espacial começou a ser mais difundida a partir do trabalho de Anselin (1988). Posteriormente, o autor publicou uma série de trabalhos mostrando os avanços do tema. Entre estes, pode-se destacar Anselin e Florax (2000) e Anselin et al (2004). Entre os autores brasileiros, podem ser destacados três trabalhos publicados recentemente, Carvalho e Albuquerque (2010), Almeida (2012) e Golgher (2015).

A criminalidade possui um padrão de concentração espacial e pode influenciar os municípios que estão na vizinhança. Por isso se justifica o uso da econometria espacial, que tem por característica levar em consideração os efeitos de unidades geográficas vizinhas. O indicador de criminalidade utilizado neste trabalho apresentou uma alta autocorrelação espacial positiva, justificando o uso da econometria espacial.

Além do gasto em educação, outros possíveis determinantes da criminalidade apontados pela literatura pertinente serão utilizados no modelo econométrico. O Quadro 1 apresenta a lista de variáveis usadas com as respectivas fontes das informações e os sinais esperados para os coeficientes das mesmas nas regressões.

Quadro 1: Variáveis utilizadas com as respectivas fontes e sinais esperados.

Sigla	Descrição	Fonte	Sinal esperado
totcrpc	Número total de crimes por 1000 habitantes em cada município	Secretaria de Segurança Pública do Rio Grande do Sul	Variável endógena
empp	Porcentagem de pessoas empregadas formalmente (inverso do desemprego)	Ministério do Trabalho e Emprego	Negativo
tvepc	Gastos públicos em educação (escolas) por 1000 habitantes em cada município	Secretaria da Fazenda do Rio Grande do Sul	Negativo
tvspc	Gastos públicos em segurança (policimento) por 1000 habitantes em cada município	Secretaria da Fazenda do Rio Grande do Sul	Negativo
veiregpc	Número total de veículos registrados por 1000 habitantes em cada município ( <i>proxy</i> de renda per cápita)	Fundação de Economia e Estatística do Rio Grande do Sul	Ambíguo
dpop	Densidade populacional do município	Fundação de Economia e Estatística do Rio Grande do Sul	Positivo

Fonte: elaboração própria.

A Tabela 2 apresenta as estatísticas descritivas das variáveis utilizadas no estudo, referentes ao ano de 2015.

Tabela 2: Estatísticas descritivas das variáveis usadas no modelo, 2015.

Variáveis	Média	Mediana	Mínimo	Máximo
totcrpc	15,49	13,65	1,29	77,53
dpop	93,09	23,27	1,48	3.091,92
veiregpc	552,79	553,20	227,96	817,41
empp	26,79	22,51	6,63	97,29
tvepc	323,88	309,74	67,31	927,43
tvspc	6.924,31	5.681,62	0,00	44.621,33

Fonte: elaboração própria.

#### 4. Resultados

O primeiro aspecto a ser considerado é verificar a distribuição entre os municípios das variáveis de interesse. Esta visualização permite verificar se há semelhança ou diferença na distribuição espacial destas variáveis. Neste caso, apresenta-se na Figura 1 os mapas temáticos de dez intervalos iguais dos gastos com educação por 1000 habitantes em 2014 e do total de crimes por 1000 habitantes em 2015 nos municípios do RS. Em linhas gerais, pode-se dizer que os padrões espaciais dessas duas variáveis são distintos. Onde há mais gasto com educação há menos crimes e vice-versa. O mapa apenas constata os padrões de distribuição, mas não permitem afirmar nada sobre relações de causa e efeito. Para isso seria necessário fazer um teste de causalidade.

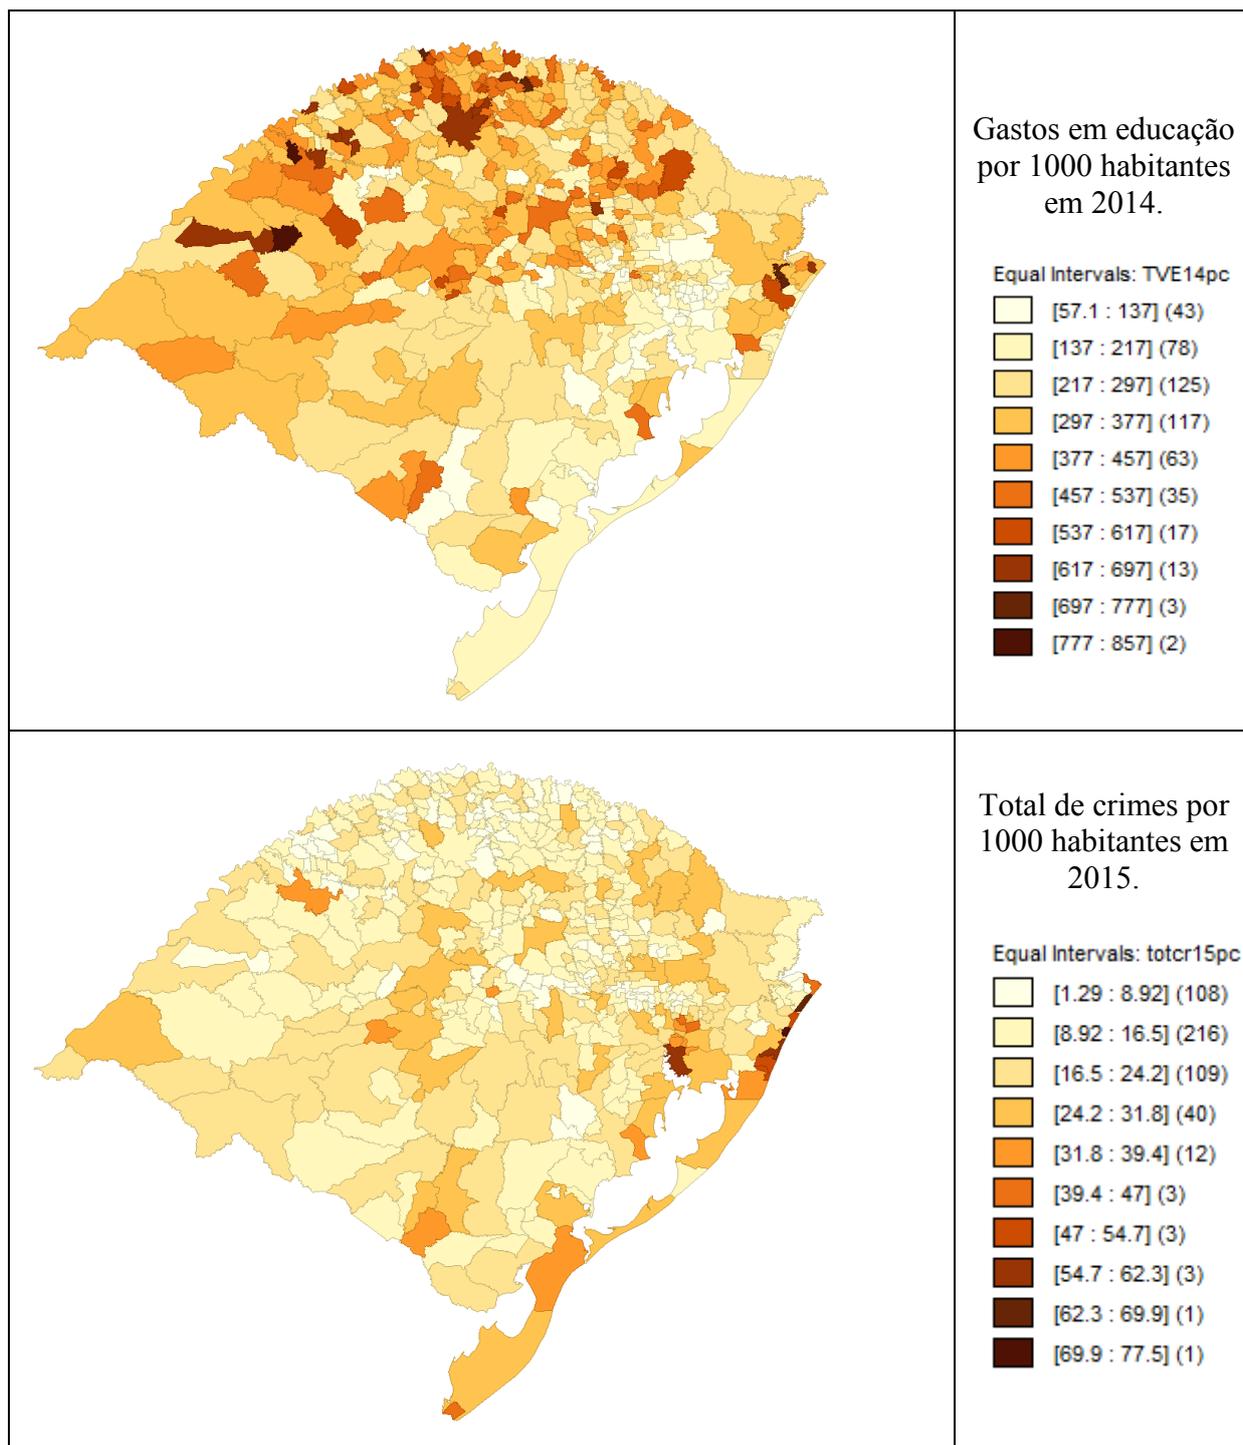


Figura 1: Mapas temáticos de gastos em educação por 1000 habitantes (2014) e de crimes por 1000 habitantes (2015) nos municípios do RS.

Fonte: Elaboração própria

Nota: mapas de dez intervalos iguais.

O segundo aspecto a ser considerado é a presença ou não de dependência espacial global. A matriz de pesos espaciais usada neste trabalho, tanto na análise exploratória quanto nos modelos econométricos, foi Queen de primeira ordem. Entre as opções testadas, esta matriz foi a que originou o maior valor do I de Moran. Além da matriz Queen, foram testadas matrizes de vizinhos mais próximos (3, 4 e 5) e de distância (68 Km e 100 Km). Para maiores detalhes sobre os tipos de matrizes de pesos espaciais, ver Almeida (2012).

Na Figura 2, aparecem dois diagramas mostrando, respectivamente, o I de Moran univariado e multivariado. O primeiro caso (a) mostra a relação entre o indicador de criminalidade nos municípios e o mesmo indicador nos municípios vizinhos (*totcrpc* e  $W\_totcrpc$ ). Pode-se perceber que esse indicador apresenta uma forte autocorrelação espacial positiva (0,3825). No segundo caso, quando se analisa a autocorrelação espacial com o gasto em educação (*tvepc* e  $W\_totcrpc$ ), percebe-se uma relação negativa (-0,1466).

O I de Moran univariado e bivariado da Figura 2 indica que a criminalidade é um fenômeno que apresenta dependência espacial. Este comportamento justifica o uso de econometria espacial, pois ela incorpora a este comportamento através das matrizes de peso espaciais.

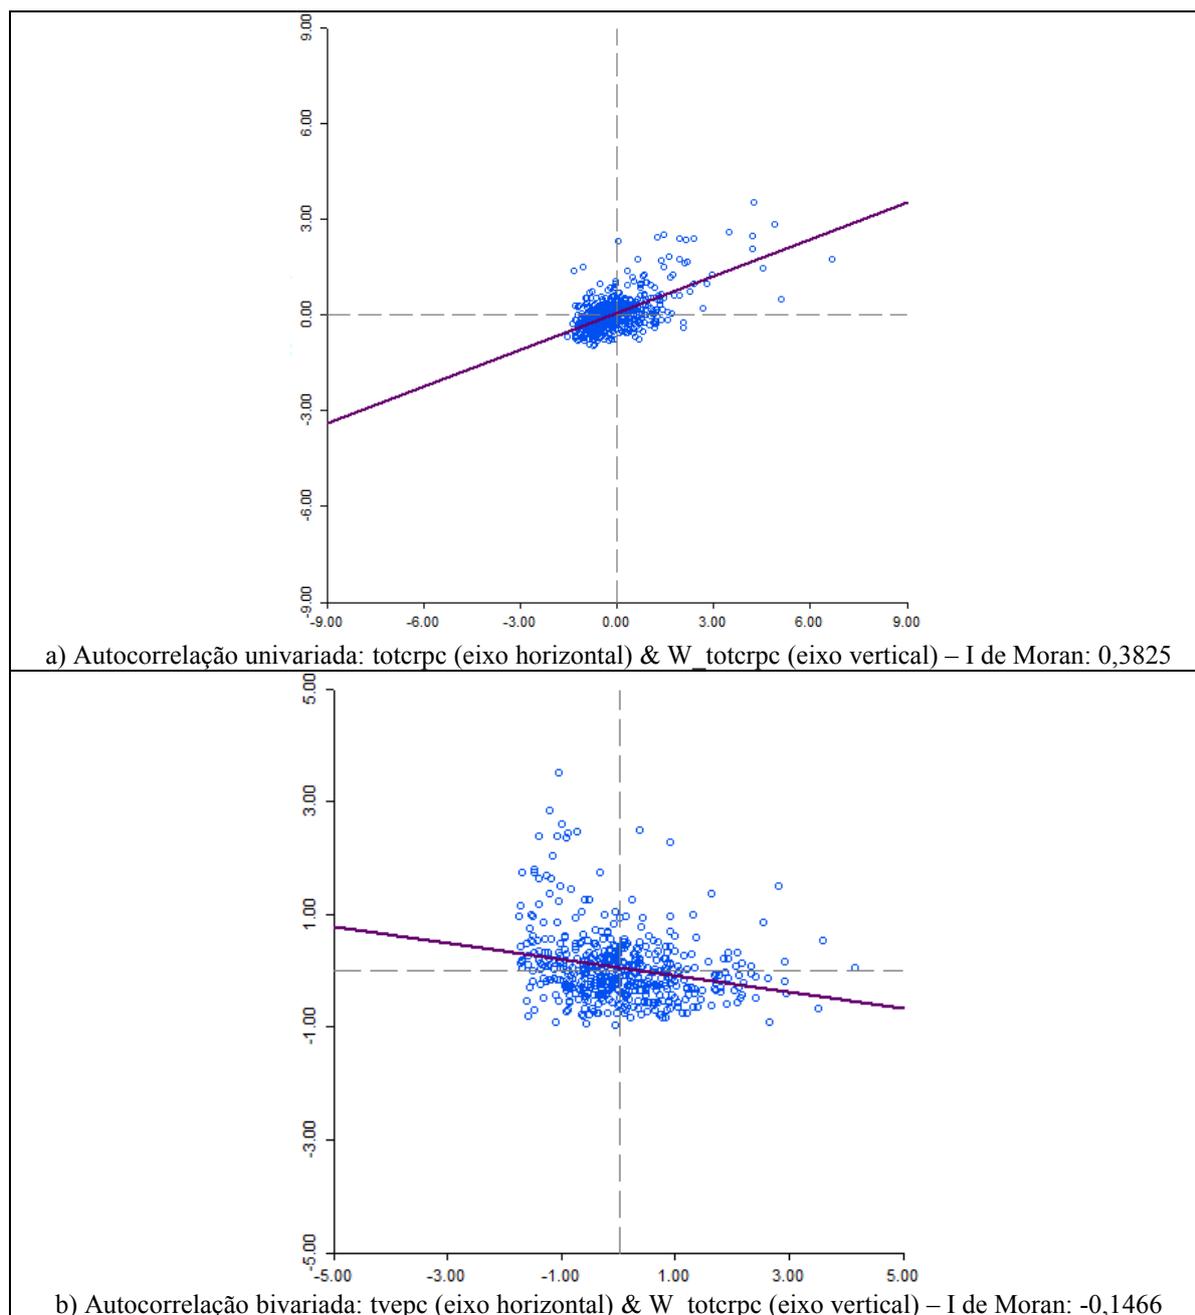


Figura 2: Autocorrelação espacial global dos indicadores de criminalidade (*totcrpc*) e de gasto em educação (*tvepc*) nos municípios do RS, 2015.

Fonte: Elaboração própria.

Nota:  $W\_totcrpc$  corresponde ao comportamento do indicador de criminalidade nos municípios vizinhos.

O I de Moran é um indicador global de autocorrelação e seus resultados podem variar de local para local. Pode haver autocorrelação positiva alta em alguns locais (combinação *high-high*) e baixa em outros (combinação *low-low*), como pode, também, haver autocorrelação negativa (combinações *high-low* ou *low-high*). Para verificar a presença de *clusters* espaciais entre esses indicadores, foi calculado o indicador de autocorrelação espacial local (LISA). A Figura 3 mostra que existem alguns *clusters* do tipo alto-alto (alta criminalidade associada à alta criminalidade nos municípios vizinhos), principalmente nas regiões Metropolitana de Porto Alegre e Litoral Norte. Na Figura 3, é possível verificar, também, que existem alguns *clusters* espaciais do tipo baixo-baixo (baixa criminalidade associada à baixa criminalidade nos municípios vizinhos), localizados ao norte do RS.

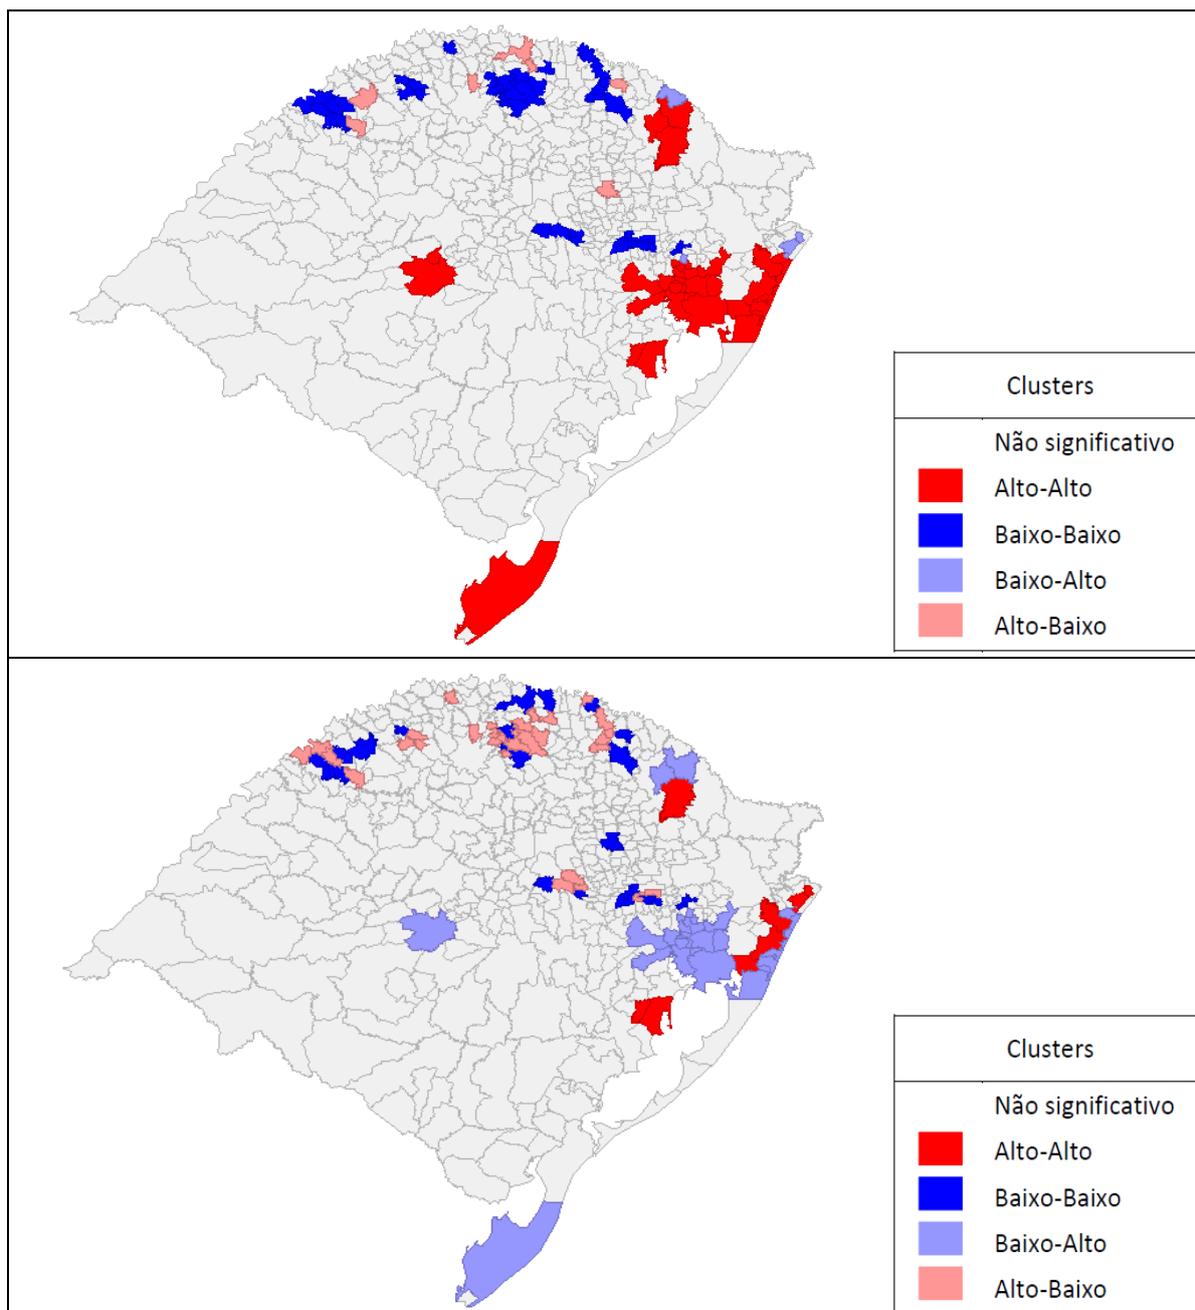


Figura 3: Autocorrelação espacial local dos indicadores de criminalidade (totcrpc) e de gasto em educação (tvepc) nos municípios do RS, 2015.

Fonte: Elaboração própria

O mapa inferior da Figura 3 mostra os *clusters* bivariados entre criminalidade e gasto em educação. É possível verificar que há uma predominância de *clusters* do tipo baixo-alto (baixo gasto em educação per capita associado à alta criminalidade nos municípios vizinhos), principalmente nas regiões Metropolitana de Porto Alegre e Litoral Norte. No Norte do RS aparecem alguns *clusters* espaciais do tipo alto-baixo (alto gasto em educação *per capita* associado à baixa criminalidade nos municípios vizinhos).

Para analisar o efeito do gasto público sobre a criminalidade nos municípios do RS, primeiro foi estimado um modelo padrão com a seguinte especificação:

$$totcrpc_i = \beta_0 + \beta_1 * tvepc_i + \beta_2 * tvspc_i + \beta_3 * dpop_i + \beta_4 * empp_i + \beta_5 * veiregpc_i + \varepsilon_i \quad (8)$$

onde:  $totcrpc_i$  é o indicador de criminalidade do município  $i$ ;  $tvepc_i$  é o indicador de gasto público em educação por mil habitantes no município  $i$  (refrente ao ano anterior);  $tvspc_i$  é o indicador de gasto público em segurança por mil habitantes no município  $i$  (refrente ao ano anterior);  $dpop_i$  é a densidade demográfica do município  $i$ ;  $empp_i$  é a porcentagem de pessoas empregadas em emprego formal no município  $i$ ;  $veiregpc_i$  é o número de veículos registrados por mil habitantes no município  $i$ ;  $\beta_0, \beta_1, \dots, \beta_5$  são os coeficientes estimados associados às variáveis independentes;  $\varepsilon_i$  é um termo de erro da regressão para o município  $i$ . Para  $tvepc_i$  e para  $tvspc_i$  foram usados os valores defasados em um ano para diminuir o problema de endogeneidade e também porque os efeitos destas variáveis sobre a criminalidade podem não ser imediatos. Foram testadas outras defasagens e diferentes combinações de defasagens para as variáveis  $tvepc_i$  e  $tvspc_i$  e os resultados se mantiveram praticamente inalterados, mas com ajuste um pouco melhor com uma e cinco defasagens. Assim, optou-se por considerar uma defasagem por ser a utilizada também por Becker (2012) que é um estudo referência para este (os resultados para as diferentes defasagens estão no Anexo 2). Foi testada também a variável gastos na função educação por município no lugar da variável  $tvepc$ , mas ela se mostrou não significativa e produziu um ajuste pior em relação à esta. As duas juntas não foi possível usar devido ao problema de multicolinearidade. O Quadro 2 mostra os resultados dessa estimação, incluindo um diagnóstico de dependência espacial.

Ao fazer um diagnóstico da regressão, percebe-se que o modelo não possui multicolinearidade (condition number = 17,61), mas, por outro lado, apresenta problemas de não normalidade dos resíduos (teste Jarque-Bera com p-valor = 0,00) e de heterocedasticidade (teste Breusch-Pagan com p-valor = 0,00), resultado comum quando existe dependência espacial nos dados.

No diagnóstico de dependência espacial, existem seis testes. No primeiro deles, tem-se um I de Moran de 0,2704 e altamente significativo, rejeitando, portanto, a hipótese nula de aleatoriedade espacial da criminalidade e indicando a existência de autocorrelação espacial nos resíduos. Os demais testes servem para mostrar qual a melhor opção em termos de inclusão de variáveis defasadas espacialmente. Pode-se ver que os dois testes simples “Lagrange Multiplier (lag)” e “Lagrange Multiplier (error)” são significativos, indicando a presença de dependência espacial. Os testes robustos ajudam a identificar que tipo de dependência espacial pode estar ocorrendo. Nestes, o teste “Robust LM (lag)” é significativo e o “Robust LM (error)” não é significativo. Portanto, o mais indicado é utilizar um modelo que incorpore este tipo de dependência espacial. Trata-se, neste caso, de dependência espacial na variável endógena, ou seja, as taxas de criminalidade nos municípios estão associadas às taxas de criminalidade nos municípios vizinhos. O modelo indicado neste caso é o SAR. Mais detalhes sobre a interpretação dos testes e procedimentos para a escolha do modelo espacial mais apropriado, ver Almeida (2012).

Quadro 2: Resultados da estimação por Mínimos Quadrados Ordinários.

SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION				
Data set	:	Educ_crime		
Dependent Variable	:	totcrpc	Number of Observations	: 496
Mean dependent var	:	15.4983	Number of Variables	: 6
S.D. dependent var	:	9.2937	Degrees of Freedom	: 490
R-squared	:	0.292206	F-statistic	: 40.4583
Adjusted R-squared	:	0.284983	Prob(F-statistic)	: 7.86307e-035
Sum squared residual	:	30322.6	Log likelihood	: -1723.84
Sigma-square	:	61.8828	Akaike info criterion	: 3459.67
S.E. of regression	:	7.86656	Schwarz criterion	: 3484.91
Sigma-square ML	:	61.1342		
S.E of regression ML	:	7.81884		
-----				
Variable	Coefficient	Std.Error	t-Statistic	Probability
CONSTANT	21.7805	2.28313	9.53975	0.00000
dpop	0.00796186	0.00109751	7.25445	0.00000
emp	0.143031	0.0274453	5.21151	0.00000
veicrep	-0.0196603	0.00367687	-5.34704	0.00000
tvepc(t-1)	-0.0102311	0.00284387	-3.5976	0.00035
tvspc(t-1)	0.000520778	8.77034e-005	5.93795	0.00000
-----				
REGRESSION DIAGNOSTICS				
MULTICOLLINEARITY CONDITION NUMBER		17.611897		
TEST ON NORMALITY OF ERRORS				
TEST	DF	VALUE	PROB	
Jarque-Bera	2	1761.3329	0.00000	
DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS				
TEST	DF	VALUE	PROB	
Breusch-Pagan test	5	115.3167	0.00000	
Koenker-Bassett test	5	22.1316	0.00049	
DIAGNOSTICS FOR SPATIAL DEPENDENCE				
FOR WEIGHT MATRIX : Educ_crime_q1				
(row-standardized weights)				
TEST	MI/DF	VALUE	PROB	
Moran's I (error)	0.2704	10.0794	0.00000	
Lagrange Multiplier (lag)	1	100.4150	0.00000	
Robust LM (lag)	1	8.2929	0.00398	
Lagrange Multiplier (error)	1	94.7752	0.00000	
Robust LM (error)	1	2.6531	0.10335	
Lagrange Multiplier (SARMA)	2	103.0681	0.00000	

Fonte: Elaboração própria. Modelo estimado com o software Geoda 1.10.

Ao utilizar o modelo SAR espacial, a qualidade do ajuste do modelo melhorou: o  $R^2$  aumentou e AIC diminuiu (ver o Anexo 1). No entanto, continuou ocorrendo o problema de heteroscedasticidade. Com isso, foi necessário usar uma versão que permitisse a correção do problema, o que foi feito através de uma estimação pelo método de mínimos quadrados ponderados espacialmente em dois estágios. O Quadro 3 apresenta os resultados.

Quadro 3: Resultados da estimação por Mínimos Quadrados Ponderados Espacialmente em dois estágios (Heterocedástico).

SUMMARY OF OUTPUT: SPATIALLY WEIGHTED TWO STAGE LEAST SQUARES (HET)				
-----				
Data set	:Educ_crime.dbf			
Weights matrix	:File: Educ_crime_ql.gal			
Dependent Variable	: totcrpc	Number of Observations:	496	
Mean dependent var	: 15.4983	Number of Variables	: 7	
S.D. dependent var	: 9.3031	Degrees of Freedom	: 489	
Pseudo R-squared	: 0.4538			
Spatial Pseudo R-squared:	0.2883			
N. of iterations	: 1	Steplc computed	: No	
-----				
Variable	Coefficient	Std.Error	z-Statistic	Probability
-----				
CONSTANT	8.1155741	4.4337629	1.8304033	0.0671897
dpop	0.0044847	0.0013920	3.2217464	0.0012741
empp	0.1301641	0.0257193	5.0609550	0.0000004
veicrepc	-0.0117018	0.0043947	-2.6627300	0.0077510
tvepc(t-1)	-0.0053352	0.0026530	-2.0109540	0.0443303
tvspc(t-1)	0.0004167	0.0000878	4.7442410	0.0000021
W_totcrpc	0.5657623	0.1617082	3.4986618	0.0004676
lambda	-0.0621565	0.2382158	-0.2609252	0.7941502
-----				
Instrumented: W_totcrpc				
Instruments: W_dpop, W_empp, W_tvspc(t-1), W_tvepc(t-1), W_veicrepc				

Fonte: Elaboração própria. Modelo estimado com o software SpaceGeoda.

Considerando que se trata de uma análise de dados em *cross-section*, os resultados mostram que o modelo tem uma boa capacidade explicativa da criminalidade (Pseudo R<sup>2</sup> de 0,4538). Os coeficientes das variáveis independentes são todos significativos, com exceção do *lambda* (coeficiente de dependência espacial nos resíduos). Os sinais dos coeficientes, em sua maioria, confirmaram as hipóteses levantadas no Quadro 1. Apresentaram sinais contrários aos esperados *a porcentagem de empregados na população (empp)* e os *gastos com segurança defasados em um período (tvspc)*.

A variável de interesse apresentou o sinal esperado. Com isso, pode-se afirmar que os gastos em educação nos municípios (gastos com recursos humanos) no período anterior tendem a ocasionar uma queda na criminalidade nos municípios no período corrente. Em termos mais precisos, o aumento de uma unidade nos gastos em educação por mil habitantes nos municípios no período anterior (2014) ocasionaram uma redução de 0,0053 crimes por mil habitantes nos municípios no período corrente (2015).

A partir desses resultados, pode-se calcular o aumento dos gastos em educação por mil habitantes nos municípios, necessário para reduzir em uma unidade o número de crimes por mil habitantes. Este valor é de R\$ 188,68/mil habitantes/ano ( $1/0,0053=188,68$ ), ou seja, um aumento de R\$188,68 na educação por mil habitantes correspondem à redução de um crime por mil habitantes. Assim, considerando os valores médios da Tabela 2, se o gasto médio em educação por mil habitantes nos municípios aumentasse de R\$ 323,88 para R\$ 512,56, o número de crimes por mil habitantes nos municípios no ano seguinte passaria de 15,49 para 14,49. Em termos absolutos, para o estado como um todo, isso significaria um aumento de R\$2.121.711,00 nos gastos públicos anuais em educação para uma diminuição anual de 11.245 crimes.

Seria interessante um mapa dos municípios onde o gasto e a criminalidade se mostraram maiores, separadas por cores...

## 5. Comentários finais

O objetivo deste estudo foi verificar se os gastos públicos em educação nos municípios influenciam as taxas municipais de criminalidade. Dado que, em geral, os crimes não acontecem de forma aleatória no espaço geográfico, foi utilizada a metodologia de análise exploratória de dados espaciais e de econometria espacial.

Na análise exploratória de dados espaciais foi possível verificar que a criminalidade apresenta uma forte autocorrelação espacial positiva. Isto significa dizer que os locais de alta criminalidade são cercados de municípios também com alta criminalidade. Também, pode-se afirmar que os locais de baixa criminalidade são rodeados de municípios também com baixa criminalidade. Analisando a relação espacial entre gastos em educação e criminalidade, verificou-se uma associação negativa, ou seja, os locais de baixo gasto em educação são cercados de municípios com alta criminalidade. Raciocínio inverso pode ser feito para os locais com alto gasto em educação.

Ainda na análise exploratória, foi calculada a correlação espacial local (LISA). Foram encontrados *clusters* do tipo alto-alto (alta criminalidade associada à alta criminalidade nos municípios vizinhos), principalmente nas regiões Metropolitana de Porto Alegre e Litoral Norte. Por outro lado, foram encontrados alguns *clusters* espaciais do tipo baixo-baixo (baixa criminalidade associada à baixa criminalidade nos municípios vizinhos), localizados ao norte do estado. Foi calculada também a correlação espacial local bivariada entre gastos em educação e criminalidade. Verificou-se uma predominância de *clusters* do tipo baixo-alto (baixo gasto em educação per capita associado à alta criminalidade nos municípios vizinhos), principalmente nas regiões Metropolitana de Porto Alegre e Litoral Norte. No Norte do RS aparecem alguns *clusters* espaciais do tipo alto-baixo (alto gasto em educação per capita associado à baixa criminalidade nos municípios vizinhos).

Por fim, os resultados do modelo econométrico espacial indicaram que aumentos de gastos em educação nos municípios (gastos com recursos humanos) no período anterior tendem a ocasionar uma queda na criminalidade nos municípios no período corrente. Com os resultados obtidos foi possível calcular que seria necessário aumentar em R\$188,68 os gastos em educação por mil habitantes nos municípios para reduzir um crime por mil habitantes. Considerando o Estado como um todo, foi possível calcular que o valor referido acima significaria um aumento de R\$2.121.711,00 nos gastos públicos anuais em educação para uma diminuição anual de 11.245 crimes.

## Bibliografia

- ALMEIDA, E. **Econometria Espacial Aplicada**. Alínea, 2012.
- ALMEIDA E. S.; HADDAD, E. A; HEWINGS, G. J. D. The spatial pattern of crime in Minas Gerais: An exploratory analysis. **Economia Aplicada**, 9, p. 39-55, 2005.
- ANSELIN, L. **Spatial econometrics: methods and models**. Kluwer Academic, 1988.
- ANSELIN, L. Local Indicators of Spatial Association-LISA. **Geographical Analysis**, 27(2), 93-115, 1995.
- ANSELIN, L.; FLORAX, R. **Advances in spatial econometrics**. Springer-Verlag, 2000.

- ANSELIN, L.; FLORAX, R.; REY, S. J. **Advances in spatial econometrics – Methodology, Tools and Applications**. Springer: Advances in Spatial Science, 2004.
- ARAÚJO Jr, A. F.; FAJNZYLBER, P. Crime e Economia: Um Estudo das Microrregiões Mineiras. **Revista Econômica do Nordeste**, v.31, n. Especial, p.630-659, 2000.
- BEATO, C. C. Determinantes da criminalidade em Minas Gerais. **Revista Brasileira de Ciências Sociais**, São Paulo: ANPOCS, v.13, n.37, Jun. 1998.
- BECKER, K. L. **Uma análise econômica da relação entre a educação e a violência**. Esalq/USP: Tese de doutorado, 2012.
- CARRETS, F. D.; OLIVEIRA, J.; MENEZES, G. R. *A criminalidade no Rio Grande do Sul: uma análise espacial para os anos de 2005, 2010 e 2015*. In: **Anais: 8º Encontro de Economia Gaúcha**, Porto Alegre/RS, 2016.
- CARVALHO, A. X. Y. e ALBUQUERQUE, P. H. M **Tópicos em econometria espacial para dados cross-section**, Brasília/IPEA: TD 1508, 2010.
- CASE, A. C. e KATZ, L. F. **The Company You Keep: The Effects of Family and Neighborhood on Disadvantaged Youths**, NBER Working Papers, 3705, 1991.
- CERQUEIRA et al. **Atlas da Violência 2017**, Ipea/FBSP, 2017.
- CHAINEDY, S. e RATCLIFFE, J. **GIS and Crime Mapping**. Wiley, 2005.
- CHAINEDY, S.; TOMPSON; L e UHLIG, S. The Utility of Hotspot Mapping for Predicting Spatial Patterns of Crime. **Security Journal**, n. 21, 2008.
- CUNHA, F.; HECKMAN, J.; LOCHNER, L. ;MASTEROV, D. **Interpreting the Evidence on Life Cycle Skill Formation**. Cambridge: National Bureau of Economic Research, 2005. 164 p. (NBER Working Paper Series, 11331).
- ECK, J. E.; CHAINEDY, S.; CAMERON, J. G.; LEITNER, M. e WILSON, R. E. **Mapping crime: understanding hot spots**. U.S. Department of Justice, 2005.
- FAJNZYLBER, P.; ARAÚJO JR, A. Violência e criminalidade. In: LISBOA, M. B. MENEZES FILHO, N. A. (Ed.) **Microeconomia e Sociedade no Brasil**, Rio de Janeiro: Contracapa Editora, 2001.
- FARIAS, C. A.; FIGUEIREDO, A. M.; LIMA, J. E. Dependência Espacial e Análise de Agrupamento de Municípios para Diferentes Tipos de Crime em Minas Gerais. **Reuna**, v.13, n.3, p.67-83, 2008.
- FARRINGTON, D. P. Predicting Individual Crime Rates. **Crime and Justice**, Chicago: The University of Chicago Press, v. 9, p. 53-101, 1987.
- FREITAS, T. A.; CADAVAL, A. F.; GONÇALVES, G. A. A estimação de um índice geral de criminalidade para os municípios do Rio Grande do Sul – IGcrime RS. In: **Anais do XIII Encontro Nacional da Associação Brasileira de Estudos Regionais e Urbanos**, Curitiba/PR, 2015.
- GOLGHER, A. B. **Introdução À Econometria Espacial**, Paco Editorial, 2015.
- KLEINSCHMITT, S. C.; WADI, Y. M.; STADUTO, J. A. Evolução espaço-temporal dos homicídios no Estado do Paraná. **REBESP**, n.3, v.4, p.16 - 27, 2010.
- KLEINSCHMITT, S. C.; WADI, Y. M.; STADUTO, J. A. Análise espacial dos homicídios no Estado do Paraná. **Revista REDES**, v.17, n.3, p.257-290, 2012.
- KUME, L. Uma Estimativa dos Determinantes da Taxa de Criminalidade Brasileira: Uma

Aplicação em Painel Dinâmico. In: **Anais** do Encontro Nacional de Economia, João Pessoa/PB, 2004.

LAVIGNE, N.G.; GROFF, E.R. The evolution of crime mapping in the United States. In: HIRSCHFELD, A.; BOWERS, K. (eds). **Mapping and Analysing Crime Data**, p. 203-221. London: Taylor & Francis, 2001.

LEIPNIK, M.R.; ALBERT, D.P. **GIS in Law Enforcement: Implementation Issues and Case Studies**. London: Taylor & Francis, 2003.

OLIVEIRA, C. A. Análise espacial da criminalidade no Rio Grande do Sul. **Revista de Economia**, v.34, n.3, p.35-60, 2008.

RESENDE, J. P. **Crime social, castigo social: O efeito da desigualdade de renda sobre as taxas de criminalidade nos grandes municípios brasileiros**. 2007. 83 p. (Dissertação de Mestrado) - CEDEPLAR, Universidade Federal de Minas Gerais, 2007,

SANTOS, M. J. Dinâmica temporal da criminalidade: mais evidências sobre o efeito inércia nas taxas de crimes letais nos estados brasileiros. **Revista Economia/ANPEC**, Brasília, v.10, n.1, p. 170-194, 2009.

SCORZAFAVE, L. G.; SOARES, M. K. Income inequality and pecuniary crimes. **Economics Letters**, v.104, p. 40-42, 2009.

SOARES, S. S. D. **Educação, um escudo contra o homicídio?** Brasília, IPEA, 2007

TAUCHEN, H.; WITTE, A. D.; GRIESINGER, H. Criminal deterrence: revisiting the issue with a birth cohort. **The Review of Economics and Statistics**, v. 76, n.3, p. 399-412, 1994.

TEIXEIRA, E. C. **Dois ensaios a cerca da relação entre criminalidade e educação**. 2011. 102p. Tese (Doutorado na área de Economia Aplicada) – ESALQ/Universidade de São Paulo, 2011.

WASELFISZ, J. J. (coord). **Juventude, Violência e Cidadania: os jovens de Brasília**. UNESCO, 1998.

WEISBURD, D.; McEWEN, T. Introduction: Crime mapping and crime prevention. In: WEISBURD, D.; McEWEN, T. (eds). **Crime Mapping and Crime Prevention**, p. 8, 1-23. New York: Criminal Justice Press, 1997.

## Anexo 1: Resultados do modelo SAR

SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION				
Data set	:	Educ_crime		
Spatial Weight	:	Educ_crime_q1		
Dependent Variable	:	totcr15pc	Number of Observations:	496
Mean dependent var	:	15.4983	Number of Variables	7
S.D. dependent var	:	9.2937	Degrees of Freedom	489
Lag coeff. (Rho)	:	0.528107		
R-squared	:	0.445524	Log likelihood	-1678.14
Sq. Correlation	:	-	Akaike info criterion	3370.28
Sigma-square	:	47.8917	Schwarz criterion	3399.73
S.E of regression	:	6.92038		
-----				
Variable	Coefficient	Std.Error	z-value	Probability
W_totcr15pc	0.528107	0.046171	11.4381	0.00000
CONSTANT	8.81773	2.19943	4.0091	0.00006
DPOP15	0.00476574	0.00101875	4.67803	0.00000
Emp15p	0.134165	0.0244202	5.494	0.00000
veicrel15pc	-0.0119489	0.00326226	-3.66278	0.00025
TVE14pc	-0.0056923	0.00253421	-2.24618	0.02469
TV14pc	0.000415258	7.73254e-005	5.37027	0.00000
-----				
REGRESSION DIAGNOSTICS				
DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS				
TEST		DF	VALUE	PROB
Breusch-Pagan test		5	84.2159	0.00000
DIAGNOSTICS FOR SPATIAL DEPENDENCE				
SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : Educ_crime_q1				
TEST		DF	VALUE	PROB
Likelihood Ratio Test		1	91.3903	0.00000

Fonte: resultados da pesquisa.

## Anexo 2: Resultados com diferentes defasagens

a) Duas defasagens				
SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION				
Data set	: Educ_crime			
Dependent Variable	: totcrpc	Number of Observations:	: 496	
Mean dependent var	: 15.4983	Number of Variables	: 6	
S.D. dependent var	: 9.2937	Degrees of Freedom	: 490	
R-squared	: 0.291499	F-statistic	: 40.3202	
Adjusted R-squared	: 0.284269	Prob(F-statistic)	: 1.00058e-034	
Sum squared residual	: 30352.8	Log likelihood	: -1724.08	
Sigma-square	: 61.9446	Akaike info criterion	: 3460.17	
S.E. of regression	: 7.87049	Schwarz criterion	: 3485.41	
Sigma-square ML	: 61.1953			
S.E of regression ML	: 7.82274			
-----				
Variable	Coefficient	Std.Error	t-Statistic	Probability
-----				
CONSTANT	21.6967	2.27609	9.53247	0.00000
dpop	0.00785456	0.00109433	7.1775	0.00000
empp	0.137898	0.0274305	5.0272	0.00000
veicrpsc	-0.0189362	0.00367448	-5.15345	0.00000
tvsv(t-2)	0.000611631	0.000103532	5.90764	0.00000
tve(t-2)	-0.0111554	0.00324203	-3.44086	0.00063
-----				
b) Três defasagens				
SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION				
Data set	: Educ_crime			
Dependent Variable	: totcrpc	Number of Observations:	: 496	
Mean dependent var	: 15.4983	Number of Variables	: 6	
S.D. dependent var	: 9.2937	Degrees of Freedom	: 490	
R-squared	: 0.285682	F-statistic	: 39.1938	
Adjusted R-squared	: 0.278393	Prob(F-statistic)	: 7.19921e-034	
Sum squared residual	: 30602	Log likelihood	: -1726.11	
Sigma-square	: 62.4531	Akaike info criterion	: 3464.22	
S.E. of regression	: 7.90273	Schwarz criterion	: 3489.46	
Sigma-square ML	: 61.6977			
S.E of regression ML	: 7.85479			
-----				
Variable	Coefficient	Std.Error	t-Statistic	Probability
-----				
CONSTANT	21.8952	2.28001	9.60313	0.00000
dpop	0.0079343	0.00109797	7.22634	0.00000
empp	0.137106	0.0275837	4.97052	0.00000
veicrpsc	-0.0189503	0.00368839	-5.13781	0.00000
tve(t-3)	-0.0118378	0.0036176	-3.27227	0.00114
tvsv(t-3)	0.000652764	0.000117706	5.54571	0.00000
-----				

(Continua)

## c) Quatro defasagens

## SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION

Data set : Educ\_crime  
 Dependent Variable : totcrpc Number of Observations: 496  
 Mean dependent var : 15.4983 Number of Variables : 6  
 S.D. dependent var : 9.2937 Degrees of Freedom : 490

R-squared : 0.286132 F-statistic : 39.2804  
 Adjusted R-squared : 0.278848 Prob(F-statistic) : 6.18296e-034  
 Sum squared residual: 30582.7 Log likelihood : -1725.95  
 Sigma-square : 62.4138 Akaike info criterion : 3463.91  
 S.E. of regression : 7.90024 Schwarz criterion : 3489.15  
 Sigma-square ML : 61.6588  
 S.E of regression ML: 7.85231

Variable	Coefficient	Std.Error	t-Statistic	Probability
CONSTANT	21.7291	2.27272	9.56085	0.00000
dpop	0.00796945	0.00109745	7.26177	0.00000
empp	0.136257	0.0275951	4.93775	0.00000
veicrepc	-0.0189596	0.00368599	-5.14369	0.00000
tvspc(t-4)	0.000773947	0.000136493	5.67024	0.00000
tvepc(t-4)	-0.0117056	0.00383767	-3.05018	0.00241

## c) Cinco defasagens

## SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION

Data set : Educ\_crime  
 Dependent Variable : totcrpc Number of Observations: 496  
 Mean dependent var : 15.4983 Number of Variables : 6  
 S.D. dependent var : 9.2937 Degrees of Freedom : 490

R-squared : 0.297759 F-statistic : 41.5533  
 Adjusted R-squared : 0.290593 Prob(F-statistic) : 1.17364e-035  
 Sum squared residual: 30084.6 Log likelihood : -1721.88  
 Sigma-square : 61.3972 Akaike info criterion : 3455.76  
 S.E. of regression : 7.83564 Schwarz criterion : 3481  
 Sigma-square ML : 60.6545  
 S.E of regression ML: 7.7881

Variable	Coefficient	Std.Error	t-Statistic	Probability
CONSTANT	21.2872	2.22425	9.57049	0.00000
dpop	0.00782658	0.00108849	7.1903	0.00000
empp	0.132233	0.0274837	4.81134	0.00000
veicrepc	-0.018435	0.00365435	-5.04466	0.00000
tvepc(t-5)	-0.0123669	0.00393819	-3.14025	0.00179
tvspc(t-5)	0.000951409	0.000149585	6.36034	0.00000

Fonte: resultados da pesquisa.

## Anexo 3 - Taxa de homicídios por Unidade da Federação - Brasil, 2005 a 2015

	Taxa de Homicídios por 100 mil Habitantes											Variação %		
	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2005 a 2015	2014 a 2015	2010 a 2015
<b>Brasil</b>	<b>26,1</b>	<b>26,6</b>	<b>25,5</b>	<b>26,7</b>	<b>27,2</b>	<b>27,8</b>	<b>27,4</b>	<b>29,4</b>	<b>28,6</b>	<b>29,8</b>	<b>28,9</b>	<b>10,6%</b>	<b>-3,1%</b>	<b>4,0%</b>
Acre	18,5	23,0	19,5	19,6	22,1	22,5	22,0	27,4	30,1	29,4	27,0	45,9%	-8,0%	20,1%
Alagoas	39,9	53,1	59,5	60,3	59,3	66,9	71,4	64,6	65,1	62,8	52,3	31,2%	-16,6%	-21,8%
Amapá	33,0	32,8	27,0	34,2	30,3	38,8	30,5	36,2	30,6	34,1	38,2	15,9%	12,1%	-1,6%
Amazonas	18,5	21,1	21,1	24,8	27,0	31,1	36,5	37,4	31,3	32,0	37,4	101,7%	16,8%	20,3%
Bahia	20,9	23,7	26,0	33,2	37,1	41,7	39,4	43,4	37,8	40,0	39,5	89,6%	-1,2%	-5,2%
Ceará	21,0	21,8	23,2	23,9	25,3	31,8	32,7	44,6	50,9	52,3	46,7	122,8%	-10,6%	47,0%
Distrito Federal	28,2	27,7	29,2	31,8	33,8	30,6	34,6	36,0	30,0	29,6	25,5	-9,6%	-13,9%	-16,8%
Espírito Santo	47,0	50,9	53,3	56,4	56,9	51,0	47,1	46,6	42,2	41,4	36,9	-21,5%	-10,9%	-27,6%
Goias	26,1	26,3	26,0	30,7	32,1	33,0	37,4	45,4	46,2	44,3	45,3	73,6%	2,4%	37,5%
Maranhão	15,3	15,7	18,0	20,3	22,0	23,1	23,9	26,5	31,8	35,9	35,3	130,5%	-1,7%	52,8%
Mato Grosso	32,4	31,4	30,5	31,7	33,3	32,0	32,8	34,5	36,4	42,1	36,8	13,9%	-12,5%	15,0%
Mato Grosso do Sul	27,9	29,7	30,5	29,9	30,7	26,8	27,2	27,3	24,3	26,7	23,9	-14,2%	-10,5%	-10,7%
Minas Gerais	22,0	21,4	20,9	19,6	18,7	18,6	21,6	23,0	22,9	22,8	21,7	-1,1%	-4,7%	16,7%
Pará	27,6	29,2	30,3	39,1	40,2	46,4	40,0	41,4	42,7	42,7	45,0	62,7%	5,3%	-3,2%
Paraíba	20,7	22,8	23,7	27,5	33,5	38,6	42,6	40,0	39,6	39,3	38,3	84,9%	-2,6%	-0,8%
Paraná	29,0	29,8	29,5	32,5	34,6	34,3	32,1	33,0	26,7	26,9	26,3	-9,3%	-2,2%	-23,4%
Pernambuco	51,5	52,6	53,0	50,9	45,0	39,5	39,2	37,3	33,9	36,2	41,2	-20,0%	13,7%	4,3%
Piauí	12,2	13,8	12,5	11,6	12,2	13,2	14,0	16,6	18,8	22,4	20,3	65,8%	-9,6%	54,0%
Rio de Janeiro	48,2	47,5	41,6	35,7	33,5	35,4	29,7	29,4	31,2	34,7	30,6	-36,4%	-11,9%	-13,6%
Rio Grande do Norte	13,5	14,9	19,1	23,0	25,5	25,6	33,0	34,8	42,9	47,0	44,9	232,0%	-4,5%	75,5%
Rio Grande do Sul	18,6	18,1	19,8	21,9	20,5	19,5	19,4	22,1	20,8	24,3	26,2	40,5%	7,7%	34,2%
Rondônia	36,2	37,4	27,2	32,1	35,8	34,9	28,5	33,1	27,9	33,1	33,9	-6,2%	2,7%	-2,9%
Roraima	24,3	27,5	27,9	25,4	28,0	26,9	20,6	30,7	43,8	31,8	40,1	65,4%	26,3%	49,5%
Santa Catarina	10,8	11,2	10,4	13,3	13,4	13,2	12,8	12,9	11,9	13,5	14,0	30,1%	4,3%	6,5%
São Paulo	21,9	20,4	15,4	15,4	15,8	14,6	14,0	15,7	13,8	14,0	12,2	-44,3%	-13,0%	-16,5%
Sergipe	24,7	29,2	25,7	27,8	32,3	32,7	35,0	41,6	44,0	49,4	58,1	134,7%	17,5%	77,7%
Tocantins	14,6	17,2	16,6	18,5	22,4	23,6	25,8	26,7	23,6	25,5	33,2	128,1%	30,4%	40,5%

Fonte: Cerqueira et al (2017)