



Universidade Federal de Pernambuco
Centro de Ciências Sociais Aplicadas
Departamento de Economia

Pós-Graduação em Economia (PIMES)

**Impactos das políticas de segurança sobre
a difusão da criminalidade entre as
cidades: uma aplicação dos modelos de
Econometria Espacial.**

Inaldo Bezerra da Silva Júnior

Dissertação de Mestrado

Recife
2016

Universidade Federal de Pernambuco
Centro de Ciências Sociais Aplicadas
Departamento de Economia

Inaldo Bezerra da Silva Júnior

Impactos das políticas de segurança sobre a difusão da criminalidade entre as cidades: uma aplicação dos modelos de Econometria Espacial.

Trabalho apresentado ao Programa de Pós-Graduação em Economia (PIMES) do Departamento de Economia da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Mestre em Ciências Econômicas.

Orientadora: *Prof. Dra. Tatiane Almeida de Menezes*

Recife
2016

Catálogo na Fonte
Bibliotecária Ângela de Fátima Correia Simões, CRB4-773

S586i Silva Júnior, Inaldo Bezerra da
Impactos das políticas de segurança sobre a difusão da criminalidade
entre as cidades: uma aplicação dos modelos de Econometria Espacial /
Inaldo Bezerra da Silva Júnior. - 2016.
55 folhas: il. 30 cm.

Orientadora: Prof^ª. Dra. Tatiane Almeida de Menezes.
Dissertação (Mestrado em Economia) – Universidade Federal de
Pernambuco, CCSA, 2016.
Inclui referências e anexos.

1. Homicídios. 2. Espaço em economia. 3. Crime. I. Menezes, Tatiane
Almeida de (Orientadora). II. Título.

331 CDD (22.ed.) UFPE (CSA 2016-075)

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS
DEPARTAMENTO DE ECONOMIA
PIMES/PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE DISSERTAÇÃO DO
MESTRADO EM ECONOMIA DE:

INALDO BEZERRA DA SILVA JUNIOR

A Comissão Examinadora composta pelos professores abaixo, sob a presidência do primeiro, considera o Candidato Inaldo Bezerra da Silva Junior **APROVADO**.

Recife, 29/01/2016

Prof. Dr. Raul da Mota Silveira Neto
Representante da Orientadora

Prof. Dr. Paulo Henrique Pereira de Meneses Vaz
Examinador Interno

Prof. Dr. Diego Firmino Costa da Silva
Examinador Externo - UFRPE

Aos meus pais e Carol.

Agradecimentos

Agradeço a Deus, pois Ele é a mola propulsora de minhas ações. Agradeço o apoio da minha família, principalmente a minha mãe, por seu amor incondicional, que sempre mostrou a importância dos estudos e nunca desistiu da árdua tarefa de me proporcionar educação formal.

Sou grato a professora Tatiane, sem a qual não se viabilizaria este trabalho. Muito obrigado Tati por ter salvado meu mestrado, serei eternamente grato por sua ajuda.

Agradeço aos meus amigos Igor, Stênio, Davison e Thiago por serem companheiros de longa data e, por estarem sempre prontos a estenderem a mão auxiliadora.

Agradeço a todos os companheiros da UFPE que ao longo desses dois anos foram sempre generosos comigo. Agraço aos companheiros da 222, principalmente a Dr. Paulo (castiga) pela amizade e companheirismo durante essa trajetória. Agradeço imensamente a Felipex e Dieison que não permitiram que eu desistisse, sem o apoio deles eu teria abandonado. Agradeço a Pedrão por ser um cara inspirador com quem tive o prazer de aprender muito sobre economia e principalmente sobre a vida. Registro ainda uma menção super honrosa ao meu grande amigo Guilherme (Mago), esse cara é um grande ser humano, sempre bom conversar com ele e foi através dessas conversas que descobrimos que estávamos no lugar errado (kkkkkkkkk, esse mestrado foi tenso). Agradeço ainda ao meu "*Amigo de Econometria* Bruno Nunes... kkkkk, valeu garoto!!!! Agradeço aos professores do Departamento de Economia e a todos os profissionais que o constitui, principalmente a Jackeline (valeu Jack, desculpa os aperreios, kkkkk).

Agradeço a todos os colegas de curso que passei a conviver desde 2009, especialmente aos amigos Augusto, Jairo e Luiza. Agradeço a Profa. Maria Fernanda, ressalto seu apoio desde o quinto período, onde tive a felicidade de tê-la como minha professora.

Por fim, mas não menos importante, agradeço a Carol que foi uma grande incentivadora para a conclusão deste trabalho.

Enfim, agradeço por todas as situações desta vida.

Agradeço ao CNPq pelo financiamento.

Resumo

A Economia do Crime afirma que, além das variáveis demográficas e socioeconômicas, o espaço é fator fundamental para o estudo da criminalidade. Devido a falta de evidências empíricas sobre a relação entre espaço e crime para as cidades brasileiras, este estudo busca identificar autocorrelação espacial para o crescimento da taxa de homicídios, no período de 2000 a 2010, nas cidades brasileiras, mais especificamente para áreas mínimas comparáveis. Para isso, foram aplicados testes de diagnósticos de dependência espacial, através de técnicas de econometria espacial. O estudo comprovou seu principal objetivo, ou seja, o espaço é importante para o estudo da criminalidade nas cidades brasileiras, detectando o efeito *spillover* espacial, além de detectar clusters com elevadas taxas de homicídios nas regiões Norte e Nordeste, e clusters com comportamento oposto nas regiões Sul e Sudeste. O modelo, controlado por variáveis demográficas e socioeconômicas, que apresentou o melhor ajuste foi o *Spatial Durbin Model (SDM)*.

Palavras-chave: Taxa de Homicídios; Espaço; *spillover*.

Abstract

The Crime Economy asserts that beyond demographic and socioeconomic variables, space is fundamental to the study of crime. Due to the lack of empirical evidence on the relationship between space and crime in Brazilian cities, this study aims to identify spatial autocorrelation for the growth of the homicide rate, from 2000 to 2010, in Brazilian cities, specifically to comparable minimum areas. Spatial dependence diagnostic tests were applied through spatial econometric techniques. The study confirmed its main objective, i.e. that space is important to the study of crime in Brazilian cities by detecting the spatial *spillover* effects as well detect clusters with high homicide rates in the North and Northeast regions, and clusters with opposite behavior in the South and Southeast. The model, controlled for demographic and socioeconomic variables, presented that the best fit was the *Spatial Durbin Model (SDM)*.

Keywords: Homicide Rate; Space; *spillover*.

Lista de Tabelas

4.1	Definição das variáveis e estatísticas descritiva	19
4.2	I - Moran Global	20
5.1	Mínimos Quadrados Ordinários.	28
5.2	Efeito diretos e indiretos.	30
B.1	Resultados das Regressões	45

Lista de Figuras

1.1	Taxa de homicídio média das cidades brasileiras entre 1988 e 2010	3
3.1	Estratégia para escolha do modelo	13
4.1	Mapa de <i>clusters</i> do crescimento da Taxa de homicídios 2000-2010	21
4.2	Kernel 1 - Taxas de homicídios das cidades brasileiras no ano 2000.	23
4.3	Kernel 2 - Crescimento das Taxas de Homicídios das cidades brasileiras entre 2000 e 2010.	24

Sumário

1	Introdução	1
2	Revisão da Literatura	5
3	Estratégia Empírica	9
3.1	Estratégia Espacial e Estimação	10
3.2	Efeitos diretos e indiretos	13
4	Descrição dos dados	17
4.1	Análise Exploratória dos Dados Espaciais	17
4.2	Análise espacial dos dados	19
5	Resultados	26
6	Considerações Finais	34
	Referências	36
A	Anexo I	41
A.1	Matrizes de pesos espaciais	41
B	Anexo II	44

CAPÍTULO 1

Introdução

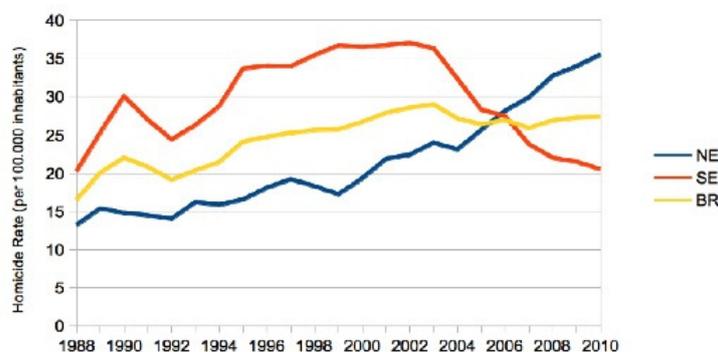
A criminalidade é um fenômeno mundial não recente e há muito tem sido objeto de interesse de pesquisadores das ciências sociais, tanto por se tratar de um problema contemporâneo de proporção mundial, quanto por ter se mostrado, através do fracasso de algumas políticas públicas, um fenômeno de enorme complexidade (Silva et al. 2012). As estatísticas criminais brasileiras são pouco animadoras e, embora sejam positivas em determinados locais, estão longe de se mostrarem satisfatórias no que tange à completude do território, no entanto, os esforços para compreender tal problema devem ser incessantes (Waiselfisz 2011).

No Brasil, a crescente e permanente criminalidade tem desafiado os estudiosos das ciências sociais, tornando-se, principalmente a partir da década de 1980, objeto de pesquisa de muitos teóricos, em uma tentativa de explicar o crescimento da criminalidade, bem como seus efeitos sobre a vida das populações urbanas, buscando compreender os meios destinados à gestão do controle do crime, da punição e seus efeitos, pode-se citar como exemplo o trabalho de Araújo Jr. e Fajnzylber (2001). No âmbito mundial, a criminalidade é há séculos objeto de estudo, inicialmente focado na figura do indivíduo e sua personalidade, posteriormente, sob a influência de sociólogos, compreendendo o crime como um fenômeno social.

A ciência econômica tem se debruçado sobre o tema da criminalidade, revestindo-a com

os seus paradigmas. De acordo com a visão canônica da teoria econômica o agente depara-se com um custo ou benefício no exercício da atividade criminosa, numa tentativa de maximizar a utilidade esperada. O eminente teórico Gary S. Becker (1968) representa um marco na entrada das ciências econômicas no estudo da criminalidade. Utilizando-se de modelagem microeconômica para analisar o comportamento racional do indivíduo que opta pelo ganho ilícito ao ganho lícito. Os trabalhos de Ehrlich (1973), Sah (1991) e Glaeser et al. (1995) são exemplos de estudos que utilizaram-se da modelagem individual para estudar criminalidade.

No contexto brasileiro, a criminalidade tem se mostrado um desafio para os teóricos, a exemplo de seu comportamento descrito na Figura 1. A análise desta identifica uma redução, particularmente nos anos 2000, da violência nos estados do sudeste (SE) vis à vis o aumento na região nordeste (NE). Trabalhos como os de Lamarca e Vetore (2013) sugerem que a elevação da violência no NE ocorre por causas independentes as que explicam a redução no sudeste. Segundo os autores, a ocorrência das políticas públicas efetivas para o combate à violência nesta região seria responsável pela drástica redução das taxas de homicídios. Por outro lado, a maioria dos estados nordestinos não se mostraram efetivos no combate à violência, o que, conseqüentemente, não alterou suas taxas históricas.

Figura 1.1 Taxa de homicídio média das cidades brasileiras entre 1988 e 2010

Com base nas observações empíricas, a hipótese levantada pelo trabalho é de que, ao intensificar o combate ao crime em uma cidade da região metropolitana que apresenta altas taxas de homicídios faz com que haja um deslocamento do crime para as áreas vizinhas. Esta migração se justificaria em função da presença de áreas conurbadas, já que as fronteiras municipais não são claras. Nas cidades em que existem políticas efetivas de combate ao crime, o criminoso, ou a atividade criminosa, acaba se deslocando para áreas em que a presença coercitiva do Estado não se dê tão eficazmente. Esta movimentação traz alterações para as cidades vizinhas, favorecendo a prática de atividades criminosas e, inevitavelmente, aumentando a taxa de homicídios.

De acordo com a hipótese supracitada, entende-se que, para uma política pública ter êxito, não deve apenas focar nas cidades mais violentas, pois isto traria consequências perversas para as regiões circunvizinhas, comportamento observado por Menezes et. al. (2013) ao analisar as taxas de homicídio entre os bairros da cidade do Recife, mas há que se abarcar também a vizinhança, mesmo que esta apresente baixas taxas de criminalidade.

Exposta a importância da migração para a compreensão do fenômeno da criminalidade, o

presente trabalho busca identificar se existe migração do crime entre as cidades brasileiras, bem como, pretende calcular o impacto das características socioeconômicas no comportamento das taxas de crescimento dos homicídios entre estas cidades. Mais especificamente, a unidade de observação serão as *Áreas Mínimas Comparáveis-AMC* . Para tanto, tal estudo inicialmente perpassa por uma revisão da literatura acerca dos temas citados, em seguida discute-se a estratégia empírica, seguindo com a descrição dos dados e apresentação dos resultados, para, enfim, tecermos discussão e as conclusões acerca dos temas.

CAPÍTULO 2

Revisão da Literatura

Este capítulo realiza uma breve revisão de literatura a respeito de trabalhos publicados sobre economia do crime, o qual perpassa tanto pela literatura nacional quanto internacional, identificando diferentes aspectos em diferentes localizações.

Nos últimos anos é possível identificar uma considerável elevação no número de estudos publicados que exploram a distribuição espacial de crimes violentos, tanto no Brasil como no mundo. Na literatura internacional, podem ser citados, por exemplo os trabalhos de Blumstein e Rosenfeld (1998); Cortiça (1999); Baller et al (2001); Messner e Anselin (2004); Cohen e Tita (1999); Morenoff et al. (2001) e Griffiths e Chavez (2004). No Brasil, temos os trabalhos de Ratton *et. al.* (2011), Beato *et. al.* (2013) , Menezes *et. al.* (2013).

Os trabalhos citados têm consistentemente demonstrado dois aspectos. Primeiro, a subpopulação de maior risco de vitimização de homicídio é composta por homens, jovens e negros, que vivem em comunidades urbanas desfavorecidas. Em segundo lugar, homicídios apresentam um padrão não-aleatório de concentração espacial positiva, significando que é possível encontrar áreas com níveis semelhantes de violência, a saber, *cluster*.

A teoria ecológica da criminalidade demonstrou que a padronização espacial dos crimes não pode ser explicada apenas pelas características socioeconômicas do lugar (Sampson e Groves

1989) . Em vez disto, a análise espacial da literatura de crime sugere que as concentrações de crime são o resultado de processos sociais específicos ou mecanismos que são manifestas de tal forma que os crimes em um único local influenciam os níveis e padrões de crimes em lugares próximos ou "conectados".

O valor principal desses estudos é servir como um lembrete constante de que o espaço é importante quando se pretende entender o comportamento da criminalidade. Refutando a noção de que os bairros e mesmos as cidades são analiticamente independentes, sendo assim, é preciso considerar de que forma os resultados observáveis nestas unidades dependem das ações e atividades ocorrendo em seu entorno (Sampson 2004; Morenoff et al. 2001). No entanto, embora muitas explicações plausíveis tenham sido oferecidas, os resultados empíricos revelam pouco em termos de apoiar declarações definitivas sobre a natureza exata dos processos que influenciam a criminalidade através do espaço.

A estratégia de modelagem individual desenvolvida por Becker (1968) e empregada na maioria dos estudos é, em parte, responsável pela ausência de uma maior formalização do mecanismo de difusão do crime no espaço. A maioria dos trabalhos empíricos, entretanto são desenvolvidos com variáveis agregadas nas áreas de interesse da análise: estado, cidades, bairros.

Por hipótese, considera-se que as áreas próximas podem influenciar umas às outras, estima-se um modelo não espacial, e utilizam-se os resíduos para testar a presença de dependência espacial para com base em testes estatísticos sugerir o modelo espacial mais adequado.

Outra modo de considerar a existência de efeitos espaciais, ou seja, *spillover*, é considerar

o fenômeno da migração intermunicipal da criminalidade. A partir de 2004 observa-se um processo de interiorização da violência, sobretudo nas regiões Norte e Nordeste (Menezes e Uchoa, 2014).

Segundo Waiselfisz (2011), tem-se que a partir do final da década de 90 as grandes metrópoles deixam de ser os grandes polos de violência. A taxa de homicídios elevou-se bastante nas capitais que estão fora do eixo das grandes metrópoles e nas cidades do interior do país, principalmente nas regiões Norte e Nordeste.

Apesar de não se ter estudos apontando a migração da atividade criminosa entre as cidades do Rio de Janeiro (RJ) devido a implantação das Unidade de Polícia Pacificadora (UPP), é possível observar com base nos dados do Instituto de Segurança Pública (ISP-RJ)¹ que houve um aumento nos índices de criminalidade das regiões da Baixada Fluminense e nas regiões de Niterói e São Gonçalo. Sendo assim, os indicadores apontam para uma possível relação espacial da criminalidade no estado do Rio de Janeiro.

Trabalhos como o de Cohen e Tita (1999) argumentam que a disseminação da atividade ilícita se propaga através do espaço basicamente de duas maneiras. *i)* Criminosos observam oportunidades em cidades que apresentam baixa criminalidade ou indivíduos de uma dada região copiam o comportamento criminoso de delinquentes de uma região distinta sem que haja, necessariamente, o contato direto entre tais bandidos, basicamente há uma imitação de comportamento; *ii)* Outra forma que o crime pode gerar efeito transbordamento é quando há contato direto entre indivíduos que se deslocam no espaço a fim de disseminar o *modus operandi*

¹<http://www.isp.rj.gov.br/resumoaisp.asp>

de suas quadrilhas.

Dentro da lógica socioeconômica que o crime percorre, tal trabalho confere relevo ao aspecto da econometria espacial na determinação da atividade criminal, buscando compreender como as características do ambiente podem influenciar na criminalidade. Para tanto, utilizaremos de trabalhos como os de Brantingham e Brantingham (1995), atentando para a importância do ambiente e seus elementos na escolha das vítimas e dos locais destinados ao crime.

CAPÍTULO 3

Estratégia Empírica

Este capítulo tem como meta expor as técnicas de econometria espacial e sua relevância para tratar questões em que o espaço é determinante do comportamento individual. Como pôde ser observado no capítulo 2, para estudar a criminalidade, o espaço é, de fato, importante. Além desta breve apresentação, este capítulo ainda conta com mais duas seções onde serão abordados a estratégia para uso de um modelo econométrico espacial e a interpretação dos parâmetros, respectivamente.

Os modelos de regressão linear buscam identificar o impacto de uma determinada variável de interesse sobre o comportamento médio de uma dada variável dependente qualquer, como descrito no modelo (3.1) abaixo:

$$Y = \alpha \iota_N + X\beta + \varepsilon, \quad (3.1)$$

onde Y é um vetor $N \times 1$ que contém as informações da variável dependente, ι_N é um vetor $N \times 1$ de uns associado ao parâmetro α dos coeficientes, X denota uma matriz $N \times K$ das variáveis independentes, β é um vetor $K \times 1$ e $\varepsilon = (\varepsilon_1, \dots, \varepsilon_N)^T$ é o vetor do termo de erro, onde ε_i são independentes e identicamente distribuído (*iid*) para todo i com média zero e variância σ^2 .

A estratégia de estimação dos coeficientes de (3.1) mais comumente empregada é o método de Mínimos Quadrados Ordinários (*MQO*). Para esta estratégia ser implementada com êxito,

faz-se necessário que o modelo esteja bem especificado e que as variáveis independentes sejam exógenas, ou seja, não estejam correlacionadas com os erros da regressão (Wooldridge, 2003).

Neste sentido, a existência de correlação espacial implica que a trajetória dos vizinhos é importante para compreender o comportamento da variável que se deseja explicar. Uma vez que não há na regressão nenhum termo que capte este efeito, o mesmo vai para o resíduo e, por conseguinte, as variáveis independentes ficam endógenas e os erros não aleatórios no espaço, tornando os estimadores de *MQO* viesados (Anselin e Bera (1988), Lesage (2009)).

3.1 Estratégia Espacial e Estimação

Seguindo o raciocínio descrito na introdução deste capítulo, uma alternativa para efetuar uma estimação consistente seria inserir no modelo as informações das áreas vizinhas que possam estar influenciando a variável dependente. Entretanto, neste caso surgiria uma super parametrização, pois ao admitir-se uma relação de dependência entre um conjunto de n observações e localidades, surgem $n^2 - n$ relações, o que inviabiliza o processo de estimação.

Seguindo Ord (1975) e Whittle (1956) a solução para esta super parametrização consiste em impor uma estrutura de dependência espacial (matriz espacial). Esta estrutura, quando imposta, gera um processo conhecido como processo de autocorrelação espacial (*spatial autoregressive process*).

Uma abordagem alternativa a estimação do *MQO* é começar com um modelo mais geral que inclua a questão espacial, ou seja, a relação das variáveis independentes e dependentes com seus

vizinhos. Neste estudo, seguiremos uma estratégia proposta por Elhorst (2010), dessa forma, o modelo que servirá de ponto de partida será o *Spatial Durbin Model (SDM)*, que tem sua forma funcional dada pela equação (3.2) a seguir:

$$Y = \rho WY + \alpha \iota_N + X\beta + WX\theta + \varepsilon, \quad (3.2)$$

onde a variável WY denota o interação endógena, ou seja, a observação y_i está, de alguma maneira, sendo afetada e afetando a observação y_j , para todo $i \neq j$, WX é a interação exógena que denota a relação entre as variáveis independentes. ρ é conhecido como o coeficiente espacial autoregressivo e θ representa um vetor $K \times 1$ de parâmetros fixos desconhecidos.

Quando a interação espacial ocorre apenas na variável dependente tem-se o modelo *Spatial Autoregressive Model (SAR)*, quando há dependência espacial no termo de erro, denominado de heteroscedasticidade espacial, tem-se o *Spatial Error Model (SEM)*, descritos pelas equações (3.3) e (3.4), respectivamente.

$$Y = \rho WY + \alpha \iota_N + X\beta + \varepsilon \quad (3.3)$$

$$Y = \alpha \iota_N + X\beta + u \quad (3.4)$$

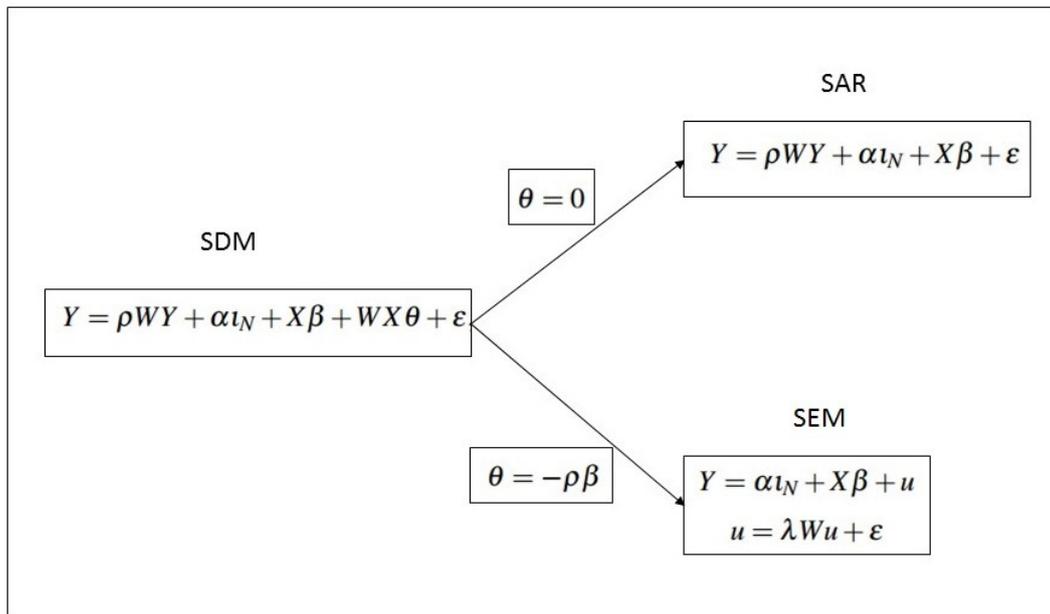
$$u = \lambda Wu + \varepsilon$$

Não é comum detectar a dependência espacial nas variáveis dependentes, independentes e no termo de erro. Com isso, a melhor maneira de encontrar o processo que representa o verdadeiro processo gerador de dados é seguir com a estratégia de Elhorts (2010).

A estratégia consiste em estimar o *MQO* e aplicar o teste LM robusto¹ proposto por Anselin et al. (1996), com o intuito de detectar se há autocorrelação espacial na variável dependente e/ou heteroscedasticidade espacial no processo gerador de dados, caso a hipótese de não autocorrelação espacial juntamente com a hipótese do termo de erro não ser correlacionado espacialmente sejam rejeitadas, tem-se que o espaço é relevante para o fenômeno analisado em questão. Desse modo, estima-se primeiro o modelo mais geral, o *SDM*, que inclui a matriz de vizinhança na variável dependente e nas independentes, em seguida, através de testes de razão verossimilhança, testa-se as seguintes hipóteses na equação 3.2 : $H_0 : \theta = 0$, caso a hipótese nula seja aceita, o *SDM* pode ser reduzido para o *SAR* e $H_0 : \theta + \rho\beta = 0$, novamente se a hipótese nula for aceita o *SDM* será simplificado para o *SEM*.

Esta estratégia foi utilizada por trabalhos no Barsil, por exemplo Lima e Menezes (2015) e Resende et al (2015). A Figura 3.1 ilustra a estratégia de escolha dos modelos, a qual é baseada em Elhorst (2010) e Halleck Vega e Elhorst (2015).

¹ Basicamente a intuição por trás do teste é que o espaço não é relevante, dessa forma, rejeitando a hipótese nula, tem-se que incorporar o espaço na modelagem econométrica.

Figura 3.1 Estratégia para escolha do modelo

3.2 Efeitos diretos e indiretos

A presença de autocorrelação e heterogeneidade espacial alteram não apenas a forma de estimação dos coeficientes, mas também sua interpretação. Os estimadores de *MQO* são interpretados como o efeito marginal da variável independente sobre aquela que deseja-se explicar. Entretanto, na presença de autocorrelação espacial o efeito da variável dependente defasada propaga-se para seus vizinhos geográficos (Lesage 2009), este fenômeno modifica a interpretação dos parâmetros estimados nos modelos espaciais, pois estes devem levar em consideração não apenas o efeito direto dos mesmos, mas também a contribuição dos vizinhos.

Observe que, no modelo sem autocorrelação espacial, a interpretação dos coeficientes é

direta, onde o β_i , na equação 3.1, mede o efeito marginal do aumento em uma unidade da variável explicativa x_i na variável dependente y_i .

Em modelos com a presença de autocorrelação espacial a interpretação dos parâmetros é mais complexa. Caso esse ponto não seja levado em consideração os estudos apresentarão conclusões equivocadas.

James LeSage & Kelley Pace (2009), demonstraram em seu livro, com base no modelo espacial mais expandido - *SDM*, como deve ser feita a interpretação dos parâmetros. Reescrevendo o *SDM* dado pela equação (3.2) tem-se que:

$$(I - \rho W)Y = X\beta + WX\theta + \iota_N\alpha + \varepsilon$$

$$Y = \sum_{r=1}^k S_r(W)x_r + V(W)\iota_N\alpha + V(W)\varepsilon \quad (3.5)$$

$$S_r(W) = V(W)(I\beta_r - W\theta_r)$$

$$V(W) = (I - \rho W)^{-1}$$

$$y_i = \sum_{r=1}^k [S_r(W)_{i1}x_{1r} + \dots + S_r(W)_{in}x_{nr}] + V(X)_i\iota_N\alpha + V(W)_i\varepsilon \quad (3.6)$$

A menos que não haja dependência espacial, a derivada de y_i com respeito a x_{jr} é diferente de zero e potencialmente diferente de β . Sendo este o caso:

$$\frac{\partial y_i}{\partial x_{jr}} = S_r(w)_{ij} \quad (3.7)$$

$$\frac{\partial y_i}{\partial x_{ir}} = S_r(w)_{ii} \quad (3.8)$$

A mudança na variável explicativa de uma região tem um efeito potencial de alterar a variável dependente de outra região. A diagonal principal da matriz de interação capta o efeito direto, que contém o "*feedback loop*", ou seja, a região i afeta ela mesma, através dos impactos que ela gera nos seus vizinhos, enquanto os elementos fora da diagonal captam os efeitos indiretos. A magnitude destes efeitos irá depender: (1) da posição da região no espaço, (2) do grau de conectividade entre as regiões, (3) do parâmetro (ρ) que mede o sentido da dependência espacial e (4) do parâmetro (β).

Uma vez que os impactos variam entre regiões (observações), Pace e LeSage (2006) sugerem utilizar uma medida média de variação no impacto, a medida natural consiste na soma das linhas (ou colunas) da matriz $S_r(W)$ extraindo assim um valor médio para todas as regiões. Para tanto, calcula-se o traço da matriz e encontra-se:

$$\text{Efeitos diretos: } \bar{M}(r)_{direto} = n^{-1} tr S_r(W)$$

$$\text{Efeitos totais: } \bar{M}(r)_{\text{totais}} = n^{-1} \mathbf{1}'_n S_r(W) \mathbf{1}'$$

$$\text{Efeitos indiretos: } \bar{M}(r)_{\text{indiretos}} = \bar{M}(r)_{\text{totais}} - \bar{M}(r)_{\text{direto}}$$

A inferência sobre os valores estimados é feita com base no cálculo da dispersão dos mesmos, empregando Cadeia de Markov com procedimento de Monte Carlo (MCMC).

Neste trabalho foi utilizado a matriz de peso espacial para os k -vizinhos mais próximos, sendo $k = 20$. Como os dados são para *AMC*, optou-se por não utilizar a matriz de peso espacial dada pelo inverso da distância. Para maiores detalhes o leitor poderá consultar o Anexo I.

CAPÍTULO 4

Descrição dos dados

Este capítulo está dividido em duas seções. A primeira seguirá com a habitual análise descritivas dos dados. Na segunda seção, explorar-se-á a análise dos dados espaciais, na qual será possível diagnosticar que o espaço é relevante para o estudo do crime. Esse diagnóstico é importante pois, segundo Elhorst(2000), Lesage(1999a) e Anselin(1988), caso haja autocorrelação no termo de erro, os estimadores de mínimos quadrados continuam sem viés, porém, perdem sua eficiência. No caso de autocorrelação na variável dependente, caso estime-se via *MCO*, os estimadores tornar-se-ão viesados e perderão a consistência.

4.1 Análise Exploratória dos Dados Espaciais

O trabalho foi desenvolvido com base em variáveis obtidas a partir de dois bancos de dados: os censos demográficos de 2000 e 2010 e o DATASUS¹. Dos Censos foram obtidos as variáveis socioeconômicas e, a partir das informações anuais contidas no DATASUS, de 2000 a 2010, foi montado o banco com as taxas de homicídio.

A base de dados foi elaborada a nível de *área mínima comparável (AMC)*, uma vez que o

¹DATASUS é o nome do departamento de informática do Sistema Único de Saúde do Brasil. Trata-se de um órgão da Secretaria de Gestão Estratégica e Participativa do Ministério da Saúde com a responsabilidade de coletar, processar e disseminar informações sobre saúde.

número de municípios brasileiros aumentou de 3.951 em 1970 para 5.507 em 2000, chegando a 5.564 em 2010. Dessa forma, as mudanças nos contornos e áreas geográficas dos municípios, devido à criação de novos municípios, impedem comparações intertemporais consistentes de variáveis demográficas, econômicas e sociais em nível municipal². Logo, faz-se necessário a agregação dos municípios em *áreas mínimas comparáveis (AMC)*. Devido à falta de dados para algumas variáveis, foram excluídas 127 observações, de modo que, a amostra é composta de 4.140 observações das 4267 áreas mínimas comparáveis.

A *Taxa de homicídios 2000-2010*, será a variável dependente, as variáveis independentes foram adotadas com base na literatura. Para evitar problemas de causalidade reversa todas as variáveis independentes são datadas de 2000, assim a *Taxa de homicídios 2000-2010* não pode interferir no comportamento das variáveis independentes. A taxa de homicídios é definida como a quantidade de homicídios por 100 000 habitantes. Por sua vez, os homicídios são considerados como Crimes Violentos Letais e Intencionais – CVLI. Seguindo autores, tais como Cook (2009), Kelly (2000) e Menezes et al.(2013), foram consideradas variáveis demográficas e socioeconômicas como variáveis que, possivelmente, explicam a taxa de homicídios.

Na Tabela 4.1 está descrito o comportamento médio das variáveis demográficas e socioeconômicas utilizadas neste trabalho.

²Informações obtidas no IPEA. http://www.ipeadata.gov.br/iframe_dicionario.aspx?width=1074&height=480

Tabela 4.1 Definição das variáveis e estatísticas descritiva

Variáveis	Definição	Média	DP	Máximo	Mínimo
dlntxhom	Taxa de crescimento de homicídios 2000-2010	0.38	1.20	4.08	-3.44
lntxhom00	Taxa de homicídios em 2000	1.37	1.09	5.81	0.00
dlnpop	Taxa de crescimento da população	0.05	0.15	1.01	-0.70
lnpop00	População em 2000	9.75	1.10	16.23	6.84
lnrdpc00	Renda per capita em 2000	6.00	0.49	7.60	4.80
PO_00	Proporção(%) de pobres em 2000	0.21	0.16	0.72	0.00
G_00	Índice de Gini	0.56	0.06	0.82	0.33
p_desocup00	% de desocupados	0.11	0.05	0.44	0.00
p_domonip00	% de domicílios monoparentais	0.25	0.05	0.50	0.05
p_mulherchefe00	% de mulheres chefes de família	0.15	0.03	0.30	0.03
p_jovem00	% de jovens (15-20)	0.21	0.01	0.27	0.13
p_negros00	% de negros	0.46	0.24	0.98	0.00
p_25_4a00	% de adultos com 4 anos de estudos	0.47	0.16	0.85	0.05
p_25_analf00	% de analfabetos	0.15	0.05	0.31	0.01
p_jovemociosos00	% de desocupados (jovens)	0.05	0.01	0.13	0.00

Fonte: Elaboração própria

4.2 Análise espacial dos dados

O objetivo desta seção é comprovar a autocorrelação espacial na variável dependente, ou seja, na *Taxa de crescimento de homicídios 2000-2010*. Para isto, o primeiro teste geral para identificação de autocorrelação espacial é a estatística *I de Moran*, dada pela expressão a seguir:

$$I = \frac{N}{\sum_i \sum_j w_{ij}} \frac{\sum_i \sum_j w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_i (y_i - \bar{y})^2}, \quad (4.1)$$

onde N é a quantidade de unidades espaciais indexada por i e j , y é a variável de interesse no estudo (*Taxa de crescimento de homicídios 2000-2010*), \bar{y} é a média de y e w_{ij} representa a

matriz de peso espacial, neste caso, a matriz dos 20 vizinhos mais próximos. Essa estatística varia entre -1 e 1 .

Na Tabela 4.2 pode ser observado que o valor da estatística global do *I de Moran* é 0.11 , indicando autocorrelação positiva, de modo que, áreas mínimas comparáveis que revelam alta *Taxa de crescimento de homicídios 2000-2010*, possuem vizinhos semelhantes.

Tabela 4.2 I - Moran Global

Variável	Estatística	p-valor
<i>Taxa de crescimento de homicídios 2000-2010</i>	0.11	0.00

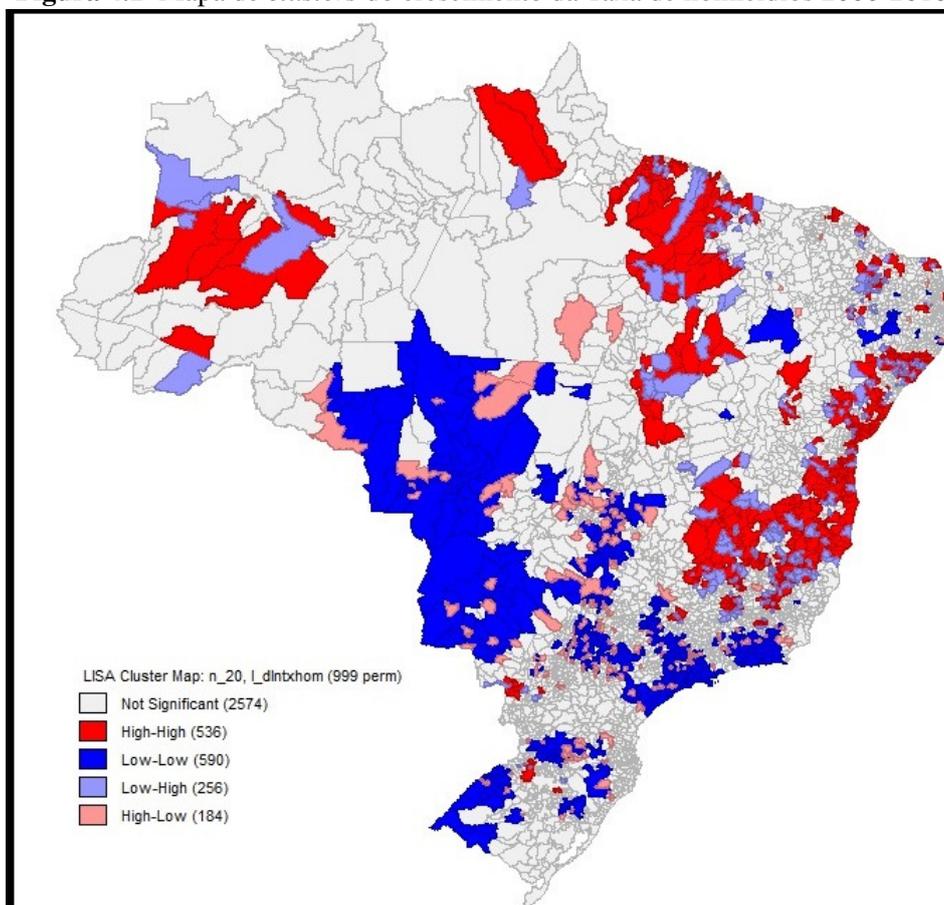
Fonte: Elaboração própria

Apesar do *I de Moran* ser significativo, é importante aplicar a versão local desta estatística, dada pela equação (4.2) a fim de detectar quais regiões apresentam padrões similares e, assim, detectar *clusters*.

$$I_i = \frac{N(y_i - \bar{y}) \sum_j w_{ij}(y_j - \bar{y})}{\sum_j (y_j - \bar{y})^2}, \quad (4.2)$$

onde I_i é a estatística calculada para a área mínima comparável i . As demais variáveis são as mesmas utilizadas na estatística global dada pela equação (4.1).

A melhor maneira de interpretar a estatística *I de Moran local* é através do mapa de *clusters*.

Figura 4.1 Mapa de *clusters* do crescimento da Taxa de homicídios 2000-2010

A Figura 4.1 revela a distribuição espacial das estatísticas *I de Moran locais*. As regiões em vermelho representam as *AMC's* que, além de possuírem taxa de crescimento de homicídio elevadas, estão cercados de vizinhos que apresentam semelhante comportamento. Essas áreas estão tipicamente na região Nordeste (NE) e Norte (N), além da região norte do estado de Minas Gerais que fica na região Sudeste (SE) do país.

Para as regiões em azul, a conclusão é oposta à afirmação acima. Essas áreas concentram-se, sobretudo, na região Centro Oeste (CO), Sul (S) e Sudeste (SE). Isso sugere que a violência na primeira década deste século apresentou taxas de crescimento mais acentuadas nas regiões

N/NE do país. Além destas áreas, ainda há as regiões que revelam altas taxas de crescimento de violência, porém, estão cercadas por regiões de baixa criminalidade. Tais regiões estão marcadas no mapa com a cor rosa. As regiões que estão marcadas com a cor roxa, demonstram situação oposta, ou seja, detém baixa taxa de criminalidade, todavia, seus vizinhos possuem taxas elevadas.

Ainda, é possível recorrer ao estimador de densidade *Kernel* para analisar a concentração espacial da *Taxa de homicídios*. O estimador de densidade Kernel desenha uma vizinhança circular ao redor de cada ponto da amostra³, correspondendo ao raio de influência, e então é aplicada uma função matemática de 1, na posição do ponto, a 0, na fronteira da vizinhança. O valor para a célula é a soma dos valores kernel sobrepostos, divididos pela área de cada raio de pesquisa (Silverman,1986).

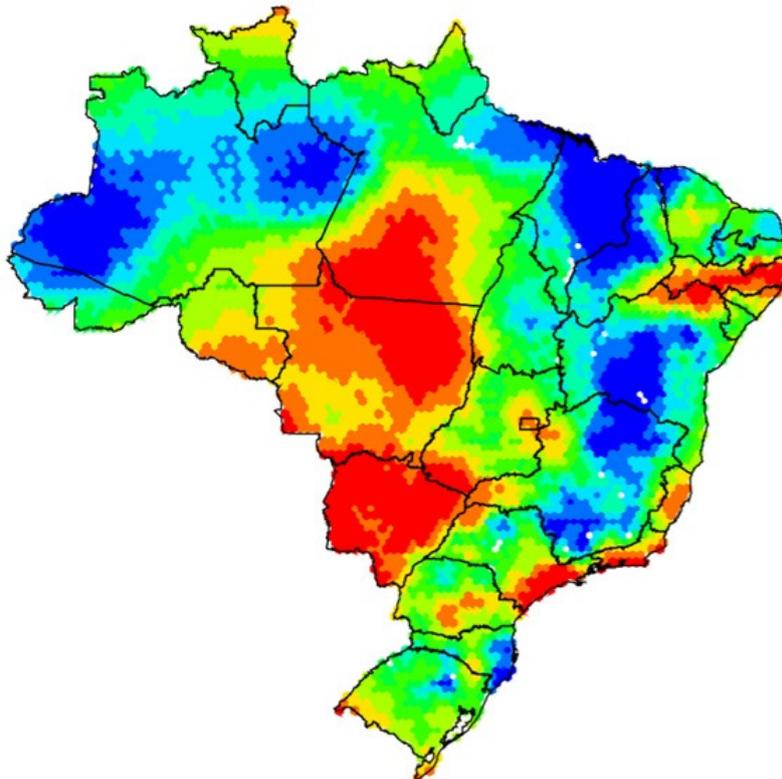
As Figuras 4.2 e 4.3 descrevem, respectivamente, a concentração das taxas de homicídios dos municípios brasileiros em 2000, e a sua taxa de crescimento entre 2000 e 2010. A análise da Figura 4.2 sugere que a concentração dos homicídios não é um fenômeno estadual e sim, municipal. O mesmo mostra que a prevalência dos homicídios não ocorre de forma homogênea no estado, ao contrário, estão concentradas principalmente nos principais centros urbanos das cidades da região SE e no estado de PE, que é um dos estados mais desenvolvidos da região NE.

Outras áreas onde se observa grande concentração de homicídios são os estados do Centro Oeste Brasileiro, mais precisamente os estados de Mato Grosso e Mato Grosso do Sul e o Sul do Estado do Pará. Estes últimos caracterizam-se por apresentarem ocupação recente, mais

³Com base no centróide de cada *AMC*.

precisamente no final dos anos 60 e por serem pouco populosos, o que naturalmente contribui, para elevação das taxas de homicídios.

Figura 4.2 Kernel 1 - Taxas de homicídios das cidades brasileiras no ano 2000.

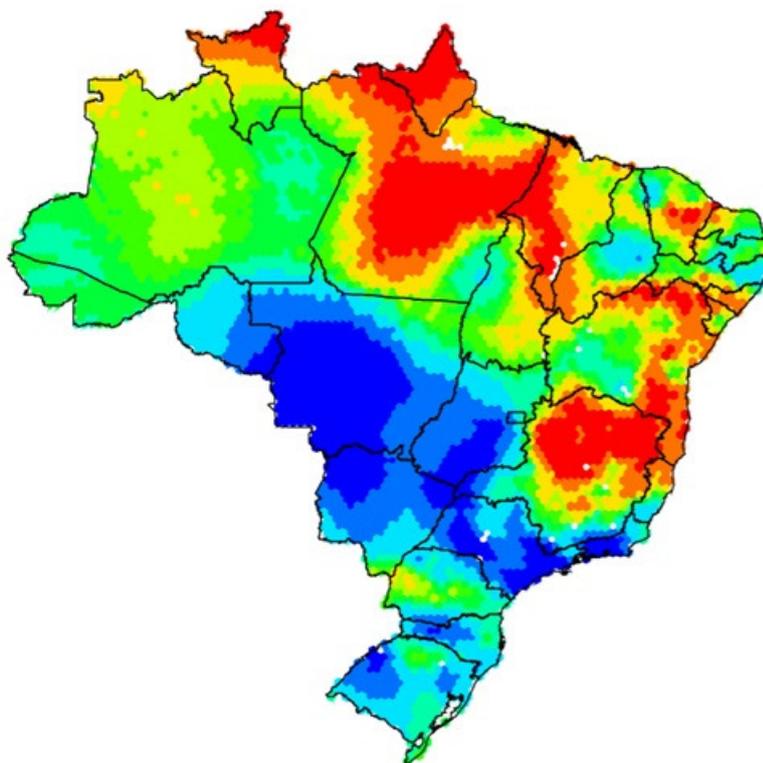


As alarmantes taxas anteriormente apresentadas, motivaram os principais Estados da região Sudeste: Rio de Janeiro e São Paulo e o estado de Pernambuco a adotarem políticas públicas, no início dos anos 2000, com o intuito de amenizar o quadro acima descrito. As políticas públicas aqui citadas estão descritas em Saporì (2011). O trabalho de Menezes *et al.* (2013), por exemplo, avalia o impacto da política de redução da criminalidade para o estado de Pernambuco. Por conseguinte, observa-se uma queda em média de 40% nos homicídios das cidades citadas.

Concomitantemente, as características de área de fronteira que existiam nas cidades do

Centro-Oeste vão sendo reduzidas nos anos 2000. A população de algumas cidades desta região mais do que dobrou no período em análise, o que juntamente com a chegada do setor público e estabelecimento da urbanização são responsáveis por uma drástica redução da violência nestas áreas.

Figura 4.3 Kernel 2 - Crescimento das Taxas de Homicídios das cidades brasileiras entre 2000 e 2010.



A análise da Figura 4.3 demonstra ter havido uma redução nas taxas de crescimento da violência nas localidades onde elas eram mais intensas, nominalmente: Pernambuco, São Paulo e Rio de Janeiro e os estados de Mato Grosso e Mato Grosso do Sul. Exceção para o sul do Pará, área que apresentava elevadas taxas de homicídios em 2000 e apresenta um forte crescimento das mesmas entre 2000 e 2010.

Os demais estados brasileiros, claramente os da região nordeste, não implementam políticas

efetivas de combate à criminalidade, por conseguinte, a mesma continua a crescer a taxas históricas, ultrapassando a média Brasileira e da região Sudeste. A partir da aparente inexistência de uma contaminação espacial do crime entre os estados a questão que se coloca é como este se propaga entre os municípios, ou seja, quando o governo do Estado toma a decisão de agir em determinados municípios onde é possível observar altas taxas de homicídio, quais as consequências desta ação sobre seus vizinhos.

CAPÍTULO 5

Resultados

Esse capítulo é destinado à análise dos resultados com o intuito de demonstrar a importância do espaço, juntamente com os fatores demográficos socioeconômicos, na compreensão do comportamento da taxa de homicídios das cidades brasileiras¹, procurando captar algum efeito de *spillover* das variáveis consideradas e também os efeitos diretos e indiretos das variáveis explicativas.

Na Tabela 5.1 estão contidos os resultados da estimação do modelo por *MQO* e as estatísticas de teste para detecção de dependência espacial, tanto no termo de erro quanto na variável dependente, além do teste *I de Moran* com base nos resíduos da regressão. A variável dependente é a *Taxa de crescimento de homicídios 2000-2010*, sendo explicada pela *Taxa de homicídios em 2000* e por características demográficas e socioeconômicas, conforme foram descritas no capítulo anterior.

A *Taxa de crescimento da população*, *Proporção(%) de domicílios monoparentais*, *% de mulheres chefes de família* e *% de adultos com 4 anos de estudos* não foram significantes. Alguns sinais foram diferentes dos esperados, como por exemplo, a variável *% de pobres em 2000*, que apresentou sinal negativo sugerindo uma correlação negativa, de modo que quanto

¹Como já foi exposto ao longo do texto, principalmente no Capítulo 4, a unidade geográfica de observação é a *AMC*, entretanto, neste capítulo a terminologia *AMC* será substituída por cidade a fim de tornar o texto mais compreensivo.

maior for a *% de pobres em 2000* menor será o crescimento da taxa de homicídios. Já a variável *% de jovens (15-25)* apresentou correlação positiva, esse resultado também foi encontrado no trabalho de Menezes et al. (2013).

A estimação via *MQO* despreza a questão espacial do fenômeno estudado, desta forma, pode-se incorrer no problema de viés de variável omitida. Para checar se, de fato, o espaço importa, aplicou-se o teste *I de Moran* nos resíduos da regressão. Como pode ser observado na Tabela 5.1, o valor da estatística de teste foi significativa a 1%. Ainda, aplicou-se mais dois testes de diagnóstico de autocorrelação espacial, um para o termo de erro e outro para a variável dependente, a saber, o teste do *Multiplicador de Lagrange Robusto (RLM)*. O teste *RLM* indica se há dependência no termo de erro e/ou na variável dependente. Sendo assim, comprova-se o efeito *spillover*, ou seja, a taxa de homicídio da região *i* afeta a taxa da região *j*, para todo $i \neq j$. Além disso, há características não observáveis que também estão correlacionadas espacialmente, uma vez que ambos os testes foram significantes a 1% e, assim, rejeitando a hipótese nula de não autocorrelação espacial.

Tabela 5.1 Mínimos Quadrados Ordinários.

	<i>Dependent variable:</i>	
	dlntxhom	
	<i>OLS</i>	<i>SDM</i>
	(1)	(2)
<i>Taxa de homicídios em 2000</i>	-0.716***	-0.839***
<i>Taxa de crescimento da população</i>	-0.010	0.027
<i>População em 2000</i>	0.240***	0.238***
<i>Renda per capita em 2000</i>	-0.309*	0.055
<i>% de pobres em 2000</i>	-1.273**	-0.904**
<i>Índice de Gini</i>	1.532***	0.519
<i>% de desocupados</i>	1.154**	0.868 **
<i>% de domicílios monoparentais</i>	0.111	1.341 *
<i>% de mulheres chefes de família</i>	0.393	-1.086
<i>% de jovens (15-20)</i>	4.140***	3.628***
<i>% de negros</i>	0.305*	0.405**
<i>% de adultos com 4 anos de estudos</i>	-0.542	0.179
<i>% de analfabetos</i>	1.983***	0.422
<i>% de desocupados (jovens)</i>	2.123**	2.666*
Constant	-1.214	2.841**
ρ		0.476***
Observations	4,140	4,140
R ²	0.385	
Adjusted R ²	0.383	
I-Moran(Resids)	0.12***	
RLM test no spatial lag	168.76***	
RLM test no spatial error	720.40***	

Note: *p<0.1; **p<0.05; ***p<0.01

Em virtude dos argumentos mencionados, o estudo confirma sua hipótese de que o espaço é relevante para estudar o crescimento da taxa de homicídios das cidades brasileiras. O efeito

spillover existe e, sendo assim, ao promover política de segurança pública sem considerar este efeito poder-se-á incorrer em resultados distintos dos desejados.

Uma vez confirmada a autocorrelação espacial, como foi exposto na metodologia, a estratégia é estimar um modelo completo, o *SDM*, e testar se ele pode ser reduzido para um modelo que incorpore autocorrelação espacial na variável dependente, o *SAR*, ou para o modelo em que a autocorrelação espacial se dê no termo de erro, o *SEM* Elhorst (2010).

Parte dos resultados estimados para o *SDM* foram incluídos na Tabela 5.1, as estimativas das variáveis exógenas defasadas espacialmente podem ser observadas no Anexo II. Como foi exposto na estratégia empírica, os coeficientes dos modelos espaciais não devem ser interpretados da mesma maneira que o modelo estimado via *MQO*. O efeito *spillover* é dado pelo parâmetro ρ que, no caso em questão, foi positivo, sugerindo que cidades que apresentam altas taxas de crescimento da violência afetarão de forma positiva a taxa de criminalidade de seus vizinhos.

A Tabela 5.2 contempla o teste da razão de verossimilhança (*log-likelihood ratio*). Com base nesse teste, pode-se rejeitar ou aceitar a hipótese de simplificação do modelo. No caso da hipótese de redução para um *SAR*, tem-se que $H_0 : \rho = 0$, então, com base no valor da estatística de teste, pode-se rejeitar essa hipótese. No que diz respeito a hipótese de simplificação para o modelo *SEM*, tem-se que $H_0 : \theta + \rho\beta = 0$, todavia, também rejeita-se tal hipótese. Essa é a estratégia explicitada na Figura 3.1 da metodologia.

Tabela 5.2 Efeito diretos e indiretos.

	<i>Efeitos:</i>		
	<i>Direto</i>	<i>Indireto</i>	<i>Total</i>
Taxa de homicídios em 2000	-0.83***	0.54***	-0.29***
Taxa de crescimento da população	0.02	-0.11	-0.08
População em 2000	0.23***	-0.12	0.11
Renda per capita em 2000	0.03	-1.33**	-1.30**
% de pobres em 2000	-0.94**	-2.74*	-3.69***
Índice de Gini	0.56	2.82*	3.38***
% de desocupados	0.89**	1.66	2.56*
% de domicílios monoparental	1.27*	-3.89*	-2.61
% de mulheres chefes de família	-1.01	4.82	3.81
% de jovens (15-20)	3.63***	0.56	4.19
% de negros	0.40**	-0.13	0.27*
% de pessoas com 4 anos de estudos	0.17	0.05	0.23
% de analfabetos	0.39	-1.98	-1.59
% de desocupados (jovens)	2.45	-13.35**	-10.90*
log-likelihood ratio(SAR)	374.306***		
log-likelihood ratio(SEM)	92.418***		

Note: *p<0.1; **p<0.05; ***p<0.01
p-values based on 10,000 draws of MCMC sampling procedure.

Com base no teste da razão de verossimilhança tem-se que o modelo adequado é o *Spatial Durbin Model*, com isso a interpretação dos parâmetros estimados não se dá do mesmo modo que no modelo de *MQO*. Note que, dada a influência do vizinho há, além do efeito direto, o efeito indireto e, pela soma destes dois, tem-se o efeito total.

Vale salientar que os impactos diretos quantificam a relação direta entre a taxa de homicídios da unidade geográfica *i* face a variações de suas próprias características demográficas e socioeconômicas, ou seja, é a mesma interpretação dos coeficientes estimados por *MQO*, ao passo que

os impactos indiretos mensuram o efeito na taxa de homicídios da mesma unidade geográfica i , em decorrência da variação nas características demográficas e socioeconômicas da unidade geográfica j .

Conforme os valores para os efeitos direto e indireto na Tabela 5.2, observa-se *spillover* positivo na variável *Taxa de homicídios em 2000*, dado pelo efeito indireto de 0.54. Caso uma determinada cidade apresente um aumento nessa variável, seu vizinho incorrerá em um aumento na *Taxa de crescimento de homicídios*. Pode-se entender esse resultado como uma espécie de contaminação, pois as cidades que apresentam acentuadas taxas de homicídios, tenderão a registrar taxas de crescimento de homicídios menores, dado que já detém uma larga base, portanto, suas taxas de homicídios crescerão menos, por outro lado, afetarão, de forma positiva, a *Taxa de crescimento de homicídios* dos seus vizinhos.

A *Taxa de crescimento população* mostrou-se não significativa, enquanto que a *População em 2000* apresentou efeito direto positivo e significativo. De fato, espera-se que o tamanho da população esteja correlacionado positivamente com a criminalidade. A intuição é que grandes aglomerados populacionais tenderiam a marginalizar seus habitantes.

A *Renda per capita* e o *Índice de Gini* apresentaram efeito direto estatisticamente iguais a zero. Todavia, os efeitos indiretos são significantes e opostos entre si. O fato de ter vizinhos com alta renda per capita diminui sua taxa de crescimento de homicídios, enquanto que cidades com alto nível de desigualdade de renda gera transbordamento espacial do crime. Trabalhos como Amin et al. (2009) mostram que a renda per capita tem um efeito dúbio, de modo que não há como afirmar que sociedades mais ricas são menos violentas.

As variáveis que captam o desemprego foram significantes. A *% de desempregado*, apesar de contribuir para o aumento da criminalidade, não apresenta efeito sobre as cidades vizinhas, ao passo que a *% de desocupados (jovens)* apresenta efeito apenas sobre seus vizinhos. A questão do desemprego como causa do aumento da violência foi estudado por Beato e Reis (1999) e por Saporì e Wanderley (2001). Tais autores afirmam que não foi observado uma relação causal entre desemprego e aumento de violência.

Há um fato interessante, a variável *% de jovens (15-25)* apresentou o sinal positivo. Note que o efeito indireto não é significativo. Hartung e Pessoa (2007) encontraram resultado semelhante, assim como Menezes et al. (2013). A explicação para esse resultado decorre do fato de que uma maior proporção de jovens implica numa maior proporção de indivíduos em idade criminal ativa. São os jovens que mais sofrem violência homicida no Brasil, pois a atividade criminal dada pelo tráfico de drogas demanda, em sua maioria, mão de obra jovem. Se a proporção de jovens no presente for elevada, significa que há aproximadamente 15 a 20 anos atrás a taxa de fecundidade apresentava padrões elevados. Donohue e Levitt (1999) encontraram relação positiva entre a taxa de fecundidade e a de criminalidade para os Estados Unidos.

As variáveis *% de domicílios monoparentais* e *% de negros* contribuem para o aumento da violência, ou melhor, estão correlacionadas positivamente com o crescimento da taxa de homicídios. Sabe-se que a cor da pele não é um determinante do comportamento dos indivíduos, porém, a herança colonial escravocrata impôs aos negros condições de desenvolvimento adversas o que, por sua vez, pode favorecer seu ingresso na vida ilícita. Os lares monoparentais podem estar correlacionados positivamente com a atividade criminal devido a ausência de creches e de

escolas de tempo integral². Dado que o chefe da família, em sua maioria, passa o boa parte do dia trabalhando, seus filhos gozam de uma liberdade plena, já que ficam apenas um turno na escola. Com isso, podem ser aliciados para a atividade criminosa com mais facilidade.

Em suma, este capítulo buscou apresentar os principais resultados deste estudo. Mostrou-se que o espaço é importante para o estudo da criminalidade, no que diz respeito a taxa de homicídios. Uma vez comprovada a importância do espaço, para não incorrer no problema de viés da variável omitida, foram estimados modelos que incorporaram a questão espacial na modelagem e, seguindo a estratégia de Elhorst (2010), aplicaram-se testes de diagnósticos de autocorrelação espacial e de razão de verossimilhança para a escolha do modelo que, neste caso, foi o *SDM*. Além disso, estimou-se os efeitos diretos e indiretos pois, a interpretação dos parâmetros não pode ser feita de forma semelhante aos parâmetros do *MQO*.

²O Tribunal de Contas do estado do Rio Grande do Sul publicou estudo revelando a carência de vagas nas creches e pré-escolas do Brasil. http://www1.tce.rs.gov.br/portal/page/portal/tcers/administracao/gerenciador_de_conteudo/noticias/Estudo%20do%20TCE-RS%20aponta%20car%EAncia%20de%20vagas%20na%20educa%E7%E3o%20infantil

CAPÍTULO 6

Considerações Finais

Este trabalho teve por objetivo investigar a relação entre as características do espaço e a criminalidade nas cidades brasileiras, tendo como proxy a taxa de homicídios. O estudo foi inovador por ter adotado *área mínima comparável* como unidade geográfica. Além de incluir o espaço, como uma variável importante no estudo da criminalidade, também foram inseridas na análise variáveis demográficas e socioeconômicas.

Buscou-se averiguar se o espaço, ou melhor, a vizinhança é relevante para o estudo do crescimento das taxas de homicídios nas cidades brasileiras. Aplicou-se inicialmente a estatística *I de Moran global* à variável *Taxa de crescimento de homicídios 2000-2010* e observou-se autocorrelação espacial positiva, porém, com o intuito de analisar onde ocorrem essas autocorrelações utilizou-se o *I de Moran local*, com isso, detectou-se a existência de *clusters*. Nas regiões N/NE há cidades com elevadas taxas de crescimento de homicídios com vizinhos que apresentam semelhante comportamento, enquanto que as regiões S/SE registram comportamento oposto aos das regiões N/NE.

Estimou-se ainda os efeitos diretos e indiretos, dado que foi comprovado a importância do espaço e, assim, observou-se que as variáveis *Taxa de homicídios em 2000* e *Índice de Gini* apresentaram efeito *spillover* positivo, sugerindo que, caso a desigualdade seja reduzida na

cidade j , o crescimento da taxa de homicídios na cidade i , para todo $i \neq j$, tende a diminuir. As demais variáveis apresentaram efeito *spillover* negativo.

Dessa forma, fica comprovada a hipótese deste trabalho. O espaço é relevante para a compreensão da criminalidade, dada pela taxa de homicídios, nas cidades brasileiras. Portanto, a adoção de políticas de segurança pública deve atentar para este fato caso desejem propor ações que sejam efetivas.

Referências Bibliográficas

- [1] AMIN, M. C.; COMIM, F. V. e IGLESIAS J. R. (2009), Crescimento econômico e criminalidade: refletindo sobre o desenvolvimento, *in* 'Anais do XXXVII Encontro Nacional de Economia', ANPEC - Associação Nacional dos Centros de Pósgraduação em Economia.
- [2] ANSELIN, L.; BERA, A. Spatial dependence in linear regression models with an introduction to spatial econometrics. In: Handbook of applied economic statistics, edited by Amman Ullah and David E.A. Giles. New York: Marcel Dekker. 1998.
- [3] BALLER ET AL. Structural Covariates of U.S. County Homicide Rates: Incorporating Spatial Effects. CRIMINOLOGY. Volume 39, No 3, 2001.
- [4] BEATO ET AL. R. bras. Est. Pop., Rio de Janeiro, v. 30, Sup., p. S155-S170, 2013.
- [5] BECKER, G. S. Crime and punishment: An economic approach. The Journal of Political Economy, v. 76(2), p. 169-217, 1968.
- [6] BLUMSTEIN, A.; ROSENFELD, R. Explaining Recent Trends in U.S. Homicide Rates. Journal of Criminal Law and Criminology. Volume 88, NO. 4, 1998.

- [7] BRANTINGHAM, P.L.; BRANTINGHAM, P.J., SEAGRAVE, J. Crime and fear at a Canadian university. In: B.S. Fisher, J.J. Sloan (eds.), *Campus Crime: Legal Social, and Policy Perspectives* Springfield (III), Charles C. Thomas, p. 123-155, 1995.
- [8] Cook, Philip J., 2009. Crime control in the city: a research-based briefing on public and private measures. *Cityscape: A Journal of Policy Development and Research* 11 (1).
- [9] COHEN, J.; TITA, G. Diffusion in Homicide: Exploring a General Method for Detecting Spatial Diffusion Processes. *Journal of Quantitative Criminology*, Vol. 15, No. 4, 1999.
- [10] Donohue, J. J. and Levitt, S. D. (1999), 'The impact of legalized abortion on crime', *Quarterly Journal of Economics* CXVI, 379–420.
- [11] GRIFFITHS, E.; CHAVEZ, J. M. Communities, Street Guns and Homicide Trajectories in Chicago, 1980-1995: Merging Methods for Examining Homicide Trends Across Space and Time. *Criminology*. Volume 42, No 4, 2004.
- [12] Halleck Vega, S. and Elhorst, J. P. (2015), THE SLX MODEL. *Journal of Regional Science*, 55: 339–363. doi: 10.1111/jors.12188
- [13] HARTUNG, G. C.; PESSOA, S. (2007), Fatores demográficos como determinantes da criminalidade, *in* 'Anais do XXXVII Encontro Nacional de Economia', ANPEC - Associação Nacional dos Centros de Pósgraduação em Economia.

- [14] INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Censo Demográfico de 2000. Disponível em: <http://www.ibge.gov.br/home/estatistica/populacao/censo2000/>. Acesso em 20 de junho de 2015.
- [15] INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Censo Demográfico de 2000. Disponível em: <http://www.ibge.gov.br/home/estatistica/populacao/censo2010/>. Acesso em 25 Maio de 2015.
- [16] Kelly, M., 2000. Inequality and crime. *The Review of Economics and Statistics* 82, 530–539.
- [17] LeSage, J.P., Pace, R.K., 2009. *Introduction to Spatial Econometrics*. CRC Press, Boca Raton, FL.
- [18] LIMA, R. C. A. ; MENEZES, T. A. . Uma Análise Espacial das Eleições Presidenciais Brasileiras de 2010. In: 2nd Ibero-American Congress on Regional Development and 12th Congress of the Brazilian Regional Science Association, 2014, Belo Horizonte. ABER, 2014.
- [19] MINISTÉRIO DA SAÚDE. DATASUS. Disponível em: <http://www2.datasus.gov.br/DATASUS/index.php>. Acesso em 23 de maio de 2015.
- [20] MENEZES et al. Spatial Correlation Between Homicide Rates And Inequality: Evidence From Urban Neighborhoods In A Brazilian City. *Economics Letters* 120 (2013) 97–99.

- [21] MESSNER, S. F.; ANSELIN, L. Spatial analyses of homicide with areal data. *Spatially integrated social science*. Volume 12, 2004.
- [22] MORENOFF ET AL. Neighborhood Inequality, Collective Efficacy, and the Spatial Dynamics of Urban Violence. *Criminology*. Volume 39, No 517, 2001.
- [23] ORD, K. Estimation Methods for Models of Spatial Interaction. *Journal of American Statistical Association*, Vol 70, No. 349, 120-126. 1975.
- [24] PACE, R. K.; LESAGE, J. P. "Interpreting spatial econometric models." *North American Meeting of the Regional Science Association International*, Toronto, CA. 2006.
- [25] RATTON, J. L. ; GALVAO, C. ; Andrade, Rayane ; PAVAO, N. . Configurações de Homicídios em Recife: um estudo de caso. *Segurança, Justiça e Cidadania: Pesquisas Aplicadas em Segurança Pública*, v. 6, p. 73-90, 2011.
- [26] SAMPSON, R. J.; RAUDENBUSH, S. W. Seeing Disorder: Neighborhood Stigma and the Social Construction of "Broken Windows". *Social Psychology Quarterly* 2004, Vol. 67, No. 4, 319–342.
- [27] SAPORI, L. F. ; A SEGURANÇA PÚBLICA NO BRASIL. *Em Debate (Belo Horizonte)*, v. 1, p. 11, 2011.
- [28] SAPORI, L. F. e WANDERLEY, C. B. A relação entre desemprego e violência na sociedade brasileira: entre o mito e a realidade. In: *A violência do cotidiano. Cadernos Adenauer*. São Paulo: Fundação Kinrad Adenauer, 2001, p. 42-73.

- [29] TYSZLER, M. *Econometria Espacial: discutindo medidas para a matriz de ponderação espacial*. Fundação Getúlio Vargas, 2006.
- [30] WAISELFISZ, J. J. (2011), *Mapa da violência 2012: os novos padrões da violência homicida no brasil*, Technical report, Instituto Sangari, São Paulo, SP.
- [31] WHITTLE, P. On the variation of yield variance with plot size. *Biometrika* 43, 337–343. 1956.
- [32] WOOLDRIDGE, J.M. “Cluster-Sample Methods in Applied Econometrics,” *American Economic Review* 93, 133-138, 2003.

ANEXO A

Anexo I

A.1 Matrizes de pesos espaciais

Nesta seção serão apresentados, de forma sucinta, alguns tipos de matrizes de pesos espaciais. Tysler (2006) expõem vários tipos de matrizes, bem como suas vantagens e desvantagens. Lesage (1999) sugere que o princípio direcionador da escolha da matriz mais adequada deve ser a natureza do problema a ser modelado, sendo relevante, também, o emprego de informações adicionais não fornecidas pela amostra.

Pois bem, dito isto, as matrizes construídas a partir de características geográficas são as mais usadas na literatura de econometria espacial. A proposição “*todos influenciam, porém, quem está mais perto influencia mais*” está por trás da intuição que norteia esta metodologia.

Para a construção da matriz de pesos espaciais, geralmente, tem-se duas maneiras, ou constrói-se a matriz por fronteiras ou por distâncias geográficas dos centroides¹. A matriz de fronteiras, também conhecida como matriz de contiguidade, é construída da seguinte maneira:

¹Centroide é o ponto associado a uma forma geométrica que representa seu centro geométrico. Uma forma geométrica possui outros centros, a saber, centro de massa e centro de gravidade.

$$w_{ij}^* = \begin{cases} 0, & \text{n\~{o} h\~{a} fronteira entre } i \text{ e } j \\ 1, & \text{caso contr\~{a}rio} \end{cases} \quad (\text{A.1})$$

Uma t\~{e}cnica usual aplicada \~{a} matriz de peso espacial \~{e} padronizar suas linhas para somarem um, onde W \~{e} uma *row-stochastic*. Essa t\~{e}cnica permite interpretar w_{ij} como a porcentagem da influ\~{e}ncia de i que \~{e} oriunda de j . Ap\~{o}s a normaliza\~{c}\~{a}o a matriz apresentar\~{a} a seguinte forma:

$$W_{ij} = \frac{w_{ij}^*}{\sum_j w_{ij}^*} \quad (\text{A.2})$$

O segundo tipo de matriz de peso espacial mais difundida na literatura \~{e} a matriz da dist\~{a}ncia por centroides. Ela \~{e} obtida calculando o inverso da dist\~{a}ncia Euclidiana:

$$w_{ij}^* = \begin{cases} \frac{1}{\sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}}, & \text{se } i \neq j \\ 0, & \text{se } i = j \end{cases} \quad (\text{A.3})$$

onde x_i , x_j e y_i , y_j s\~{a}o as latitudes e longitudes das observa\~{c}\~{o}es i e j .

Da matriz constru\~{i}da com base no inverso da dist\~{a}ncia Euclidiana, deriva-se a matriz que \~{e} o inverso da dist\~{a}ncia ao quadrado. Uma poss\~{i}vel raz\~{a}o para essa nova abordagem se d\~{a} pelo fato das unidades mais distantes serem penalizadas mais rapidamente do que na matriz de peso

espacial dada pelo inverso da distância Euclidiana. Sendo assim temos:

$$w_{ij}^* = \begin{cases} \frac{1}{(x_i - x_j)^2 + (y_i - y_j)^2}, & \text{se } i \neq j \\ 0, & \text{se } i = j \end{cases} \quad (\text{A.4})$$

As matrizes construídas a partir de (3.11), (3.13) e (3.14) são padronizadas da forma exposta em (3.12).

Entre esses dois modelos de matrizes, contiguidade e distância, há diferentes combinações possíveis. Ertur e Gallo (2003) propuseram a matriz de peso espacial para os k -vizinhos mais próximos $W(k)$. A matriz de vizinhança inclui um certo número k de vizinhos mais próximos. A matriz $W(k)$ é definida da seguinte maneira:

$$w_{ij}^* = \begin{cases} 0, & \text{se } i = j \\ 1, & \text{se } d_{ij} \leq d_i(k) \\ 0, & \text{se } d_{ij} > d_i(k) \end{cases} \quad (\text{A.5})$$

onde, $d_i(k)$ é a distância máxima, ou seja, a distância do vizinho de ordem k . Neste trabalho esta foi a matriz utilizada, sendo $k = 20$. A padronização da matriz de peso espacial dos k -vizinhos mais próximos é dada por:

$$W_{ij}(k) = \frac{w_{ij}^*(k)}{\sum_j w_{ij}^*(k)}. \quad (\text{A.6})$$

ANEXO B

Anexo II

A Tabela B.1 contém os resultados para os modelos espaciais, além do *MQO*.

Tabela B.1 Resultados das Regressões

	<i>Dependent variable:</i>			
	dlnthom			
	<i>MQO</i>	<i>SAR</i>	<i>SEM</i>	<i>SDM</i>
	(1)	(2)	(3)	(4)
Intxhom00	-0.716*** (0.015)	-0.697*** (0.016)	-0.816*** (0.016)	-0.839*** (0.016)
dlnpop	-0.011 (0.111)	0.003 (0.110)	0.040 (0.115)	0.027 (0.116)
lnpop00	0.241*** (0.019)	0.234*** (0.019)	0.245*** (0.019)	0.238*** (0.020)
lnrdpc00	-0.309** (0.124)	-0.171 (0.123)	0.002 (0.140)	0.055 (0.146)
P0_00	-1.273*** (0.388)	-1.057*** (0.385)	-0.849* (0.441)	-0.904** (0.459)
G_00	1.532*** (0.395)	1.265*** (0.391)	0.722 (0.447)	0.519 (0.465)
p_desocup00	1.154*** (0.352)	1.146*** (0.348)	0.938** (0.375)	0.868** (0.383)
p_domunip00	0.112 (0.570)	0.104 (0.564)	0.927 (0.652)	1.341* (0.698)
p_mulherchefe00	0.393 (0.864)	0.108 (0.856)	-0.597 (0.932)	-1.086 (0.971)
p_jovem00	4.140*** (1.222)	3.521*** (1.213)	4.147*** (1.331)	3.628*** (1.405)
p_negros00	0.306** (0.122)	0.231* (0.122)	0.468*** (0.149)	0.405** (0.173)
p_25_4a00	-0.542* (0.297)	-0.588** (0.295)	-0.025 (0.343)	0.179 (0.361)
p_25analf00	1.984*** (0.585)	2.324*** (0.581)	1.316* (0.739)	0.422 (0.833)
p_jovemciosos00	2.123 (1.476)	3.086** (1.465)	2.768* (1.559)	2.666* (1.595)
ρ		0.240*** (0.0294)		0.476*** (0.0337)
λ			0.603*** (0.0284)	
lag.Intxhom00				0.689*** (0.039)
lag.dlnpop				-0.072 (0.275)
lag.lnpop00				-0.176*** (0.047)
lag.lnrdpc00				-0.737*** (0.269)
lag.P0_00				-1.028 (0.835)
lag.G_00				1.253 (0.926)
lag.p_desocup00				0.473 (0.806)
lag.p_domunip00				-2.711** (1.252)
lag.p_mulherchefe00				3.084 (1.976)
lag.p_jovem00				-1.431 (2.682)
lag.p_negros00				-0.262 (0.263)
lag.p_25_4a00				-0.054 (0.621)
lag.p_25analf00				-1.255 (1.272)
lag.p_jovemciosos00				-8.374** (3.439)
Constant	-1.215* (0.687)	-1.816*** (0.681)	-2.803*** (0.780)	2.841** (1.348)
Observations	4,140	4,140	4,140	4,140
R ²	0.385			
Adjusted R ²	0.383			
Log Likelihood		-5,578.784	-5,437.840	-5,391.631
σ^2		0.865	0.793	0.782
Wald Test (df = 1)		66.822*** (p = 0.000)	449.852*** (p = 0.000)	199.248*** (p = 0.000)
LR Test (df = 1)		52.706*** (p = 0.000)	334.594*** (p = 0.000)	186.128*** (p = 0.000)
Akaike Inf. Crit.		11,191.570	10,909.680	10,845.260

Note:

*p<0.1; **p<0.05; ***p<0.01

