



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO

PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO E DESENVOLVIMENTO RURAL

**Clima e crime: Os efeitos da seca nas taxas de
criminalidade de Pernambuco**

Brendo Leonel Alves de Almeida

RECIFE

2020

BRENDON LEONEL ALVES DE ALMEIDA

**CLIMA E CRIME: OS EFEITOS DA SECA NAS TAXAS DE
CRIMINALIDADE DE PERNAMBUCO**

Dissertação apresentado ao Programa de Pós-graduação em Administração e Desenvolvimento Rural da Universidade Federal Rural de Pernambuco, para fins de qualificação.

Área de Concentração:	Políticas Públicas e Desenvolvimento Rural Sustentável
Orientador:	Prof. Dr. Leonardo Ferraz Xavier,
Coorientador(a):	Prof ^a Dr ^a . Poema Isis Andrade de Souza

RECIFE

2020

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

- 447c Almeida, Brendo Leonel Alves de
Clima e crime: Os efeitos da seca nas taxas de criminalidade de Pernambuco / Brendo Leonel Alves de Almeida. - 2020.
65 f. : il.
- Orientador: Leonardo Ferraz Xavier.
Coorientadora: Poema Isis Andrade de Souza.
Inclui referências e apêndice(s).
- Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Administração e Desenvolvimento Rural, Recife, 2020.
1. Criminalidade. 2. Seca. 3. Precipitação. 4. Dados em Paineis. 5. Econometria Espacial. I. Xavier, Leonardo Ferraz, orient. II. Souza, Poema Isis Andrade de, coorient. III. Título

CDD 338.1



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO

PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO E DESENVOLVIMENTO RURAL

**PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
DISSERTAÇÃO DE MESTRADO ACADÊMICO DE**

BRENDON LEONEL ALVES DE ALMEIDA

***CLIMA E CRIME: OS EFEITOS DA SECA NAS TAXAS DE CRIMINALIDADE DE
PERNAMBUCO***

A comissão examinadora, composta pelos professores abaixo, sob a presidência do primeiro, considera o candidato **BRENDON LEONEL ALVES DE ALMEIDA**.

Orientador:

Prof. Dr. Leonardo Ferraz Xavier, DSc
Universidade Federal Rural de Pernambuco

Banca Examinadora:

Prof(a). Dr. Gisléia Benini Duarte, DSc
Universidade Federal Rural de Pernambuco

Prof. Dr. Luiz Eduardo Barbosa Carazza, DSc
Universidade Federal Rural de Pernambuco
Examinador externo

AGRADECIMENTOS

Agradeço a todos aqueles que puderam fazer dessa etapa da minha vida um momento de concretude, e a todos os Deuses que conspiraram ao meu favor até este momento.

Aos meus orientadores, Leonardo Xavier e Poema Isis pela instrução, simplicidade e paciência na construção e desenvolvimento desse trabalho.

Ao coordenador do Programa de Pós-graduação em Administração e Desenvolvimento Rural da UFRPE, agradeço a cooperação e paciência no processo de conclusão do mestrado. E a CAPES pelo financiamento.

Agradeço a contribuição dos professores que compuseram a banca julgadora.

Agradeço a minha família a qual deu suporte nos momentos mais difíceis da minha vida, que contribuíram desde a construção do meu ser, ao suporte as necessidades básicas para a construção das minhas jornadas.

Por fim, porém não menos importante, agradeço a todos os amigxs que contribuíram direta e indiretamente, na construção da minha jornada e deste trabalho. Aos professores e profissionais que direta e indiretamente contribuíram ou incentivaram a minha jornada acadêmica, agradeço a todos que de alguma forma estiveram presentes na minha vida.

RESUMO

As condições climáticas de uma região podem exercer influências sobre alguns indicadores socioeconômicos, como, por exemplo, a criminalidade. Nesse sentido, a presente pesquisa descreve os mecanismos que podem a partir das variações de clima, expressas pelo nível de precipitação pluviométrica (através do Índice de Precipitação Padronizada, SPI), identificar como as taxas de criminalidade nos municípios pernambucanos podem ser afetadas pela ocorrência de secas. Destaca-se que o estado de Pernambuco sofreu uma severa estiagem entre os anos de 2012 a 2016, resultando em um dos mais longos períodos de seca das últimas décadas. Esse cenário de escassez levou a estresses econômicos, sociais e ambientais contundentes, que podem ter ocasionado o deslocamento das atividades rotineiras da população, inclusive a incidência de crimes. Desta forma, através de estratégias econométricas de painel espacial, o presente estudo contém as estimativas dos efeitos diretos e indiretos da seca sobre a criminalidade, particularmente a taxa de crimes violentos contra o patrimônio. Os resultados observados foram estatisticamente significativos e apontam que quanto maior for a intensidade da seca há um aumento na criminalidade no estado.

Palavras-chave: Criminalidade; Seca; Precipitação; Dados em Painel; Econometria Espacial.

ABSTRACT

The climatic conditions of a region can influence some socioeconomic indicators, such as, for example, crime. In this sense, the present research describes the mechanisms that can from the variations of climate, expressed by the level of pluviometric precipitation (through the Standardized Precipitation Index, SPI), identify how the crime rates in the municipalities of Pernambuco can be affected by the occurrence drought. It is noteworthy that the state of Pernambuco suffered a severe drought between the years 2012 and 2016, resulting in one of the longest periods of drought in recent decades. This scarcity scenario led to striking economic, social and environmental stresses, which may have caused the displacement of the population's routine activities, including the incidence of crimes. Thus, through econometric strategies of the spatial panel, the present study contains estimates of the direct and indirect effects of drought on crime, particularly the rate of violent crimes against property. The observed results were statistically significant and point out that the greater the intensity of the drought, there is an increase in crime in the state.

Keywords: Crime; Drough; Precipitation; Panel Data; Spatial Econometrics

LISTA DE FIGURAS

Figura 1 – Mapa esquemático dos efeitos da escassez de água	14
Figura 2- Mapa de cluster (LISA) referente à taxa de crimes patrimoniais	41
Figura 2- Mapa de cluster (LISA) referente à taxa de crimes de homicídios	42
Figura A1 – Resumo das estatísticas / <i>Moran Global</i> entre 2011 e 2016 – Taxa de Crimes Patrimoniais (CVP).	57
Figura A2 – Mapas de <i>clusters</i> (LISA) da taxa de CVP entre 2011 e 2016.	58
Figura A3 – Resumo das estatísticas / <i>Moran Global</i> entre 2011 e 2016 – Taxa de Homicídios (CVLI).	59
Figura A2 – Mapas de <i>clusters</i> (LISA) da taxa de CVLI entre 2011 e 2016.	60

LISTA DE QUADROS

Quadro 1 – Definição e fonte das variáveis.....	28
Quadro 2. Condições de pluviosidade segundo valores calculados do SPI3.....	31

LISTA DE TABELA

Tabela 1 – Estatísticas descritivas das variáveis utilizadas.....	33
Tabela 2 - Estatística <i>I</i> de Moran Global para crimes patrimoniais (CVP) e homicídios (CVLI).....	41
Tabela 3 - Resultados para estimações para dados em painel: crimes patrimoniais...	45
Tabela 4 - Estimativas para dados em painel espacial: crimes patrimoniais.....	46
Tabela 5 – Resultados para os efeitos do <i>Spatial Durbin Model</i> : Crimes Patrimoniais.....	49
Tabela B1 - Resultados das estimações para dados em painel: crimes de homicídios.....	62
Tabela B2 - Resultados das estimações painel espacial: crimes de homicídios.....	
Tabela B3 – Resultados da estimação SDM espacial com PIB <i>Per capita</i>	66

LISTA DE ABREVIATURAS E SIGLAS

AR - Teoria da Atividade de Rotina

BDE- Banco de Dados do Estado

CVLI – Crimes Violentos Letais Intencionais

CVP – Crimes Violentos contra o Patrimônio

FBSP – Fórum Brasileiro de Segurança Pública

GA - Modelo Geral de Agressão

IBGE – Instituto Brasileiro de Geografia e Estatística

IPEA – Instituto de Pesquisa Econômica Aplicada

IPEADATA – Base de dados macroeconômicos, financeiros e regionais do Brasil mantida pelo IPEA.

LISA - *Local Indicator of Spatial Association*

NAE - Modelo de Agressão por Escapamento Negativo

PIB - Produto Interno Bruto

SDS/PE – Secretaria de Defesa Social do estado de Pernambuco para o Desenvolvimento

SPI- Índice de Precipitação Padronizada

Sumário

1. Introdução	13
2. Revisão de Literatura	16
2.1 O cenário da seca.....	16
2.2 Criminalidade	19
2.3 O clima e a criminalidade.....	25
3. Metodologia e descrição dos dados	29
3.1 Base de dados.....	29
3.3 Modelo econométrico.....	35
3.4 Análise Exploratória de Dados Espaciais (AEDE)	39
4. Resultados.....	42
4.1 Análise Exploratória de Dados Espaciais (AEDE)	42
4.2 Estimação do modelo empírico.....	45
5. Considerações finais	52
REFERÊNCIAS	54
Apêndice	61
Apêndice A – Quadros referentes à Análise Exploratória de Dados Espaciais.	61
Apêndice B – Resultado das regressões	65

1. INTRODUÇÃO

O fenômeno da seca se diferencia de outras tragédias naturais uma vez que seus impactos podem ser diversos e suas consequências múltiplas e sistemáticas. Estes efeitos vão desde a redução das atividades ligadas diretamente a incidência de chuvas como a produção agrícola, à impactos sociais, econômicos e ambientais (FERNANDES *et al.*, 2009)

Entre os efeitos adversos causados pela seca no interior dos estados ou em áreas rurais, já foram identificados problemas que vão além dos desgastes socioeconômicos e ambientais, visto que o fenômeno também pode afetar até mesmo nas questões psicossociais como a tristeza, a falta de perspectiva e a insegurança, conforme constatado por Favero (2012) e Camurça (2016).

Nesse contexto, o estado de Pernambuco, situado na região Nordeste, com 9.557.071 habitantes distribuídos nas quatro mesorregiões (Litoral, Zona da Mata, Agreste e Sertão), há 23%¹ da população vivendo em áreas características de seca, como o Sertão (IBGE, 2019). Assim, Pernambuco está entre os oito estados brasileiros do nordeste que apresenta mais frequência para as ocorrências de seca com seu último ciclo de escassez hídrica que durou entre os anos de 2012 e 2016, apesar da regularidade das chuvas no Litoral Pernambucano e na Zona da Mata (ASFORA *et al.*, 2017).

A exemplo dos impactos desse período de estiagem no estado, Asfora *et al.* (2017) constatou que houve uma considerável queda do valor adicionado na agropecuária em Pernambuco para o ano de 2016, além de uma queda de R\$ 48,4 milhões no faturamento da Companhia Pernambucana de Saneamento (COMPESA) entre os anos de 2010 e 2016.

Percebe-se, então, que a agricultura é um dos setores mais afetados pela dinâmica da seca em todo o interior das regiões propícias à estiagem, não sendo diferente em Pernambuco. Ao analisar o efeito sobre a produtividade agrícola das variações climáticas, Araújo *et al.* (2013) verificaram que em período de ocorrência de secas, as produtividades médias de sequeiros² como

¹ Cálculo feito a partir de dados estimados sobre a população de Pernambuco disponibilizados pelo IBGE para o ano de 2019 e os dados da população municipal total disponibilizado pelo BDE. Percentual total da região dividido pelo Percentual total estimado da população.

² Produções tradicionalmente cultivadas sem quaisquer técnicas de irrigação.

mandioca, milho e cana de açúcar nos municípios produtores tendem a ser reduzidas.

Assim como no trabalho de Araújo *et al.* (2013), diversos estudos analisaram os substanciais impactos da seca na agricultura (SILVA *et al.*, 2015; CAMPOS *et al.*, 2018). Contudo, os efeitos sociais mais amplos decorrente das secas ainda receberam pouca atenção. Não obstante, alguns trabalhos já tentam verificar a existência de relação entre o clima e outras variáveis socioeconômicas e demográficas que fogem das pesquisas tradicionais sobre o clima, como é o caso da criminalidade.

Nesse sentido, os esforços de Burke *et al.* (2009), para relacionar aspectos climáticos às questões sociais, buscaram verificar de que maneira o aquecimento global aumenta tem impactos sobre os riscos de guerra civil na África. Portanto, verificou-se que as variáveis de temperatura estão fortemente relacionadas à incidência de conflitos na região.

Já o trabalho de Blakeslee e Fishman (2018) abordou algumas das principais evidências sobre a relação entre clima e criminalidade para os países em desenvolvimento. Por conseguinte, através da análise de choques climáticos, verificou-se que os mesmos choques climáticos de temperatura e pluviosidade que afetaram a produtividade agrícola nos distritos indianos e também tiveram impactos sobre a criminalidade na Índia, tanto para crimes violentos quanto para crimes contra o patrimônio.

Goin, Hudolph e Ahem (2017) usaram o fenômeno da seca como um controle, através dos métodos de controle sintético, e trouxeram evidências de como o cenário da seca no estado da Califórnia nos EUA, no ano de 2011, afetaram as taxas de criminalidade no estado.

As teorias que relacionam a criminalidade e o clima, especificamente o fenômeno da seca, torna-se alvo de um importante instrumento de análise para o comportamento das taxas de criminalidade, principalmente quando inseridos no contexto territorial onde é frequente a ocorrência desse fenômeno, característica forte no território pernambucano, que apresenta em grande parte o clima semiárido.

Além de todos os aspectos climáticos que caracterizam o estado de Pernambuco, as elevadas taxas de criminalidade também chamam bastante atenção. Em 2011, a taxa de homicídios no Brasil era de 27,4 homicídios por 100

mil habitantes, passando para 30,3 homicídios em 2016, ou seja, apresentou uma variação percentual de 10,5% no período, segundo IPEA e do Fórum Brasileiro de Segurança Pública (2018). Trata-se de uma taxa ainda bastante elevada quando comparada com a taxa de criminalidade que é considerada aceitável pela Organização Mundial de Saúde, 10,0 por 100 mil habitantes.

De todo o Brasil, as taxas de homicídios para as regiões Norte e Nordeste, além de apresentarem taxas crescentes, entre 2011 e 2015, sempre estiveram entre as mais elevadas de todo o país. Já nos estados brasileiros, Pernambuco apresenta uma das mais elevadas taxas de criminalidade, ficando na sexta posição em 2016, com uma variação percentual positiva de 20,7% no período de 2011 a 2016, segundo o IPEA e o Fórum Brasileiro de Segurança Pública (2018).

Diante desse contexto, o objetivo deste trabalho consiste em mensurar, o comportamento da criminalidade frente aos cenários de seca para os municípios pernambucanos, entre os anos de 2011 a 2016. Para isso, será construído o Índice de Precipitação Padronizado de categoria trimestral para a identificação dos anos de seca. Ainda, através dos resultados obtidos, pretende-se identificar a existência de transbordamento dos efeitos da seca para as regiões de vizinhança.

É fato que o Nordeste do Brasil sofreu elevações da criminalidade de forma bastante acentuada, no período de 2010 a 2016, divergindo de regiões como Sul e Sudeste. Associado a isso, o Nordeste é uma região com a ocorrência frequente de graves secas, inclusive no período de análise considerado neste estudo. A partir da disponibilidade de dados pluviométricos para os municípios do estado de Pernambuco, no mesmo período em que a taxa de criminalidade foi cresceu de forma bastante acentuada, inclusive nos municípios do interior do estado, este trabalho torna-se relevante por testar a relação econômica entre a existência de crime e o fenômeno de seca.

Sendo assim, além dessa introdução, o trabalho está organizado da seguinte forma. No capítulo 2 é apresentado o referencial teórico, com a apresentação de importantes estudos que tratam da relação entre o clima e a criminalidade. No terceiro capítulo, encontram-se os dados e o método utilizados para mensurar os efeitos da seca sobre os crimes. No quarto capítulo, tem-se a análise dos resultados para os efeitos da seca na criminalidade em Pernambuco. Por último, o capítulo 5 contém as considerações finais.

2. Revisão de Literatura

Este capítulo aborda a evolução dos trabalhos teóricos sobre a seca, primeiramente; e, posteriormente, as causas da criminalidade, desde os primeiros estudos que buscaram entender as condições que levam o indivíduo a se tornar criminoso. O capítulo também traz algumas das teorias relevantes sobre o crime e a violência relacionadas às mais diversas áreas de estudo (antropologia, sociologia, medicina e economia) e, por fim, as teorias que relacionam a criminalidade a partir da perspectiva climática: Teoria da Atividade de Rotina (AR), o Modelo de Agressão por Escapamento Negativo (NAE) e o Modelo Geral de Agressão (GA).

2.1 O cenário da seca

A seca é definida pela Política Nacional de Combate e Prevenção à Desertificação e dos Efeitos da Seca como um processo que ocorre naturalmente quando a precipitação pluviométrica registrada é significativamente inferior aos valores normais esperados para determinado período, ou seja, uma deficiência de precipitação em relação às médias históricas de determinada região (HAYES *et al.*, 2011; CANAMARY *et al.*, 2015).

Desta maneira, a seca trata-se de um fenômeno natural que nitidamente se diferencia de outras catástrofes naturais. Diferentemente de outros fenômenos, a seca pode ter um início lento e uma duração bastante longa, podendo se alastrar por uma vasta região. Assim, o fenômeno da seca pode ser considerado um dos mais graves fenômenos naturais, tendo em vista seu poder de destruição, seus impactos perversos na sociedade, a redução da produção agrícola e, em si, os prejuízos econômicos, ou seja, impactos diretos na esfera socioeconômica, agrícola e ambiental (FREITAS, 1998; FERNANDES *et al.*, 2009).


Para Leite e Leite (1984) o fenômeno da seca é difícil de ser delimitado, pois esse processo envolve fatores climáticos, geográficos, sociais e econômicos que atuam sistematicamente. Contudo, há certeza de que a seca pode se fundamentar principalmente pela insuficiência de chuva e pela calamidade socioeconômica, sendo a dimensão do território atingido, o período de estiagem e a capacidade econômica, fatores que contribuem para transformar

o fenômeno climático em calamidade. Ou seja, o desastre climático torna-se fenômeno de caráter eminentemente social e multidimensional (LEITE e LEITE, 1984).

Entre os efeitos causados pela seca, consistentemente, a seca pode levar à fome, ao desaparecimento de sementes de espécies crioulas³, à perda do patrimônio e do rebanho, à migração, à falta de perspectivas, ao aparecimento de doenças físicas e mentais, e ao desamparo. Onde quanto mais sistemático for o fenômeno, mais difícil pode ser para as pessoas se equilibrarem, uma vez que estas tendem a ficar cada vez mais fragilizadas, vulneráveis e pobres quanto mais tempo ficam expostas ao fenômeno de escassez pluviométrica (COSTA, 2006).

González, Decker e Hall (2017) desenvolveram um esquema para representar as diversas formas que o fenômeno da seca pode atingir os agentes diretamente, como segue abaixo:

Figura 1 – Mapa esquemático dos efeitos da escassez de água



Fonte: traduzido de González, Decker e Hall (2017).

³ É aquele germoplasma que vem sendo multiplicado por agricultores através do tempo, cuja origem pode ser de outras regiões, ou que é fruto do intercâmbio dentro de uma mesma região, e cujo cultivo *in loco* conduz à adaptação específica ao referido ambiente como resultado da seleção natural, da seleção artificial ou de ambas (BEVILAQUA et al., 2014).

Seguindo esse mesmo raciocínio dos efeitos da escassez hídrica apresentado, Goin, Rudolph e Ahern (2017) procuraram estudar os efeitos da seca na Califórnia, partindo da teoria de que a seca causa o estresse econômico nos agentes e, conseqüentemente, ocasiona uma elevação nas taxas de criminalidade.

Particularmente no Brasil, o fenômeno da seca e seus efeitos atingem, principalmente, a região nordestina, que é formada por nove estados e uma área correspondente a 1.219.000 km², preponderantemente caracterizada pelo clima semiárido. Nessa região, pode-se encontrar o polígono das secas, área marcada por características específicas de clima com chuvas concentradas em determinados períodos e irregularidades pluviométricas, com períodos longos de estiagens (CARMUÇA *et al.*, 2016).

No contexto dos territórios caracterizados geograficamente com clima propenso a cenários de seca, o Nordeste do Brasil se destaca por estar localizado na Zona Intertropical do planeta, caracterizada por grande quantidade de luz incidente na superfície, altas temperaturas em todas as estações e distribuição irregular da precipitação. Nesse contexto, dentre os nove estados que compreendem o polígono das secas, o estado de Pernambuco é um dos afetados pela estiagem (ASFORA; LIMA; LACERDA, 2017).

O estado de Pernambuco, do ponto de vista climático, apresenta 89% de sua área com clima semiárido e os outros 11% com clima úmido e subúmido, de acordo com a classificação climática de Thornthwaite⁴. O clima semiárido, presente nas mesorregiões do Sertão e do Agreste, caracteriza-se pelos baixos índices pluviométricos acompanhados de longos períodos secos e pluviosidade escassa, concentrada em poucos meses do ano, além de altas temperaturas, mantendo-se a pluviosidade média entre 500 e 800 milímetros anuais (ASFORA; LIMA; LACERDA, 2017).

⁴ A classificação de THORNTHWAITE (1948) baseia-se em dois índices climáticos principais, o Índice de Umidade (que é a relação em porcentagem entre o excesso de água e a evapotranspiração potencial) e o Índice de Eficiência Térmica (valor numérico da evapotranspiração potencial). É considerada bastante útil nos estudos da ecologia, agricultura e recursos hídricos (AYOADE, 1996).

2.2 Criminalidade

Identificar quais elementos são os causadores ou determinantes para a criminalidade é um exercício bastante antigo na literatura da criminologia. Além disso, trata-se de algo complexo, uma vez que a ciência criminológica tem uma perspectiva a partir de área multidisciplinar, resultando em constante evolução e divergência de métodos e técnicas de investigação.

Para Peteado Filho (2012), a criminologia é a ciência empírica e interdisciplinar que objetiva a análise do crime, o perfil do delinquente, a vítima e o controle social das condutas criminosas. Dessa forma, a criminologia tem o objetivo de explicar os fenômenos criminais, encontrando e guiando os caminhos para o desenvolvimento de novas estratégias de controle do fenômeno criminal (VIANA, 2014).

Os estudos sobre as causas da criminalidade, segundo Cerqueira e Lobão (2004), têm se desenvolvido em geral para compreensão de dois aspectos: as motivações individuais; e os processos que levariam as pessoas a se tornarem criminosas. Contudo, desde meados do século passado, vêm se desenvolvendo arcabouços teóricos sobre a relação entre a taxa de crimes em face das variações culturais e das organizações sociais.

De acordo com Cano e Soares (2002), é possível distinguir as diversas abordagens sobre as causas do crime em cinco grupos: i) teorias que tentam explicar o crime em termos de patologia individual; ii) teorias centradas no *homo economicus*, isto é, no crime como uma atividade racional de maximização do lucro; iii) teorias que consideram o crime como subproduto de um sistema social perverso ou deficiente; iv) teorias que entendem o crime como uma consequência da perda de controle e da desorganização social na sociedade moderna; e v) correntes que defendem explicações do crime em função de fatores situacionais ou de oportunidades.

Nesse sentido, é fundamental reunir as reflexões das principais pesquisas que tratam do crime e da violência, de forma a ajudar na seleção de variáveis adequadas ao que se busca estudar.

Na economia do crime, perspectivas para essa área de pesquisa não eram formalmente tratadas com rigor acadêmico antes de 1968, quando o economista Gary Becker publicou o trabalho "*Crime and punishment: an*

economic approach" (BECKER, 1968). Foi o primeiro estudo na teoria econômica voltado à análise da criminalidade, através de um modelo microeconômico no qual os indivíduos decidem entre realizar ou não o ato ilícito.

A teoria de Becker (1968) foi fundamentada no arcabouço do modelo neoclássico do comportamento humano, o *homo economicus*, em que este decide maximizar suas utilidades a partir de um comportamento racional, visando tirar o maior proveito de suas relações de produção e consumo na sociedade.

Nesse sentido, Becker (1968) se dispôs a responder a seguinte pergunta: qual a quantidade de recursos e punições que devem ser usados para reforçar diferentes tipos de legislações? O autor inicia seu trabalho mostrando as diversas relações sociais e econômicas que se originam quando uma atividade ilícita é cometida: i) número de crimes e seus custos sociais; ii) número de crimes e suas respectivas punições; iii) número de crimes e os gastos com segurança pública; iv) número de crimes e gastos com as punições; v) número de crimes e gastos privados com segurança.

A primeira função busca medir o dano social líquido D , está dada pela diferença entre a parte prejudicada $H(O)$ e a parte beneficiada $G(O)$, onde "O" é o nível de crime para determinado período. Matematicamente representada como:

$$D(O) = H(O) - G(O) \quad (2.1)$$

Quanto à modelagem sobre o custo com as punições em apreensão e condenação, Becker parte da hipótese de que quanto maiores forem os recursos alocados na captura e na detenção dos criminosos, maior a probabilidade de condenação do delinquente. A relação entre as ocorrências criminais definida por A e os insumos, mão de obra (m), materiais (r) e capital (c), é representada por $A = f(m, r, c)$, em que "f" é uma função de produção total das variáveis alocadas. Dados os preços dos insumos, o aumento da atividade policial seria mais oneroso, conforme:

$$C = C(A) \quad (2.2)$$

Em que C representa o Custo total e A representa as ocorrências criminais. Para Becker, quanto maior o gasto, maior a probabilidade de condenação e descoberta de crimes, de forma que $C' = \frac{dC}{dA} > 0$. Visto que medir o nível de atividade criminal pode ser complexo, faz-se necessária uma aproximação para as aplicações empíricas.

Partindo para a análise da oferta do crime, Becker relaciona variáveis determinantes da atividade criminosa e seus respectivos efeitos, com destaque para a probabilidade de o criminoso ser condenado, a punição se ele for condenado, bem como outras variáveis, como renda disponível em atividades lícitas e em outras atividades ilícitas, além de sua propensão em cometer um ato ilegal. Becker então representa a função da seguinte maneira:

$$O_j = O_j(p_j, f_j, u_j) \quad (2.3)$$

Em que O_j é o número de ocorrências que um indivíduo cometeria durante um período de tempo; j é o indivíduo; p_j é sua probabilidade de condenação pela ocorrência; f_j é a pena pela ocorrência; e u_j é uma variável que representa todas as outras influências que afetam O_j .

Evidentemente, trabalhar com todos os indivíduos seria bastante complexo, com limitações empíricas, de maneira que Becker simplificou a equação:

$$O = O(p, f, u) \quad (2.4)$$

Assume-se então que a equação apresenta as propriedades individuais, em que (p, f) apresentam relação negativa com a criminalidade, sendo mais responsivo a p que a f . Para o autor, contudo, esse efeito maior da primeira em relação à segunda variável só acontece se o criminoso for propenso ao risco.

Ainda segundo Becker, as punições também geram custos, não apenas ao infrator, mas à sociedade em geral. Sendo o custo social total das punições dado pela soma do custo para os criminosos, acrescido do custo (ou

ganho com sinal negativo) dos outros indivíduos da sociedade. Os custos sociais descritos por Becker, portanto, são expressos da seguinte maneira:

$$f' = bf \quad (2.5)$$

Em que f' é o custo social das punições e b é o coeficiente que transforma f em f' e varia de acordo com as diferentes punições.

Por fim, na análise das condições de otimização, Becker encontra a condição ótima de combate ao crime, que seria o ponto em que o custo social marginal (resultado líquido entre o benefício adquirido pelo criminoso ao realizar o crime, o malefício causado ao restante da sociedade e os custos incorridos à sociedade para punir o ato criminoso.) de aumentar a criminalidade fosse igual ao ganho social marginal de aumentar a criminalidade para gerar uma soma zero. Esta condição pode ser descrita através da função que mede a perda social:

$$L = L(D, C, bf, O) \quad (2.6)$$

Esse modelo para Becker representa a minimização dos custos sociais, em que L representa a função de perda com os custos sociais. A minimização desta função resulta nos valores ótimos das variáveis " p " e " f " de modo que o combate à criminalidade siga um critério que leva em conta os custos sociais contra atos ilícitos.

A partir do modelo de Becker, que estabeleceu o pilar principal para o desenvolvimento do campo de pesquisa conhecido como economia do crime, diversos autores internacionais e nacionais trabalharam na busca pelo seu aprimoramento, com o intuito de identificar as principais causas do comportamento criminoso.

Apesar da contribuição teórica bastante robusta feita por Gary Becker, ele não realizou nenhum estudo econométrico em seu trabalho, algo introduzido por Isaac Ehrlich no trabalho "*Participation in illegitimate activities: a theoretical and empirical investigation*" (EHRlich, 1973), conforme destaca Halicioglu (2012).

Ehrlich (1973) buscou investigar os efeitos da distribuição de renda sobre o crime, voltados especialmente para os crimes contra o patrimônio. Para tanto, construiu um modelo de participação em atividades ilegais e testou as variações das taxas de crimes dos Estados Unidos (EUA) para os anos de 1940, 1950 e 1960. Ehrlich modelou e acrescentou ao modelo de Becker os rendimentos das atividades ilícitas e lícitas a serem colhidas, a distribuição de renda e a possibilidade do desemprego:

$$O = o(p, f, W_i, W_j, u, \pi) \quad (2.7)$$

onde: p é probabilidade do criminoso ser preso e condenado; f é penalidade imposta ao criminoso; W_i são os rendimentos provenientes de atividades ilegais; W_j são os rendimentos provenientes de atividades legais; u representa o desemprego; π são outras variáveis que podem influenciar na escolha do indivíduo entre cometer ou não o crime (educação, renda, etc).

Ehrlich (1973) concluiu então que o comportamento criminoso está condicionado ao custo de oportunidade de cometer o crime, como a renda, o emprego e a possível punição. Em seu trabalho, destaca-se que o autor ainda encontrou uma correlação positiva entre os crimes contra o patrimônio e a desigualdade social.

Desde então, diversos autores vêm tentando entender a dinâmica do crime através de variáveis econômicas, sociais e demográficas (HALICIOGLU, 2012). Lima *et al.* (2005) constataram que variáveis como densidade populacional, coeficiente de Gini, pobreza e desemprego podem estar associados com as taxas de violência, e os efeitos podem variar de acordo com tempo e espaço.

De acordo com o trabalho de Soares (2008), que analisa os homicídios no Brasil e no mundo numa perspectiva histórica e comparada, a densidade demográfica é positivamente relacionada aos homicídios. Em Kume (2004), com a utilização de estimativas de painel dinâmico por GMM (Método Generalizado dos Momentos), tem-se que o grau de desigualdade de renda e a taxa de criminalidade do período anterior tem um efeito positivo com a taxa de criminalidade do período presente; enquanto variáveis como PIB *per capita*, grau de urbanização e escolaridade têm um efeito inverso.

No entanto, no trabalho de Gutierrez (2004), com dados para os estados brasileiros, alguns resultados encontrados em Kume (2004) não foram corroborados. Enquanto a desigualdade é confirmada como fator relevante para explicar positivamente a criminalidade, a taxa de urbanização, ao contrário, teria um efeito positivo sobre a criminalidade. Alguns resultados adicionais, como o efeito da redução da criminalidade associado a maiores gastos estaduais com segurança e a inexistência de relação entre pobreza e crime também foram encontrados nessa pesquisa.

Corroborando com os trabalhos que caracterizam a dinâmica dos homicídios, o trabalho de Carmo (2014) buscou compreender a dinâmica do crime contra o patrimônio, através da análise de furtos e roubos em Uberlândia (MG). Como resultado, mostraram-se significantes as variáveis número de domicílios (aumentando a criminalidade), preço da terra (aumentando a criminalidade) e idade média da população daquele município (reduzindo a criminalidade quanto maior a idade).

Fica evidente que não há um fator ou fatores específicos determinantes para o acontecimento do crime, podendo assim ser um conjunto de causas com diferentes níveis de influência, de acordo com a região ou o tempo analisado. Pode-se dizer que, o crime violento letal intencional é um fenômeno complexo e controverso quanto a sua predição e suas causas, uma vez que depende da ação humana para sua ocorrência, além da diversidade de fatores externos que podem influenciar ou não tal prática.

Contudo, Caplan e Kennedy (2010) apontam ainda que o risco surge em certos tipos de disposições, conhecidas por serem mais fortes e atraentes para a ocorrência de crimes. Logo, são nesses lugares que se encontram uma maior incidência de crimes. Em outras palavras, o crime emerge mais facilmente em locais onde há uma alta vulnerabilidade com base nas influências espaciais combinadas a vários recursos que induzem à criminalidade.

Nos estudos de Rogers e Pridemore (2013), a associação entre pobreza e homicídios foi testada em diferentes amostras, através da adoção de várias técnicas de estimação de modelos. Em todos os casos, encontrou-se a associação significativa entre a variável pobreza e a taxa de homicídios de forma consistente, ou seja, associação positiva entre pobreza e homicídios.

Os resultados destacam as condições socioeconômicas como fatores importantes para explicar a ocorrência de crimes, e sendo o fenômeno da seca um fator agravante das vulnerabilidades socioeconômicas nos municípios, que deteriora o emprego, aumenta as desigualdades e leva à corrosão das comunidades, interpreta-se que este somatório de desastres deve estar associado a maiores taxas de criminalidade.

2.3 O clima e a criminalidade

Os elementos climáticos são capazes de gerar diversos desconfortos, podendo levar a diversas respostas no organismo humano. Tais respostas envolvem abordagens, hipóteses e teorias diversificadas, cujos estudos são mais frequentes em países desenvolvidos. Apesar das diversas preocupações sobre os efeitos do ambiente nos organismos, algo que levou à consolidação da climatologia, pouco se tem desenvolvido a esse respeito (BRITO; FERREIRA, 2012).

Existe uma forte influência do clima na saúde do ser humano, sendo diversos os sintomas que muitas vezes são considerados simples reações orgânicas. A pressão atmosférica, o vento, a eletricidade atmosférica e a radiação provocam efeitos que são percebidos pelo indivíduo através de reações orgânicas. Fatores emocionais e neurológicos são responsáveis por grande parte de reações do corpo humano que podem ser alteradas por oscilações climáticas. Considera-se, então, que as reações negativas ou positivas podem surgir e modificar o psicológico do indivíduo, desencadeando reações de rara compreensão (MENDONÇA, 2000).

Os primeiros estudos que relacionaram o clima com a criminalidade datam do século XIX, por Adolphe Quetelet, criador da estatística criminal como campo de estudo e autor da obra “Física social” (QUETELET, 1835 apud PETEADO FILHO, 2012). Ao analisar os dados criminais da França, o referido autor considerou que as causas do delito estão relacionadas com fatores externos ao agente criminoso, como miséria, analfabetismo, clima, dentre outros. Quetelet instituiu que se o tempo se apresentar frio, o número de delitos contra o patrimônio recrudescer, enquanto reduz o número de crimes contra a pessoa. Porém, no verão, os delitos em desfavor da pessoa são levados a efeito com

mais frequência, em virtude do calor (QUETELET, 1835 apud PETEADO FILHO, 2012).

Nesse sentido, os primeiros trabalhos que tentaram verificar as relações do clima com a criminalidade tiveram como tema central a temperatura. Nesse aspecto, a Teoria da Atividade de Rotina (AR), o Modelo de Agressão por Escapamento Negativo (NAE) e o Modelo Geral de Agressão (GA) tentam explicar o comportamento criminoso mediante os efeitos das mudanças climáticas.

A Teoria da Rotina, do inglês *The Routine Activity* (RA), proposta por Cohen e Felson (1979), sugere que as mudanças nas atividades diárias das pessoas (que são diretamente causadas pela mudança climática) podem alterar a janela de oportunidade para a ação criminal, contudo requer a presença de três elementos: um agressor motivado, um alvo adequado e a ausência de segurança. Essa teoria é muitas vezes empregada para explicar como o clima afeta as taxas de crimes contra o patrimônio.

Já para explicar o comportamento agressivo entre pessoas, que tem como o desenrolar os crimes de lesão corporal intencionais e/ou letais, o Modelo de Agressão por Escapamento Negativo, do inglês *Negative Escape Aggression* (NAE), proposto por Bell (1992), reflete que os efeitos de moderadas elevações de temperatura facilitam o comportamento agressivo. Contudo, condições extremas de temperatura levam à fuga do indivíduo, ou seja, formando uma curva da intenção criminosa como um U invertido, à medida que a temperatura aumenta. Na mesma linha, Anderson e Anderson's (1998) afirma, com o Modelo Geral da Agressão, do inglês *General Affect* (GA), que as temperaturas mais altas facilitam a agressão efetiva, ou seja, quando se tem por objetivo causar alguma lesão letal a terceiros.

O debate sobre o clima e a criminalidade utiliza fortemente a temperatura como medida, como feito por Cohn e Rotton (2000a; 2000b; 2000c) na literatura internacional, e Mendonça (2001) e Brito e Ferreira (2012; 2013) na literatura nacional, sendo este último trazendo uma rápida abordagem entre a precipitação e a criminalidade. Contudo, já aparecem evidências de que seja possível relacionar a precipitação para explicar a criminalidade (JACOB, LEFGREN, MORETTI, 2007; HORROCKS, MENCLOVA, 2011; MARES, 2013;

HABIBULLAH, 2017; SOMMER *et al.*, 2018), inclusive o fenômeno da seca (GOIN; RUDOLPH; AHERN, 2017).

Horrocks e Menclova (2011), ao analisar o efeito do clima na criminalidade para 43 distritos da Nova Zelândia de 2000 a 2008, através da técnica de dados em painel, concluíram que a precipitação é significativa apenas para os crimes violentos, tendo uma fraca relação entre os crimes contra a propriedade nos distritos, contudo, a temperatura mostrou-se com maior relação.

No trabalho de Mares (2013), foram estudadas as anomalias na precipitação sobre as taxas de criminalidade da cidade de *St. Louis*, no estado de (EUA), de 1990 a 2009, analisando-se como o crime se comportava à medida que a taxa de precipitação se desviava da média mensal. Com o uso de séries temporais, foi encontrada uma relação negativa e significativa, tanto para crimes letais quanto para roubos, furtos e outros contra o patrimônio, encontrando uma redução de mais de 6% nesse último a cada aumento de uma polegada na média de precipitação.

Através do modelo generalizado de correlação de erros e controlando por população e desemprego, Habibullah (2017) também trabalhou sobre a pluviosidade, além da temperatura, para encontrar seus efeitos sobre a criminalidade na Malásia, de 1973 a 2009. O trabalho mostrou que existe uma relação de longo prazo negativa entre os crimes totais e a precipitação, assim como entre os crimes contra o patrimônio e a precipitação.

O trabalho de Blakeslee e Fishman (2017) teve uma proposta parecido com a do presente estudo, o qual verificou o efeito da seca e do calor nas múltiplas categorias de crime e na agricultura para a Índia, de 1971 a 2000, usando as estações/moções mais chuvosas do ano, que consiste na quantidade sazonal, como parâmetro climático para análise. Os resultados mostraram que, para ambos os choques, positivos ou negativos para a seca, medidos pela pluviosidade, é possível constatar alterações nas taxas de criminalidade, tanto quanto na agricultura e na renda, sendo os efeitos positivos do clima duplicados em relação aos crimes contra o patrimônio.

Vale ainda destacar o trabalho de Goin; Rudolph e Ahern (2017), que estudou a seca que assolou o estado da Califórnia (EUA), de 2011 a 2015. Os autores buscaram encontrar o efeito do fenômeno nas taxas de criminalidade, tanto para o patrimônio, quanto para os crimes violentos, a partir do método de

identificação por controle sintético. Para os resultados, foi encontrado um aumento significativo dos crimes contra o patrimônio no período, e nenhum efeito para os crimes violentos.

Do que se expõe, entende-se que o clima e a criminalidade podem estar ligados de diversas maneiras a diferentes localidades. Nesse sentido, a partir da literatura apresentada, e munido de evidências empíricas que mostram os diversos efeitos das mudanças climáticas sobre as taxas de criminalidade, pode-se partir para a análise do objetivo que se pretende identificar no presente trabalho.

3. Metodologia e descrição dos dados

A metodologia empregada neste trabalho está baseada no modelo teórico apresentado na revisão bibliográfica, bem como nos trabalhos empíricos que relacionam criminalidade e mudanças climáticas através de modelos econométricos. Além de tratar sobre os dados utilizados neste trabalho, inclusive quanto ao uso de métricas climatológicas, o presente capítulo apresentará as estratégias econométricas baseadas em dados em painel e painel com efeitos espaciais, utilizadas para atingir os objetivos propostos.

3.1 Base de dados

Os dados utilizados no presente trabalho provêm de fontes diversas a fim de permitir observar o efeito das variáveis explicativas relativas às condições econômicas, sociais e demográficas sobre dois indicadores de crime, Crimes Violentos Letais Intencionais (CVLI) e Crimes Violentos contra o Patrimônio (CVP), para os 185 municípios do estado de Pernambuco, no período de 2011 a 2016. O Quadro 1 descreve as variáveis consideradas nesse estudo e suas respectivas fontes de dados.

O cenário de estudo do presente trabalho é o Estado de Pernambuco, o qual apresenta uma superfície territorial de 98.146,3 Km², localizado na região Nordeste do Brasil. Conforme o IBGE (2018), Pernambuco tem uma população estimada de 9.496.294 habitantes, distribuída em 185 municípios, a contar com a Ilha de Fernando de Noronha. A capital pernambucana é a cidade do Recife, e sua Região Metropolitana têm o total de 4.046.845 habitantes.

Para análise e avaliação dos resultados, levou-se em consideração a divisão administrativa dos municípios de Pernambuco e as mesorregiões do Estado, que compreendem vários municípios de uma área geográfica, com características relativas ao processo social, como determinante; o quadro natural, como condicionante; e a rede de comunicação e de lugares, como elemento da articulação espacial (IBGE, 2015). Precisamente, o presente trabalho busca-se compreender os efeitos totais, diretos e indiretos para os municípios, verificando-se efeitos isolados ou de vizinhança para essas localidades.

Quadro 1 – Definição e fonte das variáveis

Dependente	Características	Fonte
Crimes patrimoniais (<i>CVP</i>)	Quantitativo de crimes contra o patrimônio a cada 100 mil habitantes. Para o ano de 2011 a 2016.	Secretaria de Defesa Social de Pernambuco (SDS/PE, 2019)
Crimes Letais (<i>CVLI</i>)	Quantitativo de crimes de homicídios a cada 100 mil habitantes. Para o ano de 2011 a 2016.	
Independentes	Características	Fonte
Variável dependente defasada (CVP_{t-1})	Quantitativo de crimes contra o patrimônio a cada 100 mil habitantes defasada em $t - 1$ período. Para o ano de 2011 a 2016	Secretaria de Defesa Social de Pernambuco (SDS/PE, 2019)
Variável dependente defasada ($CVLI_{t-1}$)	Quantitativo de crimes de homicídios a cada 100 mil habitantes defasada em $t - 1$ período. Para o ano de 2011 a 2016	
<i>Proxy</i> para educação – (<i>Educ</i>)	Índice construído pela assistência à educação, abandono do ensino, distorção idade-série do ensino, docentes com ensino superior, média de horas aulas diárias e resultado do IDEB (todos relacionados ao ensino fundamental). O índice varia de 0 a 1 (quanto mais próximo de 1 melhor o desempenho do município). Período de coleta de 2011 a 2016.	Índice Firjan de Desenvolvimento Municipal – Educação (FIRJAN, 2019)
<i>Proxy</i> para emprego e renda – <i>Emp&Ren</i>	Índice construído pela geração de emprego formal, taxa de formalização do trabalho, geração de renda, massa salarial real do mercado de trabalho e índice de Gini do trabalho para o mercado formal. O índice varia de 0 a 1 (quanto mais próximo de 1 melhor o desempenho do município). Período de coleta de 2011 a 2016.	Índice Firjan de Desenvolvimento Municipal – Renda (FIRJAN, 2019)
Densidade demográfica (<i>Dens</i>)	População dividida pela área total do município (km ²). Dados para o ano de 2011-2016	Banco de Desenvolvimento do Estado de Pernambuco (CONDEPE-FIDEM, 2019)
PIB Per capita (<i>PIBpc</i>) ⁵	O Produto Interno Bruto Municipal dividido pela população total de cada município. Dados para os anos de 2011 a 2016	Banco de Desenvolvimento do estado de Pernambuco (BDE, 2019)
Índice de Precipitação Padronizada (<i>SPI3</i>)	Índice de Precipitação Padronizada para os três meses mais chuvosos do ano (SPI-3), índice usado para definir se o município está em SECA ou não, varia de -2 a 2, sendo -2 muito seco e 2 muito úmido. Período entre os anos de 2011 e 2016.	Índice construído a partir dos dados da Agência Pernambucana de Águas e Clima (APAC, 2019)

Fonte: elaboração própria.

⁵ Esta variável foi introdução e sua estimação tem finalidade de efeito de comparação uma vez substituída pela variável *Emp&Ren*, o resultado dessa estimação encontra-se em anexo.

Quanto aos dados, foram coletadas variáveis referentes aos municípios para os anos de 2011 até o ano de 2016, dado o acesso a dados tanto para criminalidade, quanto referente à maior disponibilidade de informações pluviométricas, que coincide com o período de último ciclo de seca para o estado. Como já destacado, as variáveis a serem explicadas, uma para cada equação, referem-se à taxa de homicídios e à taxa de crime contra o patrimônio⁶, que podem ser vistas como *proxies* para os índices de criminalidade.

Quatro variáveis explicativas consideram refletir os fatores condicionantes da violência e entram nesse trabalho como controle: "*Crimes*"_{*t-1*}⁷, *Rend*, *Educ* e *Dens*. Nesse sentido, foram incluídas variáveis que representam condições socioeconômicas, demográficas e referentes ao sistema de segurança pública⁸, indicativas como condicionantes ao crime por Kume (2004) Gutierrez (2004) e Lima *et al.*, (2005) para controles⁹.

Particularmente como variável explicativa de interesse, com o intuito de distinguir os municípios que manifestaram seca para cada ano *i*, foi utilizado o Índice de Precipitação Padronizado (SPI), conforme aplicado em diversos trabalhos da área de climatologia (COSTA, 2011; SILVA *et al.*, 2013; FECHINE, 2015). Referido método observa a distribuição de probabilidades da precipitação, identificando-se os municípios que registraram pluviosidade abaixo de sua

⁶ Apesar do possível problema de subnotificação de relatos de roubos, este trabalho assume que a utilização de dados em painel pode minimizar esse problema ao remover o efeito fixo potencialmente correlacionado com os regressores. Assumindo a hipótese de que o percentual de subnotificação é semelhante entre os municípios, bem como que esse percentual não varia consideravelmente ao longo do tempo.

⁷ A variável se refere a *CVLI*_{*t-1*} na equação que tem CVLI como variável dependente, e a *CVP*_{*t-1*} na equação de CVP.

⁸ Uma vez tendo a limitação da falta de variáveis próprias do sistema de segurança, a variável dependente defasada tenta reduzir essa falta de informações uma vez que o modelo de Becker assume que maiores índices de criminalidade devem aumentar os gastos da atividade policial. Além disso a variável pode captar a possibilidade da presença do "efeito inércia" nas taxas de crimes que se dá em função da aprendizagem e especialização na atividade criminosa ao longo do tempo, ocasionando a transferência do crime de um período para outro (KUME, 2004).

⁹ É importante complementar que outras variáveis explicativas difundidas na literatura (a exemplo de desigualdade de renda) não foram tratadas neste trabalho pela indisponibilidade de dados municipais em todos os anos da série estudada. Contudo, deve-se também ressaltar que a variável *Rend* chega a captar todas essas informações em um só indicador, ou seja a geração de renda e a empregabilidade.

probabilidade histórica. Nesse aspecto, conforme Wilks (2006), recomenda-se o uso da função Gama para representar a distribuição das precipitações:

$$G(x) = \frac{1}{\Gamma(\gamma) \cdot \beta^\gamma} \cdot \int_0^x x^{\gamma-1} \cdot e^{-x/\beta} dx \quad (3.1)$$

Em que: $G(x)$ é a função de distribuição acumulada; x é a precipitação observada em dado intervalo de tempo; γ é o parâmetro de forma da distribuição Gama¹⁰; β é o parâmetro de escala da distribuição Gama¹¹; e $\Gamma(\gamma)$ é a função Gama do parâmetro γ ¹².

Dessa maneira, cada observação em dado município retornará um valor $G(x)$. Como cada município possui características particulares, os valores de $G(x)$ devem ser normalizados para $Z[G(x)]$ ¹³. Assim, para cada município, o conjunto de dados $G(x)$ deve ser transformado para $Z[G(x)]$, passando este a apresentar média nula e variância unitária. Tal resultado corresponde ao inverso da função de probabilidade da distribuição Normal-Padrão, dado por $\Psi^{-1}[G(x)]$, o qual finalmente determina o valor calculado do Índice de Precipitação Padronizado (SPI), ou seja:

$$SPI = \Psi^{-1}[G(x)] \quad (3.2)$$

Conforme orienta McKee et al. (1993), classifica-se o SPI em categorias que indiquem a condição de pluviosidade no município no dado intervalo de tempo, segundo definição exposta no quadro a seguir.

¹⁰ Seguindo Thom (1966), o parâmetro α pode ser calculado pelo método de verossimilhança, determinado por $\hat{\gamma} = \frac{1}{4 \cdot A} \cdot \left(1 + \sqrt{1 + \frac{4 \cdot A}{3}} \right)$, com $A = \ln(\bar{x}) - \left[\frac{1}{n} \cdot \sum_{i=1}^n \ln(x_i) \right]$, em que x_i é a precipitação observada em dado intervalo de tempo e $\bar{x}$ é a média aritmética das precipitações observadas.

¹¹ Ainda conforme Thom (1966), o parâmetro β também pode ser calculado pelo método de verossimilhança, determinado por $\hat{\beta} = \bar{x} / \hat{\gamma}$.

¹² A função Gama do parâmetro α é expressa por $\Gamma(\gamma) = \int_0^\infty X^{\gamma-1} \cdot e^{-X} dX$.

¹³ Ao se considerar um conjunto de valores calculados de $G(x)$ para dado município, a normalização se dá por $Z[G(x)] = [G(x) - \overline{G(x)}] / \sigma_G$, em que $\overline{G(x)}$ é a média aritmética dos valores de $G(x)$ para referido município e σ_G é o desvio padrão de $G(x)$ para o mesmo município.

Quadro 2. Condições de pluviosidade segundo valores calculados do SPI3.

Valores do SPI	Condições de pluviosidade
$SPI \leq -2$	Extremamente seco
$-2 < SPI \leq -1,5$	Severamente seco
$-1,5 < SPI \leq -1$	Moderadamente seco
$-1 < SPI \leq -0,5$	Levemente seco
$-0,5 < SPI \leq 0,5$	Normal
$0,5 < SPI \leq 1$	Levemente chuvoso
$1 < SPI \leq 1,5$	Moderadamente chuvoso
$1,5 < SPI \leq 2$	Severamente chuvoso
$SPI > 2$	Extremamente chuvoso

Fonte: McKee et al. (1993).

Ainda, cabe salientar os diferentes métodos de análise propostos de acordo com critérios de corte temporal: i) SPI-3, quando se observa o registro de precipitação no município em seus três meses mais chuvosos do ano, o que reflete condições de pluviosidade de curto prazo; ii) SPI-6 e SPI-9, quando se observa, respectivamente, os registros nos seis meses e nos nove meses mais chuvosos do ano, o que reflete condições de médio prazo; e iii) SPI-12, quando se observa os registros de todo o ano, captando padrões de precipitação de longo prazo (ALBUQUERQUE, 2010; NDMC, 2017; ZARGAR *et al.*, 2011).

Para o presente trabalho, é apropriada a utilização do critério SPI-3, pois, em geral, o conjunto de municípios estudados apresenta apenas uma estação chuvosa ao longo do ano, o que corresponde a três meses. Dessa maneira, a indicação de que determinado ano foi seco ou não para certo município, leva em conta os registros de pluviosidade em seus três meses mais chuvosos. Caso essas observações, em determinado ano, apontem para registros abaixo de sua probabilidade histórica, indica-se que aquele período foi, portanto, considerado seco, em conformidade com as categorias listadas no Quadro 2.

Como discorrido, todo esse procedimento depende dos dados pluviométricos registrados nos municípios de interesse, ao longo do tempo. Tais informações encontram-se disponibilizadas pela Agência Pernambucana de Águas e Clima (APAC, 2019), em abrangente banco de dados que reúne registros de diversos postos de coleta distribuídos nos municípios pernambucanos. Nesse aspecto, o horizonte temporal analisado compreende o

período de 1º de janeiro de 1990 a 31 de dezembro de 2018, com registros diários coletados em 541 diferentes postos distribuídos nos 185 municípios pernambucanos. Salienta-se a existência de municípios que contam com mais de um posto de coleta pluviométrica e, nesses casos, é apropriado considerar a precipitação média de tais registros. Ainda, cabe ressaltar a ocorrência de postos que foram desativados ao longo do tempo analisado, seja de forma temporária ou mesmo permanentemente. Particularmente nesses períodos, portanto, é recomendável descartar tais postos da análise.

Resumidamente, o cálculo do SPI, desde a consolidação da base de dados utilizada, compreende a seguinte estratégia: i) obtenção dos registros pluviométricos diários de 541 diferentes postos distribuídos nos 185 municípios pernambucanos, entre 1º de janeiro de 1990 e 31 de dezembro de 2018; ii) cálculo da média de registros nos municípios com mais de um posto de coleta; iii) soma dos registros diários para obtenção da precipitação mensal de cada município; iv) descarte das observações cujo número de coletas mensais é inferior ao número médio de coletas mensais realizadas em todo o estado¹⁴; v) identificação do trimestre historicamente mais chuvoso de cada município, considerando suas médias históricas mensais de precipitação; vi) soma dos registros mensais no trimestre historicamente mais chuvoso de cada município, para obtenção dos dados que servirão ao cálculo da função de distribuição acumulada $G(x)$; e vii) normalização dos dados através de $Z[G(x)] = \Psi^{-1}[G(x)]$, o que determina o valor calculado para SPI-3.

Finalmente, produz-se uma matriz formada por i municípios e t anos analisados. Internamente, encontram-se os valores calculados para $SPI-3_{it}$ e, a partir das categorias listadas no Quadro 2, pode-se interpretar se determinado ano, para dado município, pode ou não ser considerado seco. Note-se que, através dessa abordagem, a ocorrência ou não de um ano de estiagem, em dado

¹⁴ Em determinado mês, dentro de todo o horizonte temporal estudado, certo município pode não contar com registros diários suficientes para determinar sua precipitação com confiança. Por exemplo, imagine-se que um município conte com apenas um posto de coleta e que este ficou temporariamente desativado, entre 29 de janeiro de 1995 e 10 de junho de 1995. Dessa forma, para esse município, as observações de fevereiro de 1995 a maio de 1995 são tratadas como não avaliadas, já que não houve nenhuma coleta nesse período. Por sua vez, o mesmo deve ser feito para junho de 1995, visto que se passaram dez dias sem coleta, prejudicando o cômputo da precipitação mensal. Por fim, no caso de janeiro de 1995, este pode ser tratado como confiável, visto que houve registro em 29 dos 31 dias compreendidos naquele mês.

município, é avaliada com base nas observações registradas em seus três meses historicamente mais chuvosos.

Nesse sentido, a Tabela 1 apresenta as estatísticas descritivas das variáveis que serão utilizadas para a modelagem econométrica.

Tabela 1 – Estatísticas descritivas das variáveis utilizadas

<i>Variável</i>	<i>Descrição</i>	<i>Média</i>	<i>DP</i>
<i>CVP</i>	Taxa de crime patrimonial por 100 mil habitantes	296,36	338,52
<i>CVLI</i>	Taxa de homicídios por 100 mil habitantes	34,76	22,17
<i>Educ</i>	Indicador de educação básica	0,6593	0,0762
<i>Emp&Ren</i>	Indicador de emprego e renda	0,4553	0,1275
<i>Dens</i>	Taxa de densidade (área/população)	0,2567	0,9291
<i>Pibpc</i>	PIB <i>Per Capita</i>	11668,46	10221,95
<i>SPI3</i>	Índice de Precipitação Padronizada	-0,1579	0,9177

Fonte: elaboração própria.

3.3 Modelo econométrico

O modelo de dados em painel consiste na integração de informações de corte transversal (*cross-section*) e séries temporais, o que permite uma modelagem mais robusta que capta os efeitos não identificados nos métodos de corte transversal, além de outras vantagens, como a elevação dos graus de liberdade, a eficiência do estimador, aumento das considerações de variações, redução da colinearidade entre os dados e redução dos erros por omissão das variáveis relevantes da região fixa no tempo (MALASSIE; PARRÉ; FRAGA, 2015). Outras vantagens de seu uso são a menor variabilidade intra-observação, a possibilidade de captar a relação dinâmica entre indivíduos, o fato de um mesmo indivíduo ser controle e submetido a diferentes tratamentos em diferentes momentos (algo que limita o uso de modelos de *Propensity Score Matching* na presente pesquisa), além da característica de captar o movimento no tempo dos valores observados para cada observação de maneira transversal.

Os modelos de regressão linear buscam identificar o impacto de uma determinada variável de interesse sobre o comportamento médio de uma dada variável dependente. Ao estimar uma equação em dados em painel, deve-se identificar o modelo mais adequado, cuja escolha depende primordialmente do

efeito individual. A versão mais simples de dados em painel, contém apenas um intercepto para todos os indivíduos, de forma que o método de Mínimos Quadrados Ordinários (MQO) fornece estimadores eficientes e consistentes (GREENE, 2008).

Em geral, porém, os modelos de dados em painel apresentam heterogeneidade individual, ou seja, diferenças nas características individuais que causam efeito não observável, conhecido por Efeito Fixo. A maneira usual de estimar consistentemente os parâmetros do modelo, diante da existência do efeito fixo, é através do Estimador de Efeitos Fixos. Essa metodologia tem sido amplamente empregada nas análises econométricas como maneira de tratar a questão da heterogeneidade não observada, uma vez que o estimador de MQO torna-se inconsistente neste contexto (HSIAO, 2003).

É possível também que as características individuais não estejam correlacionadas com os regressores e seu comportamento seja puramente aleatório. Nesse caso, a estimação é feita introduzindo a heterogeneidade individual no termo de erro, obtendo-se o modelo de Efeitos Aleatórios. Logo, tanto o estimador de MQO, quanto o de Efeitos Fixos, produzem estimativas consistentes dos parâmetros de interesse, mas não são eficientes em comparação ao estimador de Efeitos Aleatórios (UCHOA; MENEZES; 2012).

Além dessas questões, é plausível acreditar que quando se considera a existência de efeitos espaciais, essa dependência ocorre geralmente em níveis mais desagregados, como municípios, bairros, cidades etc. Não diferente dessa ideia, a abordagem da criminalidade traz o fenômeno com um aspecto temporal e de espaço, dada a dinâmica da criminalidade que pode ser tanto de migração interestadual quanto intermunicipal, principalmente com a observação do processo contínuo de interiorização da violência verificada por Waiselfisz (2011), após a década de 1990, principalmente nas regiões Norte e Nordeste do Brasil.

Nesse sentido, parte-se da ideia de que os dados espaciais possuem duas importantes características, a autocorreção espacial e a heterogeneidade espacial. A primeira assume que os dados possuem interdependência espacial, podendo haver um efeito transbordamento (*spillovers*) de determinadas atividades ou fatores, enquanto a segunda assume que os diferentes indivíduos têm suas individualidades que geram erros heterocedásticos. De maneira geral,

uma mistura desses dois efeitos está presente quando se trabalha com dados em painel (MOREIRA e FACHEZATTO, 2018).

A econometria espacial considera que há dependência espacial entre as unidades, exigindo que se faça uma adaptação nos modelos para captar prováveis presenças de dependência. Nesse sentido, o painel espacial visa tratar essa possível autocorrelação e heterogeneidade espacial, de forma que o modelo é projetado para captar essas diferentes médias e heterogeneidades ao longo do espaço, englobando todas as vantagens de um estudo em dados em painel.

Uma das formas de levar a estrutura espacial aos dados em consideração é por meio da matriz de vizinhança W ¹⁵ que tenta captar o grau de conectividade entre as observações de várias maneiras distintas.

Dessa forma, após a estimação do painel tradicional, faz-se o teste de verificação de autocorrelação espacial do modelo, o que pode ser feito através do teste do índice I de Moran¹⁶, ou pelo teste de multiplicador de Lagrange de defasagem espacial e do erro espacial.

O modelo geral de dados empilhados é dado por:

$$y_t = \alpha + \rho Wy + X\beta + WX\theta + \mu \quad (3.3)$$

$$\mu = \lambda W\mu + \epsilon$$

Em que Wy é a defasagem espacial da variável dependente e denota os efeitos de interação endógena entre as variáveis dependentes, WX é a defasagem espacial das variáveis explicativas e denota os efeitos de interação exógena entre as variáveis independentes, $W\mu$ é a defasagem espacial do erro e denota efeitos de interação entre os termos de erro das diferentes unidades, enquanto λ , e ρ são os parâmetros espaciais, e θ é o vetor de coeficiente espacial.

Nesse sentido, uma forma de tratar a endogeneidade é impor restrições aos parâmetros espaciais presentes nos modelos com dependência

¹⁵ A matriz de pesos espaciais serve para captar os efeitos espaciais e pode ser binária, de vizinhos mais próximos ou utilizar alguma medida de distância entre os municípios vizinhos.

¹⁶ Segundo LeSage (1999), o cálculo de Teste I de Moran é definido por $I = \frac{N(y-\bar{y})'W(y-\bar{y})}{S(y-\bar{y})'(y-\bar{y})}$, em que S é a soma de todos os elementos da matriz W e N é a dimensão de W . Mais detalhes a respeito do índice I de Moran serão dispostos no próximo tópico.

espacial, cujos modelos usuais são o Modelo Autorregressivo Espacial (SAR), o Modelo de Erros Autorregressivos (SEM) e o *Modelo Durbin Espacial* (SDM).

Um dos modelos mais comumente utilizados para modelagem de correlação espacial é o modelo autorregressivo espacial, ***spatial autorregressive model (SAR)***. A ideia dos modelos SAR é incorporar um termo de *lag* entre os regressores da equação. Na sua forma mais simples, o modelo SAR tem expressão:

$$Y = \rho WY + X\beta + \epsilon \quad (3.4)$$

Em que Y é um vetor coluna $n \times 1$ de observações da taxa de criminalidade, X é uma matriz $n \times k$ de observações das variáveis independentes, β é o vetor coluna $k \times 1$ de parâmetros, ϵ é um vetor $n \times 1$ de erros aleatórios independente e identicamente distribuídos e W é a matriz de vizinhança $n \times n$ de pesos espaciais exógenos, que define a relação de dependência entre as observações. O parâmetro autorregressivo ρ pode ser interpretado como um indicador da intensidade da dependência espacial, pois quando ele é igual a zero, a equação se torna um modelo de regressão linear padrão. Para evitar produzir estimativas inconsistentes, pode-se utilizar máxima verossimilhança, a partir da hipótese de que o vetor de resíduos ϵ possui distribuição normal multivariada com média nula e covariância $\sigma^2 I$ (CARVALHO; ALBUQUERQUE, 2010). Pode-se então escrever:

$$Y = (I - \rho WY)^{-1} X\beta + (I - \rho W)^{-1} \epsilon \quad (3.5)$$

Agora, o valor de Y depende tanto do valor de X da sua própria região como de como de todas as outras regiões, visto que o vetor de variáveis observadas Y possui distribuição condicional a X normal multivariada com média condicional a X e matriz de variância condicional a X ¹⁷.

¹⁷ Ver Carvalho e Albuquerque (2010).

Eventualmente, a estrutura de dependência espacial é evidenciada nos resíduos. Nesse caso, utiliza-se o **Spatial Error Model (SEM)**, cuja especificação típica é dada por:

$$Y = X\beta + \mu \quad (3.6)$$

$$\mu = \lambda W\mu + \epsilon, \epsilon \sim (0, \sigma^2 I) \quad (3.7)$$

Em que o parâmetro λ desempenha papel semelhante a ρ no SAR, ou seja, é o parâmetro espacial a ser estimado que mensura a relevância da estrutura autorregressiva. O W é a matriz vizinhança de pesos espaciais. Através da estimação do modelo SEM via máxima verossimilhança, combinando as expressões, tem-se que:

$$Y = X\beta + (I - \lambda W)^{-1} \epsilon \quad (3.8)$$

Esse modelo difere do anterior pela inclusão da defasagem espacial nos resíduos. A intuição nesse modelo é que os efeitos espaciais decorrem de choques aleatórios em determinadas regiões, afetando seus vizinhos e esses efeitos não são captados pelas demais variáveis.

Por sua vez, quanto ao **Spatial Durbin Model (SDM)** destaca-se que este pode ser especificado como:

$$Y = \rho WY + X\beta + WX\theta + \epsilon \quad (3.9)$$

Esse modelo difere do modelo SAR por incluir a defasagem espacial na variável explicativa juntamente com a defasagem espacial da variável independente.

3.4 Análise Exploratória de Dados Espaciais (AEDE)

A execução de AEDE pode ser efetuada a partir da utilização de medidas de avaliação globais ou locais de autocorrelação espacial, sendo esses indicadores o *I de Moran Global* e o *I de Moran Local*.

Nesse sentido, o indicador estatístico *I de Moran* pode ser representada como o grau de associação espacial presente nos dados. Formalmente, o *I de Moran Global* pode ser dado pela seguinte expressão:

$$I = \frac{N}{\sum_i \sum_j W_{ij}} \frac{\sum_i \sum_j W_{ij} (Y_{it} - \bar{Y}_t)(Y_{jt} - \bar{Y}_t)}{\sum_i (Y_{it} - \bar{Y}_t)^2} \quad (3.4.1)$$

Em que N é o número de regiões, W_{ij} são os elementos da matriz de pesos espaciais (W)¹⁸, Y_{it} é a observação na região i no período t , e $\bar{Y}_t$ é a média das observações entre as regiões no período t . A estatística varia entre -1 e 1.

A análise da autocorrelação espacial local, por sua vez, pode ser efetuada utilizando-se o *I de Moran Local*, que é um indicador do tipo LISA (*Local Indicator of Spatial Association*). Segundo Anselin (1995), o *I de Moran Local* fornece indicação de *clusters* ou agrupamentos espaciais significativos de valores semelhantes em torno de certa observação. Para cada observação e período, o *I de Moran Local* pode ser expresso por:

$$I_i = \frac{N(Y_{it} - \bar{Y}_t) \sum_j W_{ij} (Y_{jt} - \bar{Y}_t)}{\sum_j (Y_{it} - \bar{Y}_t)^2} \quad (3.4.2)$$

Em que 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 anterior. Valores positivos do índice *devem* indicar presença de agrupamentos de valores similares entre si. Por outro lado, valores negativos indicam presença de agrupamentos de valores relativamente dissimilares. A melhor maneira de interpretar a estatística *I de Moran Local* é através do mapa de clusters, considerando-se os seguintes tipos de associação espacial: i) os *clusters* Altos-Alto, cujas regiões apresentam alto valor da variável em estudo circundadas por uma vizinhança em que o valor médio da mesma variável

¹⁸ Conforme Anselin (1995), a matriz W contempla as informações referentes à dependência espacial entre as N regiões i . Os elementos w_{ij} indicam a associação espacial entre as regiões i e j , sendo os elementos na diagonal principal iguais a zero. Nesse caso, a matriz utilizada no presente trabalho foi a Queen de primeira ordem.

também é alto; ii) *clusters* Baixo-Baixo, cujas regiões apresentam baixo valor da variável em estudo circundadas por uma vizinhança em que o valor médio da mesma variável também é baixo; e iii) os *outliers* Baixo-Alto e Alto-Baixo. Nesse contexto, a Análise Exploratória de Dados Espaciais (AEDE) deve funcionar como ponto de apoio para estimações econométricas, pois possibilita *ex ante* a constatação de indícios de autocorrelação espacial, sendo que tal fato é devidamente confirmado apenas a partir das estimações dos modelos espaciais.

4. Resultados

Este capítulo é destinado à análise dos resultados, com o objetivo de demonstrar a importância do espaço, juntamente com os fatores demográficos e socioeconômicos na compreensão do comportamento das taxas de criminalidade, diante do fenômeno climático da seca, procurando captar seus efeitos diretos e indiretos

4.1 Análise Exploratória de Dados Espaciais (AEDE)

O objetivo desta seção é avaliar se há autocorrelação espacial na variável dependente, ou seja, em cada caso, nas taxas de homicídios e crimes patrimoniais. Para tanto, o primeiro teste geral para identificação de autocorrelação espacial é a estatística *I de Moran*.

A tabela a seguir reporta os resultados da AEDE, realizada por meio do diagrama¹⁹ de dispersão do *I de Moran Global*, enquanto as figuras posteriores trazem os mapas criados pelo *Local Indicator of Spatial Association* (LISA) univariado das taxas de criminalidade observadas nos municípios pernambucanos, entre 2011 e 2016²⁰.

Tais indicadores apontam se há indícios de autocorrelação espacial agindo sobre os dados. Para tanto, considerou-se uma matriz de contiguidade espacial do tipo *Queen* de primeira ordem, normalizada na linha. Os quadrantes do *I de Moran Global*²¹ são: Q1 (Alto-Alto, AA), Q2 (Alto-Baixo, AB), Q3 (Baixo-Baixo, BB) e Q4 (Baixo-Alto, BA). Realizando-se um teste de hipótese via 999 permutações dos valores do *I de Moran Global*, é possível rejeitar, a 5% de pseudo-significância, a hipótese nula de aleatoriedade espacial em todos os períodos considerados. Dessa forma, essa estatística aponta indícios de dependência espacial da criminalidade.

¹⁹ Os diagramas podem ser visualizados em apêndice.

²⁰ Os mapas temáticos obtidos a partir do LISA são compostos por cinco cores distintas, cada qual representando um tipo de associação espacial: Vermelha (Alto-Alto), Azul (Baixo-Baixo), Azul-claro (Baixo-Alto), Rosa (Alto-Baixo) e Cinza (Não Significativo). Detalhes sobre o LISA estão dispostos em apêndice.

²¹ Os mapas de quadrantes, bem como as significâncias para os mapas de cluster, encontram-se em apêndice.

Tabela 2 - Estatística *I de Moran Global* para crimes patrimoniais (CVP) e homicídios (CVLI).

	<i>I de Moran para CVP</i>	<i>I de Moran para CVLI</i>
2011	0,435	0,206
2012	0,615	0,172
2013	0,562	0,198
2014	0,614	0,344
2015	0,544	0,337
2016	0,544	0,272


Fonte: elaboração própria através do software Geoda.

Nota-se que os resultados apresentados pelo LISA (FIGURAS 2 e 3) são capazes de confirmar localmente a incidência de autocorrelação espacial já constatada por meio do indicador global. Portanto, tem-se que a autocorrelação espacial vigente nas taxas de criminalidade foi comprovada tanto global quanto localmente, sendo um forte indício para se acreditar em uma distribuição espacial não aleatória da criminalidade.

Pode-se perceber que, conforme os anos vão passando, tanto a relação Alto-Alto quanto o Baixo-Baixo, mostram indícios de que seguem determinado processo de atração espacial, ficando cada vez mais próximos entre si. Além disso, constata-se um aumento da relação Alto-Alto que sai do Litoral e se expande para o Agreste, enquanto a relação Baixo-Baixo é expandida para as regiões do Sertão, uma relação de espacialidade do crime que anteriormente não se verificava, como é no caso da imagem do ano de 2011.

Para as taxas de crimes patrimoniais verificou-se uma forte relação da expansão Baixo-Baixo nos municípios do Sertão, enquanto para as taxas de homicídios verificou-se uma expansão espacial da criminalidade nos municípios do Agreste, corroborando com a afirmação de expansão da criminalidade ao interior observada anteriormente por Waiselfisz (2011). Vale ressaltar que nessas regiões, cuja expansão espacial da criminalidade foi observada, o fenômeno da seca mostra-se com maior expressividade. Nota-se ainda que as demais relações não demonstram grande importância, se expressando sobre a forma de pequenos grupos, formados por pontos praticamente isolados ao longo dos anos.

Figura 2- Mapa de cluster (LISA) referente à taxa de crimes patrimoniais.




Fonte: Elaboração própria a partir do software GeoDa, desenvolvido por Anselin et al. (2006).

Nota 1: P-valor = 0,05.

Nota 2: Pseudo-significância baseada em 999 permutações randômicas.

Figura 3 - Mapa de cluster (LISA) referente à taxa de homicídios.



Fonte: Elaboração própria a partir do software GeoDa, desenvolvido por Anselin et al. (2006).

Nota 1: P-valor = 0,05.

Nota 2: Pseudo-significância baseada em 999 permutações randômicas.

4.2 Estimação do modelo empírico

Neste trabalho, estimam-se modelos de dados em painel e painel com dependência espacial, com o objetivo de estudar os efeitos da seca na criminalidade dos 185 municípios pernambucanos, no período de 2011 a 2016. Como anteriormente colocado, a escolha do período de análise considerou dois fatores: o primeiro versa sobre a disponibilidade de dados para a criminalidade no estado; e o segundo sobre a maior disponibilidade de coleta pluviométrica nos municípios do estado.

Os modelos econométricos para dados em painel e com efeitos espaciais, empiricamente, são divididos em duas abordagens: uma primeira equação tendo a taxa de crimes patrimoniais (CVP) como variável dependente; e outra tendo como variável dependente a taxa de homicídios (CVLI) no estado de Pernambuco.

$$CVP = \beta_0 + \beta_1 Tx CVP_{t-1} + \beta_2 Educ + \beta_3 Emp\&Ren + \beta_4 Dens + \beta_5 SPI3 + \varepsilon \quad (4.1)$$

$$CVLI = \beta_0 + \beta_1 Tx CVLI_{t-1} + \beta_2 Educ + \beta_3 Emp\&Ren + \beta_4 Dens + \beta_5 SPI3 + \varepsilon \quad (4.2)$$

Nessas expressões, cada observação representa a informação relativa à variável considerada para o município $i = 1, \dots, n$ no ano $t = 1, \dots, T$. Desse modo, a base de dados é formada por observações dos 185 municípios pernambucanos entre os anos de 2011 e 2016, perfazendo um total de $nT = 1.110$ observações.

No que se refere à criminalidade contra o patrimônio (Tabela 3), quanto aos estimadores *Pooling*, percebe-se que são significativos os valores estimados para os coeficientes associados a criminalidade passada, educação, renda, densidade e pluviosidade padronizada. Por sua vez, os resultados para os estimadores de Efeitos Fixos mostram uma pequena alteração na magnitude e na significância dos coeficientes. Observando-se ainda a Tabela 3, resultados semelhantes são encontrados para os estimadores de Efeitos Aleatórios, mas a variável *Emp&Ren* perde sua significância. Salienta-se que os resultados para o Teste de Chow e Teste de Breush-Pagan rejeitam a preferência pelos estimadores *Pooled*. Por sua vez, o Teste de Hausman rejeita a preferência pelos estimadores de Efeitos Aleatórios, em favor dos estimadores de Efeitos Fixos. Nesse sentido, a análise pelo modelo de Efeitos Fixos seria mais adequada.

De toda forma, em todas as estimações, os coeficientes estimados para a variável de interesse (SPI3) se mostraram significativos e negativamente relacionados com a taxa de crimes patrimoniais (CVP). Portanto, maiores níveis de pluviosidade padronizada levariam à redução do CVP, o que indica que situações de seca (consistentes com valores negativos para SPI3) estão associadas a maiores taxas de Crimes patrimoniais.

Contudo, para os resultados relativos aos crimes de homicídios no estado, não se verificou significância nessa relação, seja para os estimadores

Pooling, Efeitos Fixos ou Efeitos Aleatórios, de forma que outras variáveis explicam a criminalidade letal no estado, que não a seca²².

Tabela 3 - Resultados para estimações para dados em painel: crimes patrimoniais

Variável	<i>Pooling</i>		<i>EF</i>		<i>EA</i>	
	Estimativas	P>(z)	Estimativas	P>(z)	Estimativas	P>(z)
<i>Constante</i>	-259,825	0,003***	-593,94	0,051*	-280,009	0,005***
<i>CVP(t - 1)</i>	0,5745	0,000***	0,531	0,014**	0,4291	0,000***
<i>Educ</i>	454,78	0,000***	805,57	0,000***	680,008	0,000***
<i>Emp&Ren</i>	171,048	0,016**	-429,72	0,000***	-30,386	0,686
<i>Dens</i>	90,161	0,000***	1408,2	0,093*	117,193	0,000***
<i>SPI3</i>	-36,984	0,000***	-35,79	0,001***	-40,554	0,000***
R ²	0,4818		0,2743		0,1276	
OBS		906	906			
Teste Chow			6,63***			
Teste Breusch-Pagan					121,37***	
Teste Hausman			2113,16***			
Teste Wald			3900,00***			

Fonte: elaboração própria.

Nota 1: *** 1% de significância, ** 5% de significância, * 10% de significância.

Nota 2: Para os modelos de Efeitos Fixos e Efeitos Aleatórios é utilizado o R² do *within groups*.

Os resultados então apresentados desprezam a questão espacial do fenômeno estudado. Dessa forma, pode-se incorrer no problema de viés de variável omitida. Para checar se, de fato, o espaço importa, aplicou-se o teste / *de Moran*, como discutido anteriormente. 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 informações é seguir com a estratégia de estimar através

²² As regressões para crimes de homicídios encontram-se em apêndice.

do método de Máxima Verossimilhança, seguindo os procedimentos propostos por Belotti *et al.*, (2013) e Belotti *et al.*, (2016) para painel desbalanceado²³.

Basendo-se na estratégia de Elhorst (2010) e Belotti *et al.*, (2013), inicialmente é estimado o modelo mais geral (SDM), que inclui a matriz de vizinhança na variável dependente e nas independentes. Em seguida, através de testes de razão verossimilhança, testa-se a hipótese $H_0 : \theta = 0$ na equação (3.9). Caso a hipótese nula seja aceita, o SDM pode ser reduzido para o modelo SAR. Por sua vez, se $H_0 : \theta + \rho\beta = 0$ for aceita, o SDM será simplificado para o SEM.

Tabela 4 - Estimativas para dados em painel espacial com efeito fixos: crimes patrimoniais.

Variável	SDM		SAR		SEM	
	Estimativas	P>(z)	Estimativas	P>(z)	Estimativas	P>(z)
<i>CVP(t - 1)</i>	0,1029	(0,000)***	0,1083	(0,000)***	0,0998	(0,000)***
<i>Educ</i>	549,70	(0,001)***	759,13	(0,000)***	879,73	(0,000)***
<i>Emp&Ren</i>	-219,52	(0,002)***	-317,69	(0,000)***	-355,18	(0,000)***
<i>Dens</i>	1331,74	(0,000)***	1412,58	(0,000)***	1450,58	(0,000)***
<i>SPI3</i>	-12,01	(0,062)*	-17,38	(0,003)***	-15,22	(0,023)***
ρ	0,4079	(0,000)***	0,7115	(0,000)***		
λ					0,7238	(0,000)***
OBS	1110		1110		1110	
<i>Loglikelihood ratio</i>			7,17***			
<i>Loglikelihood ratio</i>					14,23***	

Fonte: elaboração própria. Nota: *** 1% de significância, ** 5% de significância, * 10% de significância.

Do que se apresenta, todos os modelos espaciais corroboram com a hipótese levantada nesse trabalho, de que o fenômeno da seca eleva as taxas

²³ Essa estratégia resolve o problema de *missing* por imputação múltipla, que é o processo de substituir valores ausentes por vários conjuntos de valores plausíveis. No pacote Stata, utilizado nesta pesquisa, esse procedimento se dá pelo comando *xsmle*, que é usado junto com o *mi*.

de criminalidade, em especial a taxa de crimes patrimoniais, uma vez que apenas nesta categoria de crime houve efeitos significantes da seca.

Em geral, quando a literatura analisa a relação da pluviosidade ou da temperatura nas diferentes categorias de crime, encontra-se relação em ambas as categorias, ou seja, crimes patrimoniais e letais, em alguns casos, uma relação mais forte em um tipo de crime do que outro. Contudo quando se analisa exatamente o fenômeno da seca, como foi o caso de Goin; Rudolph e Ahern (2017), encontraram apenas a relação do fenômeno com os crimes patrimoniais, o que corrobora, com os resultados encontrados nesse trabalho.

Com base no teste da razão de verossimilhança tem-se que o modelo adequado é o *Spatial Durbin Model*, corroborando com os trabalhos de Junior (2016) e Sass *et al.* (2016). Com isso, dada a influência da vizinhança, deve-se considerar, além do efeito direto, o efeito indireto e, pela soma desses dois, tem-se o efeito total.

Nesse sentido, os impactos diretos quantificam a relação direta da taxa de criminalidade na unidade geográfica *i* com a variação de suas próprias características associadas às variáveis explicativas, ou seja, a mesma interpretação associada ao estimador MQO. Por sua vez, os efeitos indiretos medem os efeitos da taxa de criminalidade da mesma unidade geográfica *i*, em decorrência da variação das variáveis explicativas da unidade geográfica *j*.

Desta forma os efeitos indiretos indicam se existem ou não efeitos de transbordamento espacial significativos (*spillovers*) em vez de considerar a estimativa do coeficiente associado à variável dependente espacialmente defasada (Elhorst, 2011). O motivo dos efeitos diretos das variáveis explicativas terem valores diferentes das estimativas obtidas no modelo de regressão é o fato de que este coeficiente inclui os efeitos de *feedback* que surgem como resultado dos impactos que passam pelos municípios vizinhos e retornam.

Conforme a Tabela 5, observa-se *spillovers* positivos na variável de seca, dado pelo efeito indireto de -42,7073. Ou seja, caso a seca apresente gravidade em algum determinado município, seu vizinho também incorrerá em um aumento da taxa de crimes patrimoniais. Logo, pode-se entender esse resultado como uma espécie de contaminação, algo que se espera, uma vez que o fenômeno da seca pode trazer um estresse econômico para seu município, transbordando atos criminosos nos municípios vizinhos.

Nesse sentido, cabe ressaltar que os efeitos indiretos são maiores que os efeitos diretos, logo, podemos entender que o efeito da seca no município j é de maior magnitude do que o município que entrou em seca i , podemos interpretar esse resultado pelo fato do custo benefício do crime no município j ser maior uma vez que este não encontra-se comprometido pelo fenômeno.

Quanto as demais variáveis, vale salientar os *outputs* dos indicadores de educação e emprego e renda, uma vez que estes apresentaram-se de maneira contrária ao que se esperava. A variável emprego e renda, com o seu sinal negativo mostra-se redutora da criminalidade, isto pode ser justificado pelo fato desta levar em consideração além de indicadores de renda, indicadores de emprego. Contudo para além dessa afirmação, trabalhos como Amin *et al.* (2009) mostram que a renda per capita tem um efeito dúbio e não é conclusiva em relação a criminalidade como um todo, de modo que não há como afirmar que sociedades mais ricas são menos violentas.

A variável de educação tem em resposta o sinal positivo, indicando que elevações no índice de educação incrementa elevações na taxa de criminalidade, o que vai de encontro à literatura, isto pode estar acontecendo uma vez que a variável *educ* compreende índices ligados a educação fundamental, e esta educação pode estar sendo de qualidade insuficiente para reduzir a criminalidade nos municípios do estado.

Em síntese, este capítulo buscou apresentar os principais resultados referente ao efeito do fenômeno da seca na criminalidade patrimonial e letal²⁴. Mostrou-se que o espaço é importante para o estudo da criminalidade, de maneira que foram estimados modelos que incorporaram a questão espacial e, seguindo a estratégia de Elhorst (2010) e Belotti *et al.* (2013), foram aplicados testes para a escolha do modelo mais adequado que, neste caso, mostrou-se favorável ao 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.

²⁴ Os resultados da regressão para crimes de homicídios encontram-se em anexo, tanto para painel quanto painel espacial.

Tabela 5 – Resultados para os efeitos do *Spatial Durbin Model* com efeitos fixos: Crimes Patrimoniais.

Variável	Diretos		Indiretos		Totais	
	Estimativas	P>(z)	Estimativas	P>(z)	Estimativas	P>(z)
<i>CVP(t – 1)</i>	0.108865	(0,000)***	0.162679	(0,000)***	0.271544	(0,000)***
<i>Educ</i>	569.1037	(0,001)***	793.7361	(0,014)**	1362.84	(0,000)***
<i>Emp&Ren</i>	-224.605	(0,001)***	-372.463	(0,020)**	-597.068	(0,001)***
<i>Dens</i>	1342.031	(0,000)***	340.5303	(0,616)	1682.561	(0,016)**
<i>SPI3</i>	-13.3671	(0,029)**	-42.7073	(0,000)***	-56.0744	(0,000)***
OBS	1110		1110		1110	

Fonte: elaboração própria. Nota: *** 1% de significância, ** 5% de significância, * 10% de significância.

CAPÍTULO 5

Considerações finais

Este trabalho teve por objetivo investigar a relação entre o fenômeno da seca e a criminalidade pernambucana, tendo como *proxies* as taxas de crimes patrimoniais e a taxa de homicídios. O estudo foi inovador na área da criminologia no Brasil, por adotar técnicas econométricas de estimação que, além de incluir as relações climáticas como determinantes da criminalidade, também foram inseridas as relações espaciais e temporais. Dessa maneira, buscou-se examinar como a criminalidade é impactada uma vez que o município entra em estado de seca, sendo o estado de seca definido pelo Índice de Precipitação Padronizada (SPI3).

Para averiguar a dependência espacial da variável dependente, aplicou-se inicialmente a estatística *I de Moran Global* à variável taxa de crime patrimonial e à taxa de homicídios, de 2011 a 2016, e observou-se autocorrelação espacial positiva. Porém, com o intuito de analisar onde ocorrem essas relações, utilizou-se o *I de Moran Local*, detectando-se a existência de clusters, bem como um movimento na dinâmica espacial ao passar do tempo, tanto alto-alto, quanto baixo-baixo, para os municípios do interior do estado.

Para além da estimação por MQO e painel espacial, estimou-se ainda os efeitos diretos e indiretos, dado que foi comprovada a importância do espaço e, assim, observou-se que o fenômeno da seca tanto eleva a criminalidade contra o patrimônio, quanto tem efeitos de transbordamento. Assim, sugere-se que um município *j*, uma vez que a seca nele se manifesta, exibe incrementos em sua taxa de criminalidade patrimonial, assim como eleva a taxa registrada no município vizinho *i*. Destaca-se que esses efeitos foram observados apenas para as taxas de crimes patrimoniais, uma vez que não foi encontrado significância quanto à relação entre a variável de interesse e a taxa de crimes violentos letais intencionais.

Apesar das limitações do trabalho (a exemplo da indisponibilidade de dados relativos à desigualdade de renda ou indicadores de atividade policial nos municípios em todos os anos da série), fica comprovada a hipótese inicialmente proposta. Assim, o fenômeno da seca eleva a criminalidade, particularmente a

taxa de crimes violentos contra o patrimônio. Essa conclusão fortalece a necessidade de adoção de políticas de segurança pública que levem em consideração tal relação, uma vez que os municípios estejam propícios ou entrem em estado de seca.

Por fim, como sugestão para futuras pesquisas, propõe-se o melhoramento dos instrumentos utilizados para controlar o modelo econométrico, uma vez que a falta de variáveis chamadas *enforcements* da segurança pública foi uma limitação deste trabalho.

REFERÊNCIAS

- ALBUQUERQUE, T.M.A. **Estudos dos processos de gestão de seca: aplicação no estado do Rio Grande do Sul**. Tese de doutorado. UFRGS. Rio Grande do Sul. (2010).
- AMIN, M. C.; COMIM, F. V. e IGLESIAS J. R. ; **Crescimento econômico e criminalidade: refletindo sobre o desenvolvimento**. Anais do XXXVII Encontro Nacional de Economia', ANPEC - Associação Nacional dos Centros de Pósgraduação em Economia. 2009.
- ANDERSON, C. A. & Anderson, K. B. Temperature and aggression: paradox, controversy, and a (fairly) clear picture, In R. Geen & E. Donnerstein, (Eds), Human Aggression: **Theories, Research and Implications for Social Policy**. San Diego, CA: Academic Press, pp. 49- 72, (1998).
- ANSELIN, Luc. Local indicators of spatial association—LISA. **Geographical analysis**, v. 27, n. 2, p. 93-115, 1995.
- 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.
- APAC, Agência Pernambucana de Águas e Clima. **Monitoramento pluviométrico**. Disponível em: <<http://www.apac.pe.gov.br/meteorologia/monitoramento-pluvio.php>>. Acesso em: 27 jan. 2019.
- ARAÚJO, P. H. C. et al. Efeitos da seca sobre a produtividade agrícola nos municípios da região nordeste. **Anais do IX Encontro de Economia Baiana. Salvador: Bahia**, 2013.
- ASFORA, M. C. et al. Diagnóstico da seca 2011-2016 em Pernambuco: impactos e políticas de mitigação. **Parcerias Estratégicas** v. 22, n. 44 p. 247-274, 2017.
- AYOADE, J. O. **Introdução á climatologia para os trópicos**. Rio de Janeiro, Bertrand Brasil, 1996.
- BDE- BASE DE DADOS DO ESTADO; Condepe Fidem; Pernambuco; Acesso em http://www.bde.pe.gov.br/estruturacaogeral/conteudo_site2.aspx 2019.
- BEATO, C. C. Determinantes da criminalidade em Minas Gerais. **Revista Brasileira de Ciências Sociais**. São Paulo, v. 13, N, 37, p. 74-87, 1998.
- BECKER, G.; ***“Crime and Punishment: An Economic Approach”***. *Journal of Poli-tical Economy*, vol. 76, pp. 169-217. 1968.
- BECKER, G. Crime and punishment: an economic approach. **The Journal of Political Economy**, v. 76, n. 2, p.169-217. 1968.

BELL, P. A. In defense of the negative affect escape model of heat and aggression. 1992.

BELOTTI, F.; HUGHES, G.; MORTARI, A. **xsmle: Stata module for spatial panel data model estimation**. Statistical Software Components, 2013.

BELOTTI, F.; HUGHES, G.; MORTARI, A. **Spatial Panel Data models using Stata**. Roma, IT: [s.n.], 36 p. (CEIS Research Paper, 373). 2016.

BEVILAQUA, G. A. P., et al. "Agricultores guardiões de sementes e ampliação da agrobiodiversidade." **Embrapa Clima Temperado-Artigo em periódico indexado (ALICE)** (2014)

BLAKESLEE, D. S.; FISHMAN, R. Weather Shocks, Agriculture, and Crime Evidence from India. **Journal of Human Resources**, v. 53, n. 3, p. 750-782, 2018.

BURKE, M. et al. Warming increases the risk of civil war in Africa. Oslo: **Peace Research Institute Oslo (PRIO)**, 2009. Disponível em: www.pnas.org/cgi/doi/10.1073/pnas.0907998106

CAMPOS, K. C. *et al.*; **Análise Da Dependência Espacial Da Produtividade Agrícola Do Feijão Em Relação As Chuvas Observadas Nos Municípios Cearenses Entre Os Anos De 2008 A 2016**. 2018

CAMURÇA, C. E. S. et al. Implicações psicossociais da seca na vida de moradores de um município da zona rural do nordeste do Brasil. **Avances en psicología latinoamericana**, v. 34, n. 1, p. 117-128, 2016.

CANAMARY, E. A.; REIS JR, D. S.; MARTINS, E. S. Evaluation of ensemble SPI forecasts for Ceará, Northeastern Brazil. **Drought: Research and Science-Policy Interfacing**, p. 245, 2015.

CANO, I; SOARES, G. D. As teorias sobre as causas da criminalidade. **Rio de Janeiro: IPEA**, 2002.

CAPLAN, J. M.; KENNEDY, L. W. Risk Terrain Modeling Manual. **Newark, NJ: Rutgers Center on Public Security**, 2010.

CARMO, C. R. S. Criminalidade: um estudo sobre os determinantes de crimes contra o patrimônio a partir externalidades urbanas. **Revista Brasileira de Gestão e Desenvolvimento Regional**, 10(1), (2014).

CARVALHO, A. X. Y., E ALBUQUERQUE, P.H.M. Tópicos em econometria espacial para dados cross-section. No. 1508. Texto para Discussão, **Instituto de Pesquisa Econômica Aplicada (IPEA)**, 2010.

CERQUEIRA, D; LOBÃO, W. Determinantes da criminalidade: arcabouços teóricos e resultados empíricos. **Dados**, v. 47, n. 2, p. 233-269, 2004.

COHEN, L. E. & FELSON, M. Social change and crime rate trends: A routine activity approach. **American sociological review**, p. 588-608, 1979.

COHN, E. G. Weather and crime. **The British Journal of Criminology**, 30(1), 51–64. (1990).

COHN, E. G., & ROTTON, J. Weather, seasonal trends and property crimes in minneapolis, 1987–1988. A moderator-variable time-series analysis of routine activities. **Journal of Environmental Psychology**, 20(3), 257–272. (2000b).

COHN, E. G., & ROTTON, J. Weather, seasonal trends and property crimes in minneapolis, 1987–1988. A moderator-variable time-series analysis of routine activities. **Journal of Environmental Psychology**, 20(3), 257–272. (2000c)

COHN, E., & ROTTON, J. Violence is a curvilinear function of temperature in Dallas: **A replication**. **Journal of Personality and Social Psychology**, 78, 1074–1081, (2000a).

COHN, E., & ROTTON, J. Weather, disorderly conduct, and assaults: From social contract to social avoidance. **Environment and Behavior**, 32, 651–673, (2000b).

COSTA, A. C. Local patterns and trends of the Standard Precipitation Index in southern Portugal (1940-1999). **Advances in Geosciences** 30, no. NA (2011): 11-16.

COSTA, A. M. Pobreza e vulnerabilidade de agricultores familiares de Santo Cristo/RS: uma análise da seca a partir da abordagem das capacitações. 2006.

DE BRITTO, M. C; FERREIRA, C. C. M. Aspectos da Relação Clima, Estacionalidade e Criminalidade Violenta em Minas Gerais. **REVISTA GEONORTE**, v. 3, n. 9, p. 711-734, 2012.

EDWARD B. et al. the social and economic impacts of drought. **Australian Social Policy Association**. V. 54, p. 22-31,(2018).

EDWARDS B. et al. The impact of drought on mental health in rural and Regional Australia. **Social Indicators Research** 2015; 121(1):177-194.

EHRlich, I.; **Participation in illegitimate activities: A theoretical and empirical investigation**. *Journal of political Economy*, v. 81, n. 3, p. 521-565, 1973.

Elhorst, J. P. , **Dynamic spatial panels: models, methods, and inferences**, *Journal of Geographical Systems* 14, 5–28. 2011

Elhorst, J. P. ; **Applied spatial econometrics: raising the bar**. *Spatial Economic Analysis* 5(1): 9{28. 2010

FAVERO, E. **O impacto psicossocial das secas em agricultores familiares do Rio Grande do Sul: um estudo na perspectiva da psicologia dos desastres**. 2012.

FECHINE, J. A. L. Identificação de secas meteorológicas na região metropolitana de Fortaleza, usando o índice de precipitação padronizada (SPI). **Boletim de Geografia**, v. 33, n. 2, p. 18-33, 2015.

FERNANDES et al. Índices para a quantificação da seca. **Embrapa arroz e feijão**- Santo Antônio de Goiás -Go, (2009)

FREIRE-GONZÁLEZ, J., DECKER, C., & HALL, J. W. **The Economic Impacts of Droughts: A Framework for Analysis. *Ecological Economics***, v. 132, p. 196-204, 2017.

FREITAS, M.A.S. Um sistema de suporte à decisão para o monitoramento de secas meteorológicas em regiões semi-áridas. **Revista Tecnologia** 19, no. 1 (1998).

GOIN, D. E.; RUDOLPH, K. E.; AHERN, J. Impact of drought on crime in California: A synthetic control approach. **PLoS one**, v. 12, n. 10, p. e0185629, 2017.

GREENE, W. H. **The econometric approach to efficiency analysis**, in H. O. Fried, C. A. K. Lovell, and S. S. Schmidt, eds., **The Measurement of Productive Efficiency and Productivity Growth**, Oxford: Oxford University Press, [New York], 2008.

GUTIERREZ, M. B. S., et al . Inequality and criminality revisited: further evidence from Brazil. **In Anais do XXXII Encontro Nacional de Economia** [Proceedings of the 32nd Brazilian Economics Meeting] (No. 149). ANPEC. 2004

HABIBULLAH, M.S. The effects of weather on crime rates in Malaysia. **International Journal of Business and Society**, Vol. 18 No. 2, 2017, 263-270 (2017)

HALICIOGLU, F. Temporal causality and the dynamics of crime in Turkey. **International Journal of Social Economics**, v. 39, p. 704 - 720, 2012.

HAYES, M. et al. The Lincoln declaration on drought indices: universal meteorological drought index recommended. **Bulletin of the American Meteorological Society**, v. 92, n. 4, p. 485-488, 2011.

HSIANG, S. et al. Quantifying the Influence of Climate on Human Conflict. **Science**, v.341,n.6151, 1235367, (2013)

HSIAO, C. Analysis of panel data, **Cambridge University Press**. 2003

IBGE, Instituto Brasileiro de Geografia e estatística. **Panorama**. Disponível em: <<https://cidades.ibge.gov.br/brasil/pe/panorama>> Acesso em, 25 jun 2019.

FIRJAN – FEDERAÇÃO DAS INDÚSTRIAS DO ESTADO DO RIO DE JANEIRO. **Índice Firjan de Desenvolvimento Municipal (IFDM)**: Rio de Janeiro: Firjan. Disponível em < <https://www.firjan.com.br>> 2019

IMBENS, G. W.; LEMIEUX, T. Regression discontinuity designs: A guide to practice. **Journal of econometrics**, v. 142, n. 2, p. 615-635, 2008.

IPEADATA, Instituto de pesquisa econômico aplicada. **Indicadores sociais**. Disponível em: < <http://www.ipeadata.gov.br/Default.aspx>> (2019)

JACOB, B; LEFGREN, L; MORETTI, E. The dynamics of criminal behavior evidence from weather shocks. **Journal of Human resources**, v. 42, n. 3, p. 489-527, 2007.

HORROCKS J; MENCLOVA, A. K. The effects of weather on crime, **New Zealand Economic Papers**, 45:3, 231-254, 2011. DOI: 10.1080/00779954.2011.572544

JÚNIOR, J. M. N. A dinâmica dos homicídios no Nordeste e em Pernambuco. **Dilemas-Revista de Estudos de Conflito e Controle Social** 3, no. 10, 51-74, (2010).

KUME, L. et al. Uma estimativa dos determinantes da taxa de criminalidade brasileira: uma aplicação em painel dinâmico. **Apresentado no encontro da ANPEC**, 2004.

LEITE, F.J.A. Identificação de secas meteorológicas na região metropolitana de Fortaleza, usando o índice de precipitação padronizada (SPI). **Boletim de Geografia** 33, no. 2 (2015): 18-33.

LEITE, J.A.A. e LEITE, P. S. Uma investigação do problema do semi-árido nordestino com destaque para a Paraíba. **I encontro sobre alternativas econômico-sociais para o desenvolvimento do nordeste**, v. 1, 1984.

IEsAGE, J. The theory and practice of spatial econometrics. **Department of Econo-mics** - University of Toledo, 1999.

LIMA, M. L. C., et al. Análise espacial dos determinantes socioeconômicos dos homicídios no Estado de Pernambuco. **Revista saúde pública**, v. 39, n.2, p. 176-82, 2005.

MALASSISE, R.L.S., PARRÉ, J. L., e FRAGA, G.B. "O Comportamento do Preço da Terra Agrícola: um modelo de painel de dados espaciais." **Revista de Economia e Sociologia Rural** 53, no. 4 (2015): 645-666.

MARES, D. Climate change and crime: monthly temperature and precipitation anomalies and crime rates in St. Louis, MO 1990–2009. **Crime, law and social change**, v. 59, n. 2, p. 185-208, 2013.

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales. In: **Proceedings of the 8th Conference on Applied Climatology**, p. 179-183. Anaheim, CA: American Meteorological Society, 1993.

MENDONÇA, F. **Aspectos da interação clima-ambiente, saúde Humana: da relação Sociedade-natureza à (in) sustentabilidade ambiental**. IV SBCG (Simpósio Brasileiro Climatologia Geográfica), Rio de Janeiro. Revista R. RA'EGA, Curitiba. n. 4, p. 85-99. 2000. Universidade Federal do Paraná; 2000. Disponível em: < <http://www.unit.br/mestrado/saudeambiente/leitura2008> >. Acesso em: 20 jan. 2014.

MENDONÇA, F.A. **Clima E Criminalidade: Ensaio Analítico Da Correlação Entre a Temperatura Do Ar E a Criminalidade Urbana.** . Editora da UFPR. 2001

MOREIRA, R. C.; FOCHEZATTO, A.; **Análise Espacial Da Criminalidade No Estado Da Bahia.** *RDE-Revista de Desenvolvimento Econômico*, 3.38. 2018

NDMC, National Drought Mitigation Center. **Interpretation oof Standardized Precipitation Index Maps.** Disponível em: < <https://drought.unl.edu/droughtmonitoring/SPI.aspx> > Acesso em 23 jun 2019.

PENTEADO FILHO, N. S. **Manual esquemático de criminologia.** – 2 ed.- São Paulo: **Saraiva Educação SA**, 2012.

ROGERS, M. L. & PRIDEMORE, W. A.. The effect of poverty and social protection on national homicide rates: Direct and moderating effects. **Social science research**, v. 42, n. 3, p. 584-595, 2013.

SASS, K. S.; PORSSSE A. A; DA SILVA, E. R. H.; **"Determinantes das taxas de crimes no Paraná: uma abordagem espacial."** *Revista Brasileira de Estudos Regionais e Urbanos* 10.1. pp. 44-63. 2016

SDS-PE, Secretaria de Defesa social de Pernambuco. **Estatísticas - Indicadores criminais.** Disponível em: < <http://www.sds.pe.gov.br/estatisticas> >. acesso em 20 de mar, 2019.

SILVA, F. et al. Avaliação da ocorrência de secas na Bahia utilizando o Índice de Precipitação Padronizada (SPI). **Bahia Análise & Dados**, v. 23, n. 2, p. 461-473, 2013.

SILVA, J. G. S, et al.; **Impactos da seca nas unidades produtivas familiares assentadas.** *RDE-Revista de Desenvolvimento Econômico*, 16.30. 2015.

SILVA, T. P. Análise espacial e avaliação de vulnerabilidade socioeconômica para os crimes violentos letais intencionais (cvli) no estado de pernambuco. **Geoiingá: Revista do Programa de Pós-Graduação em Geografia**, v. 7, n. 2, p. 60-77, 2016.

SOARES, G. A. D. **Não matará: desenvolvimento, desigualdade e homicídios.** FGV Editora, 2008.

SOMMER, A. J., LEE, M., & BIND, M. A. C.; ***Comparing apples to apples: an environmental criminology analysis of the effects of heat and rain on violent crimes in Boston.*** *Palgrave communications*, 4(1), 1-10. 2018.

THOM, H. C. S. **Same methods of climatological analyses.** Geneva: World Meteorological Organization, 1966.

THORTHWAITE, C. W. **An approach towards a rational classification of climate.** *Geographycal Review* London, Nova Jersey n.38,p.55-94, (1948)

UCHÔA, C. F.; MENEZES, T. A.; **Spillover espacial da criminalidade: Uma aplicação de Painel Espacial para os Estados Brasileiros**. XL Encontro Nacional de Centro de Pós-Graduação em Economia, Porto de Galinhas, v. 11, 2012.

VIANA, Eduardo. Criminologia. **Salvador: Juspodivm**, 2014.

WASELFISZ, J. J., Mapa da violência 2012: os novos padrões da violência homicida no brasil, **Technical report, Instituto Sangari**, São Paulo, SP – 2011.


WILKS, D. S. **Statistical methods in the atmospheric sciences**, 2^a Ed. California: Elsevier, 2006.

ZARGAR, A. et al. A review of drought índices. **Envirounmental reviens**, [s.l.], v 18, n. , p 333-349, dez. 2011. Canadian Science Publishing

Apêndice


Apêndice A – Quadros referentes à Análise Exploratória de Dados Espaciais.

Figura A1– Resumo das estatísticas *I* Moran Global entre 2011 e 2016 – Taxa de Crimes Patrimoniais (CVP).



Fonte: elaboração própria a partir do software GeoDa, desenvolvido por Anselin et al. (2006).

Figura A2 – Mapas de *clusters* (LISA) da taxa de CVP entre 2011 e 2016.




Fonte: elaboração própria a partir do software GeoDa, desenvolvido por Anselin et al. (2006).

Nota 1: P-valor = 0,05.


Nota 2: Pseudo-significância baseada em 999 permutações randômicas.

Figura A3 – Resumo das estatísticas *I* Moran Global entre 2011 e 2016 – Taxa de Homicídios (CVLI).



Fonte: elaboração própria a partir do software GeoDa, desenvolvido por Anselin et al. (2006).

Figura A4 – Mapas de *clusters* (LISA) da taxa de CVLI entre 2011 e 2016.



Elaboração própria a partir do software GeoDa, desenvolvido por Anselin et al. (2006).

Nota 1: P-valor = 0,05.

Nota 2: Pseudo-significância baseada em 999 permutações randômicas.

Apêndice B – Resultado das regressões

Tabela B1 - Resultados das estimações para dados em painel: crimes de homicídios

Variável	<i>Pooling</i>	EF	EA
<i>Constant</i>	18.08777 (0.006)***	42.06332 (0.008)***	19.83158 (0.004)***
Taxa CVLI(t-1)	0.491331 (0.000)***	0.0268756 (0.393)	0.449852 (0.000)***
Educ	-2.98892 (0.736)	30.57327 (0.08)*	-1.90186 (0.837)
Ren_emp	5.303932 (0.316)	-37.20081 (0.000)***	2.938867 (0.589)
Densidade	0.502283 (0.457)	-38.22334 (0.177)	0.692333 (0.34)
Seca	-0.86967 (0.223)	-0.9831317 (0.115)	-0.96872 (0.169)
R ²	0.2464	0.069	0.009
OBS	906		
Teste Chow		4.04***	
Teste Breusch-Pagan			35.65***
Teste Hausman		917.08***	
Teste Wald		2.6E+31***	

Tabela B2 - Resultados das estimações painel espacial: crimes de homicídios

Variável	SDM	
	Estimativas	P>(z)
<i>CVLI_{t-1}</i>	-0.0029	0.905
<i>Educ</i>	4.1713	0.781
<i>Emp&Ren</i>	-11.7848	0.078
<i>Dens</i>	-12.3475	0.609
<i>SPI3</i>	0.5728	0.386
ρ	0.159537	0.096
OBS	1110	

Tabela B3 – Resultados da estimação SDM espacial com PIB *Per capita*

Variável	Estimativas		Diretos		Indiretos		Totais	
	Coeficiente	P>(z)	Coeficiente	P>(z)	Coeficiente	P>(z)	Coeficiente	P>(z)
<i>CVP(t – 1)</i>	0.1107634	(0,000)***	0.119492	(0,000)***	0.181779	(0,000)***	0.301271	(0,000)***
<i>Educ</i>	594.0356	(0,000)***	660.1225	(0,000)***	1645.549	(0,000)***	2305.672	(0,000)***
PIBpc	-0.0014735	(0,466)	-0.00128	(0,513)	-0.00024	(0,955)	-0.00152	(0,716)
<i>Dens</i>	1271.841	(0,000)***	1310.147	(0,000)***	940.8792	(0,225)	2251.026	(0,010)
<i>SPI3</i>	-13.57103	(0,043)**	-15.4306	(0,016)**	-43.4581	(0,000)**	-58.8887	(0,000)**
OBS	1110		1110		1110		1110	
ρ	0.2644104	(0,000)***						