

## Padrões de Concentração Espacial de Roubos de Automóveis em Municípios da Grande João Pessoa a Partir de Técnicas de Aprendizado de Máquinas

### Spatial Concentration Patterns of Vehicle Theft in Municipalities of Great João Pessoa Using Machine Learning Techniques

**Otoniel Rodrigues dos Anjos Junior**

Universidade Federal da Paraíba – UFPB – Brasil  
pbdosanjos@hotmail.com  
ORCID: 0000-0003-0085-4893

**Robson Oliveira Lima**

Instituto Federal da Paraíba – IFPB – Brasil  
robson.lima@ifpb.edu.br  
ORCID: 0000-0001-6310-0023

**Stélio Coêlho Lombardi Filho**

Universidade Federal da Bahia – UFBA – Brasil  
stelio.filho@hotmail.com  
ORCID: 0000-0001-7753-5351

**Aléssio Tony Cavalcanti de Almeida**

Universidade Federal da Paraíba – UFPB – Brasil  
alessiotony@gmail.com  
ORCID: 0000-0003-0436-359X

**Hilton Martins Brito Ramalho**

Universidade Federal da Paraíba – UFPB – Brasil  
hilton@lema.ufpb.br  
ORCID: 0000-0003-1501-8652

**Submetido em 27/02/2020; Aprovado em 08/09/2020.**

#### Resumo

**Objetivo:** Este artigo tem como objetivo identificar padrões de concentração espacial relacionados a roubos e furtos de veículos na grande João Pessoa (PB), região composta pelos municípios de Bayeux, Cabedelo, João Pessoa e Santa Rita, usando técnicas de aprendizado de máquinas. Com isso, busca-se contribuir com a discussão sobre os potenciais benefícios da utilização de ferramentas da Inteligência Artificial no campo da segurança pública. **Metodologia:** Os dados utilizados foram obtidos junto à Secretaria de Estado da Segurança e da Defesa Social da Paraíba e contemplam os anos de 2017 a 2019. A base é composta por 5.385 ocorrências de roubo e furto de carros e motos, indicando coordenadas geográficas, município, bairro, dia da semana, turno e hora de ocorrência do crime. A estratégia empírica adotada consistiu na aplicação do algoritmo de Clusterização Espacial Baseada em Densidade de Aplicações com Ruído (*Density-Based Spatial Clustering of Applications with Noise*, DBSCAN). **Resultados:** A análise descritiva apontou que o centro da cidade de João Pessoa é o bairro com maior taxa de subtração de veículos por 100 mil habitantes, seguido por Barra de Gramame, Ponta do Seixas, Distrito Industrial e Varadouro. Em relação à concentração de crimes em locais determinados, a utilização do DBSCAN permitiu identificar *hotspots* para diferentes dias e turnos, sendo que o número destes se mostrou maior durante os dias de semana, no período noturno. **Contribuições:** Tais resultados têm potencial para auxiliar a elaboração de um planejamento mais eficaz de segurança pública nos bairros da grande João Pessoa, pois sugerem como deslocar o efetivo policial de modo a se alcançar maior eficiência na prevenção de crimes e captura de criminosos.

**Palavras-chave:** Padrões de concentração; Roubos e furtos de veículos; Grande João Pessoa; Hotspots.

## Abstract

**Purpose:** The objective of this paper is to identify patterns of spatial concentration related to robbery and theft of vehicles in the great João Pessoa (PB), a region composed by the municipalities of Bayeux, Cabedelo, João Pessoa and Santa Rita, using machine learning techniques. Thus, it seeks to contribute to the discussion on the potential benefits of using Artificial Intelligence tools in the field of public security.

**Methodology:** The data used were obtained from the Secretaria de Estado da Segurança e da Defesa Social da Paraíba and include the years from 2017 to 2019. The base is made up of 5.385 occurrences of robbery and theft of cars and motorcycles, indicating municipality, neighborhood, day of week, shift and time of crime. The empirical strategy adopted consisted in the application of the Density-based Spatial Clustering of Applications with Noise (DBSCAN) algorithm. **Findings:** The descriptive analysis showed that the center of João Pessoa is the neighborhood with the highest rate of vehicle subtraction per 100 thousand inhabitants, followed by Barra de Gramame, Ponta do Seixas, Distrito Industrial and Varadouro. In relation to the concentration of crimes in certain places, the use of the DBSCAN algorithm allowed to identify *hotspots* for different days and shifts, being that the number of these was higher during the weekdays at night. **Contributions:** These results have the potential to help develop a more effective public security planning in the neighborhoods of the great João Pessoa, as they suggest how to move the police force in order to achieve greater efficiency in preventing crimes and capturing criminals.

**Keywords:** Concentration patterns; Robbery and theft of vehicles; Great João Pessoa; Hotspots.

## 1. Introdução

A criminalidade é um fenômeno social que afeta milhões de pessoas ao redor mundo, com taxas elevadas, sobretudo, em países do continente americano (OMS, 2020). A situação é particularmente preocupante na América Latina, de sorte que o Escritório das Nações Unidas sobre Drogas e Crimes (*United Nations Office on Drugs and Crime - UNODC*) enumera quatro dimensões para explicar o aumento e a persistência da violência nesta região: i) a dimensão econômico-estrutural, que inclui baixa qualidade de emprego e insuficiente mobilidade social; ii) a dimensão social, com destaque para as mudanças na estrutura familiar (em especial, o incremento significativo de lares monoparentais), a evasão escolar e o crescimento urbano acelerado; iii) os facilitadores do delito, tais como armas, álcool e drogas; e iv) a falta de capacidade do Estado – forças policiais, juízes, ministério público e prisões – para fazer frente aos desafios da segurança (UNODC, 2013).

Os elevados índices de criminalidade e seus custos associados têm se tornado uma das grandes preocupações das autoridades. O crime e a violência vêm se destacando como um dos mais sérios empecilhos ao desenvolvimento econômico e social, uma vez que tais fenômenos produzem efeitos danosos sobre a renda e a saúde física e mental dos indivíduos, principalmente, devido aos elevados custos associados à mortalidade (Santos & Santos Filho, 2011; Gomes, Evangelista, Lima & Parré, 2017). Logo, essa atividade ilegal impacta negativamente o convívio humano, causando medo (Cardia & Cinoto, 2012), problemas psicológicos (Andrade, Wang, Andreoni, Silveira, Alexandrino-Silva, Siu & Viana, 2012), reduzindo o capital humano (Koppensteiner & Menezes, 2019), aumentando os custos (Cerqueira, 2014) e gerando perdas sociais irreversíveis (Soares, 2015).

A matriz geradora da criminalidade não é totalmente conhecida, mas as pesquisas realizadas até o presente já trazem importantes achados para direcionar políticas no setor. Estudos seminais da área apontam que a dinâmica do crime parece encontrar refúgio na falta de punição (Sherman & Berk, 1984), na ausência de autocontrole dos indivíduos (Gibbs, Giever, & Martin, 1998) e no aumento dos ganhos individuais devido à ação ilícita (Becker, 1968). É possível entender a ação criminoso como sendo uma externalidade negativa que piora o bem-estar de parte dos agentes da sociedade em detrimento de outros. A teoria da escolha racional, iniciada com Becker (1968) e, posteriormente, difundida e expandida por diversos autores (Cerqueira & Lobão, 2004; Becker & Rubenstein, 2011; Santos & Santos Filho, 2011; Soares, 2015; Suliano & Oliveira, 2015; Oliveira & Arcaro, 2016; Bartz, Quartieri, & Menezes, 2018; Koppensteiner & Menezes, 2019; Eriksson, 2020), argumenta que o criminoso é um ser racional que pondera custos e benefícios da prática criminoso. Sendo assim, o indivíduo emprega maiores esforços nos setores que oferecerem maiores lucros individuais, seja tal setor legal ou ilegal. Nessa linha, Shikida (2016), a partir de entrevistas com detentos paraenses com idade entre 18 e 23 anos, constatou que criminosos migram para as atividades ilegais na esperança de que seus ganhos pecuniários esperados superem os riscos dessa atividade, como já previra Becker (1968).

O comportamento criminoso pode sofrer mudanças, em especial devido à influência de fatores como urbanização, renda e densidade populacional. A literatura mostra que lugares mais urbanizados desencadeiam menores probabilidades de identificação e prisão dos criminosos, aumentando as possibilidades de fuga e a impunidade (Cano & Santos, 2007). A urbanização associada à densidade populacional e à falta de estrutura básica seriam fortes facilitadores da prática criminosa, uma vez que aumenta a utilidade esperada do crime (Fajnzylber, Lederman & Loayza, 2002; Kume, 2004; Santos & Kassouf, 2008; Anjos Junior, Lombardi Filho, Silva Ciríaco & Silva, 2018b). Dessa forma, uma aplicação mais ampla de policiamento nos pontos de maior incidência de crimes poderia impactar significativamente os níveis gerais de criminalidade nas áreas urbanas (Weisburd, Braga, Groff & Wooditch, 2017), pois o aumento de efetivo policial teria como resultado um aumento nos custos associados ao comportamento criminoso (Suliano & Oliveira, 2015).

No Brasil, as pesquisas têm apontado que a dinâmica da criminalidade parece encontrar refúgio em fatores como o desemprego, a densidade demográfica, a desigualdade de renda e a estrutura familiar instável (Bartz et al., 2018). Verifica-se que os crimes contra o patrimônio (roubo e furto) são mais comuns em regiões ricas devido ao contexto de oportunidades, enquanto que os crimes contra a vida, com destaque para os homicídios, exibem frequência mais acentuada em áreas pobres (Guimarães, 2014; Gomes et al., 2017). Ademais, a atividade criminosa também prejudica o desempenho e a frequência escolar, sobretudo de meninos pobres (Koppensteiner & Menezes, 2019). Para Anjos-Junior et al. (2018b), a presente situação de insegurança do país está associada a fatores como impunidade (fragilidade das leis ou benevolência das penas), baixo número de prisões (as polícias prendem pouco) e prisões que estimulam a prática de outros delitos (as prisões que não recuperam).

A concentração de renda é considerada um dos pilares de sustentação dos altos índices de crimes observados no Brasil (Costa & Balestreri, 2010; Gomes et al., 2017; Bartz et al., 2018). De acordo com a UNIODC (2013), para reduzir a criminalidade, deve-se aumentar o investimento público e privado como forma de fomentar a capacitação e a criação de oportunidades de trabalho dignas, direcionadas principalmente aos jovens que não estudam e nem trabalham, priorizando os contextos urbanos onde persiste a pobreza. Oliveira & Arcaro (2016), em estudo realizado para a região metropolitana de Porto Alegre, encontraram que a redução na taxa de desemprego poderia reduzir furtos mensais na região.

Mais recentemente, tem-se dado atenção às formas como as inovações no campo da Tecnologia da Informação (TI) podem contribuir para a compreensão e tomada de decisão acerca de questões relacionadas à criminalidade. Pesquisas têm adotado ferramentas de Inteligência Artificial (IA) para tratar de temas como fraudes financeiras (Pacheco Junior, 2019), lavagem de dinheiro (Paula, 2016) e corrupção (Vieira, 2019), por exemplo. A utilização destes instrumentos vem se expandindo, principalmente, por sua capacidade de tratamento de grandes bases de dados, fornecendo cenários e identificando padrões de comportamento que, em última instância, podem guiar as ações da polícia, a alocação de viaturas, o ajustamento de rondas e o emprego do efetivo policial. Portanto, esse conjunto de medidas pode auxiliar na busca por uma gestão eficiente da segurança pública em um cenário de restrição e escassez de recursos.

Os sistemas computadorizados e os analistas de dados auxiliam policiais no processo de resolução de crimes, em uma abordagem que une ciência da computação e justiça criminal (Sathyadevan, Devan & Gangadharan, 2014). Diariamente, uma enorme quantidade de dados sobre diferentes tipos de crimes ocorridos em diferentes localizações geográficas é coletada e armazenada: data, local, tipo de crime, identificação do criminoso, vítima, possíveis testemunhas e objetos envolvidos na ação (carros, armas, viaturas, drogas etc.). Isto se configura um desenho apropriado para o emprego de técnicas de aprendizado de máquinas, dado que estas podem desempenhar um papel notável na revelação das tendências e padrões criminais (Kumar & Nagpal, 2019; Biswas & Basak, 2019).

Tendo isso em vista, este artigo tem por objetivo contribuir com a discussão sobre os potenciais benefícios da utilização de ferramentas da IA no campo da segurança pública. Mais especificamente, busca-se identificar padrões de concentração espacial de crimes contra o patrimônio nos municípios da grande João Pessoa, a partir da aplicação de algoritmos de aprendizado de máquinas. A pesquisa tem como foco analisar os casos de roubo (Art. 157; o Código Penal Brasileiro – CPB classifica o roubo como sendo o ato de subtrair coisa móvel alheia, para si ou para outrem, mediante grave ameaça ou violência à pessoa, ou depois de havê-la, por qualquer meio, reduzido à impossibilidade de resistência) e furto (Art. 155; o CPB classifica o furto como sendo o ato de subtrair, para si ou para outrem, coisa alheia

móvel) de automóveis (carros e motocicletas) ocorridos nos municípios de Bayeux, Cabedelo, João Pessoa e Santa Rita (ver Figura 1). Os municípios selecionados estão dentre os mais desenvolvidos em termos econômicos do estado da Paraíba. A literatura documenta que há relação positiva dos crimes patrimoniais com a renda dos locais de ocorrência (Resende & Andrade, 2011; Guimarães, 2014; Oliveira & Arcaro, 2016; Gomes, et al., 2017). Ademais, cabe ressaltar que a literatura nacional que trata de crimes contra o patrimônio é relativamente escassa quando comparada à de crimes contra a vida. Nessa linha, busca-se avançar na compreensão das características dessa modalidade de crime, fornecendo novos *insights* acerca de sua dinâmica.

A racionalidade do criminoso o leva a selecionar vítimas, horários e locais de atuação de forma que aumente os ganhos individuais de suas ações. Nesse caso, alguns locais acabam apresentando melhores condições e tornando-se mais propícios às práticas ilícitas (Chainey & Monteiro, 2019). Esse comportamento promove o surgimento de pontos de maior incidência de delitos, os chamados *hotspots* de crimes. Nas últimas duas décadas, têm ocorrido um consenso crescente entre os pesquisadores de que o policiamento nos *hotspots* é uma estratégia eficaz para prevenir e combater a criminalidade (Braga, Papachristos & Hureau, 2014; Weisburd et al., 2017). Dessa forma, um dos objetivos desse artigo é identificar estes pontos de concentração nos municípios supracitados.

Considerando o exposto, espera-se que este estudo forneça insumos que possam auxiliar no desenvolvimento de uma ferramenta capaz de aprimorar o planejamento e a elaboração de estratégias mais eficazes de segurança pública, tendo por base a utilização de instrumentos de IA como suporte para a tomada de decisão. A redução das taxas de crimes, além de fornecer ganhos de bem-estar relevantes para a população, também tem o potencial de proporcionar uma melhor alocação dos recursos da sociedade.



**Figura 1.** Mapa do estado da Paraíba com destaque para a Região Metropolitana e a grande João Pessoa.

Fonte: elaboração própria a partir dos dados do IBGE.

## 2. Fundamentação teórica

A ação criminosa pode ser abordada por diferentes óticas e correntes de pensamento, de modo que um mesmo fato pode ter diversas explicações e interpretações. Conforme apontado por Cano e Soares (2002), existem teorias que se propõem a explicar o comportamento criminoso considerando as patologias individuais, a deficiência do sistema social, a perda de controle, a desorganização social e fatores situacionais ou de oportunidade.

Neste contexto, percebe-se algumas diferenças entre as teorias existentes para analisar o fenômeno da criminalidade, pois enquanto umas consideram o crime como sendo fruto do sistema e da sociedade como um todo (governo, família e comunidade); outras evidenciam que o indivíduo possui o poder de decisão entre praticar ou não determinado ato ilícito, o que confere à criminalidade um caráter passível de análise microeconômica comportamental. Desse modo, devido às diversidades analíticas construídas ao longo dos anos, identificar os fatores e as motivações capazes de explicar a taxa de crime

de determinado ambiente pode ser tarefa complicada e desafiadora.

Inicialmente, Shaw e McKay (1942) observaram que existem diferenças entre as taxas de crimes verificadas em áreas projetadas (que apresentam maior grau de infraestrutura) e nas áreas periféricas. Naquelas mais organizadas, a taxa de criminalidade é relativamente menor que as constatadas nos ambientes dominados pela desorganização e falta de infraestrutura. Tal teoria, denominada Desorganização Social, aponta a criminalidade como fruto do *status* socioeconômico, da mobilidade residencial e da desagregação familiar (Cerqueira & Lobão, 2004).

Já Bruinsma (1992) e McCarthy (1996) analisaram como o comportamento dos indivíduos acerca do crime pode ser influenciado a partir de seus respectivos grupos de amizade e família. Esta corrente ficou conhecida pelo nome de Aprendizado Social e ressalta que as situações vivenciadas podem ser reflexo das experiências pessoais de cada agente com relação às situações de conflitos. Estas podem ser afetadas pelo grau de supervisão familiar, grupos de amizades, amigos com problemas com a polícia, contato com técnicas criminosas, dentre outros (Cerqueira & Lobão, 2004).

A chamada Teoria do Controle Social, aplicada por diversos autores (Agnew & White, 1992; Junger-Tas, 1992), aponta motivações pelas quais alguns agentes não entram no mundo do crime. Neste caso, o enfoque é dado aos agentes que se abstêm do cometimento do crime, sendo tal fato influenciado por normas vigentes, crenças, percepção e envolvimento do cidadão no sistema social, além de outros fatores. Segundo Cerqueira e Lobão (2004), tal teoria afirma que quanto maior o envolvimento do cidadão e seu elo com a sociedade, menor será a probabilidade de que este se torne um criminoso.

Outra importante teoria acerca do estudo da criminalidade foi denominada de Autocontrole. Esta considera que alguns agentes não foram capazes de desenvolver mecanismos psicológicos de autocontrole. Na ótica de Cerqueira e Lobão (2004), as distorções observadas no processo de socialização, ocasionados pela falta de imposição e de limites, faz com que o agente tome suas decisões ao sabor do momento e sem medir consequências. Esta teoria foi desenvolvida por Gottfredson e Hirschi (1990), sendo acompanhada por vários estudos que buscaram encontrar as causas que melhor explicariam as taxas de crime em dada localidade (Arneklev, Grasmick, Tittle, & Bursik Jr., 1993; Gibbs et al., 1998).

Dessa forma, observa-se que os estudos sobre criminalidade podem abordar diferentes dimensões. Uma relevante contribuição às pesquisas relacionadas neste campo foi desenvolvida por Becker (1968). Em seu trabalho seminal, este aponta que a decisão pelo crime é tomada racionalmente com base nos custos e benefícios da ação criminosa. Tal teoria foi intitulada de abordagem da Escolha Racional, pois argumenta que o indivíduo é capaz de tomar decisões entre mercado legal e ilegal baseado no lucro líquido de cada um destes setores. Destaca-se que a partir da introdução da racionalidade aos estudos da criminalidade, foi possível avançar e encontrar resultados baseados em instrumentos matemáticos e estatísticos (Carrera-Fernandez & Pereira, 2001).

O agente otimizador descrito por Becker (1968) representa um caso clássico de maximização de ganhos esperados sujeito a perdas associadas a cada tomada de decisão individual. Portanto, tal teoria do crime apresenta oportunidades de otimização de ganhos, funcionando como indicadores de onde cada indivíduo deve implementar maior dedicação. Carrera-Fernandez e Santo (2008) mostraram que a atividade criminosa possibilita, inclusive, encontrar uma curva de oferta de crimes apenas partindo do processo de maximização de lucro dos agentes envolvidos no processo de escolha entre crime e não crime.

Para McKenzie e Tullock (2012), o fato de os agentes serem racionais permite que a quantidade de crime de uma localidade seja determinada como qualquer outra atividade da economia. Assim, deve-se considerar que os indivíduos reagem a incentivos e podem praticar maior ou menor quantidade de crimes, pois tal fenômeno passa a depender essencialmente do comportamento marginal dos ganhos de cada setor em análise. Carrera-Fernandez e Santo (2008) entendem que a teoria da Escolha Racional considera o setor criminal como uma forma de atividade econômica.

Apesar das críticas sofridas, sobretudo por parte dos adeptos das correntes sociológicas, a teoria da Escolha Racional tem sido testada e adotada extensivamente em trabalhos empíricos (Grogger, 1991; Almeida, Haddad, & Hewings, 2005; Soares, 2015; Shikida, 2016; Quartieri, & Menezes, 2018; Koppens-teiner & Menezes, 2019; Eriksson, 2020). Cerqueira e Lobão (2004) apontam algumas variáveis que têm sido utilizadas pelos seguidores dessa teoria para identificar os determinantes da ação criminosa, quais sejam: salários, renda familiar *per capita*, desigualdade de renda, acesso a programas de bem-estar social, eficiência da polícia, adensamento populacional, magnitude das punições, inércia criminal, aprendizado social e educação.

Vem sendo frequentemente apontado pela literatura que quanto maior o percentual de pessoas residentes em áreas urbanas em uma dada localidade, maior serão seus índices de criminalidade (Araújo Junior & Fajnzylber, 2001; Kume, 2004; Santos & Kassouf, 2008; Anjos Junior et al., 2018b). De fato, a violência é um fenômeno que se mostra de maneira mais intensa em áreas urbanas, em decorrência da concentração de pessoas, renda e serviços. Ademais, conforme Cano e Santos (2007), ambientes mais urbanizados reduzem as chances de identificação e prisão dos criminosos. Nesta ótica, Glaeser e Sacerdote (1999) apontam que a prática criminosa é facilitada nos grandes centros urbanos devido às menores probabilidades de identificação do agressor. Para Glaeser, Sacerdote e Scheinkman (1996), o fenômeno da urbanização facilita a relação de grupos criminosos, melhora o aprendizado do crime e facilita a troca de informações.

Ademais, conforme já discutido, a criminalidade costuma estar associada a questões educacionais e de oportunidades de emprego (Ehrlich, 1975; Fajnzylber et al., 2002). Níveis mais elevados de capital humano tornam os indivíduos trabalhadores mais produtivos e capazes de obter maiores retornos no mercado de trabalho, reduzindo as chances de que estes recorram a uma vida de crimes. Ademais, maiores oportunidades de emprego reduzem a necessidade de se cometer crimes para adquirir os meios de subsistência.

Partindo agora para a ótica do planejamento, mais recentemente, tem-se observado que vários tipos de práticas criminosas podem ser abordadas e mitigadas a partir do uso de ferramentas de IA. A ideia geral consiste em empregar estes instrumentos como forma de mapear o comportamento criminoso e gerar relatórios que possam identificar padrões e tendências da atividade criminosa em determinadas regiões. A posse destas informações facilita o planejamento e a execução de políticas públicas de segurança e combate ao crime. Nessa linha, Loyola-González (2019) estuda o comportamento criminoso na Cidade do México através do emprego de IA como forma de entender e reduzir a criminalidade. No Brasil, Alves, Ribeiro e Rodrigues (2018) empregaram algoritmos de floresta aleatória para prever crimes e quantificar a influência de indicadores urbanos nos homicídios. Os autores constataram que o desemprego, o analfabetismo e a proporção da população masculina são responsáveis por explicar 78% da variação na criminalidade dos municípios brasileiros.

De fato, a elaboração de uma estratégia na área de segurança pública não pode negligenciar o fato de o criminoso agir, preferencialmente, em alguns locais em detrimento de outros. Tal preferência decorre de determinadas características que favorecem a prática criminosa em certas localidades, a exemplo do nível de renda, aspectos demográficos e fatores geográficos (Anjos Júnior, Lombardi-Filho & Amaral, 2018a). Há evidências de que a criminalidade não se espalha de maneira homogênea nos espaços urbanos, ou seja, ambientes como cidades ou bairros podem exibir resultados bem distintos uns dos outros no que se refere à incidência de atividades criminosas (Weisburd, Morris & Groff, 2009; Andresen e Malleson 2011; Weisburd, 2015; Paula, 2016; Gill, Wooditch & Weisburd, 2017; Pacheco Junior, 2019; Chainey & Monteiro, 2019; Vieira, 2019). Por esta razão, a polícia precisa dispor de instrumentos capazes de analisar dados e colher informações que possam guiar sua atuação frente ao comportamento delituoso.

Em estudo recente, Chainey, Pezzuchi, Rojas, Ramirez, Monteiro & Valdez (2019) analisaram a concentração da criminalidade em 42 cidades da América Latina a partir de casos de roubos e furtos. Os resultados da pesquisa sugerem que o crime está concentrado em níveis mais elevados nas cidades latino-americanas do que nos contextos industrializados ocidentais. Além disso, indicam que a redução da criminalidade poderia ser promovida através da implementação de programas voltados para áreas menores, onde o crime é observado em maior concentração. Na mesma linha, Chainey e Monteiro (2019) estudaram casos de roubo em um conjunto de cidades do Rio de Janeiro. Os autores observaram que, em períodos de aumento da criminalidade, tais delitos tendem a ocorrer mais intensamente nas áreas onde estas práticas já são concentradas. Isto ocorre pelo fato de que estes locais oferecerem condições estáveis e favoráveis ao crime.

Em termos de política pública, uma das estratégias mais adotadas pelos órgãos de segurança na atualidade consiste em policiar com maior intensidade os *hotspots*. Parte da literatura considera esta estratégia como sendo eficaz para garantir o controle dos índices de criminalidade (Braga et al., 2014; Weisburd et al., 2017), uma vez que essas áreas aparentam serem mais responsáveis pela dinâmica da criminalidade local (Ratcliffe, 2010).

### 3. Aspectos metodológicos

Esta seção discute os procedimentos metodológicos empregados no estudo. Inicialmente, descreve-se a base de dados utilizada, dando ênfase à adequação desta aos propósitos da pesquisa. Em seguida, o foco recai sobre a estratégia empírica adotada para identificar padrões de concentração de roubos de automóveis nos municípios que compõem a grande João Pessoa.

#### 3.1 Fonte e Tratamento dos Dados

A base de dados empregada consiste no registro de ocorrências de furtos e roubos de veículos (carros e motocicletas) realizados nos municípios de Bayeux, Cabedelo, João Pessoa e Santa Rita, que em conjunto formam a região da grande João Pessoa, nos anos de 2017, 2018 e 2019. Os dados da pesquisa são de acesso restrito e foram obtidos via solicitação junto à Secretaria de Estado da Segurança e da Defesa Social da Paraíba (cabe destacar que a seleção dos municípios e do período temporal contemplados no estudo ficou restrita à disponibilidade dos dados junto ao órgão responsável). Estes foram utilizados com o intuito de buscar padrões de concentração de roubos e furtos de veículos, identificando-se os bairros, dias e turnos de maior incidência destas atividades ilícitas.

De acordo com as estimativas populacionais do IBGE (2019), os municípios selecionados formam um agregado populacional composto por 1.110.217 habitantes, distribuídos da seguinte forma: Bayeux (96.880), Cabedelo (67.736), João Pessoa (809.015) e Santa Rita (136.586). Tais municípios concentram 27,63% da população de todo o estado da Paraíba. Adicionalmente, estas unidades apresentaram as seguintes densidades demográficas neste mesmo ano: João Pessoa (3.825,13); Bayeux (3.027,5); Cabedelo (2.123,4) e Santa Rita (187,93).

Ressalta-se que os dados empregados exibem um histórico completo do crime ocorrido, fornecendo hora, dia, mês e ano da ação, seguindo o seguinte formato: PMXXXX.XXXX.XXXX. Logo, a ficha de crime PM2005.0323.2002.00311 corresponde a um crime ocorrido no ano de 2005, no dia 23 de março, às 20 horas e dois minutos. Os últimos números representam o cadastro na fila. Além dessas informações, também consta na base o detalhamento da localização das ocorrências: bairro, logradouro, tipo de local (urbano, rural, residência, ruas e avenidas) e situação do crime (se consumado ou tentado). Finalmente, também cabe destacar que a coleta destes dados integra o Sistema de Informação Geográfica (SIG), o que permite identificar com exatidão o local de incidência do crime por meio da latitude e longitude dos pontos de ocorrência.

**Tabela 1:** Número de registros por tipo de ocorrência (2017 a 2019)

Tipo de ocorrência	N
Perturbação do sossego/tranquilidade	16.792
Conflito interpessoal (Vias de Fato - Briga)	10.696
Roubo a transeunte (pessoa na rua)	10.371
Averiguação de atitude suspeita	8.097
Violência doméstica	6.023
Ameaça	5.032
Furto	3.496
Lesão corporal (Agressão - Espancamento)	3.136
Busca terrestre a animal	2.601
Veículo localizado	2.579
Roubo de motocicleta	2.327
Homicídio doloso	1.980
Violação de domicílio	1.950
Roubo a estabelecimento comercial	1.931
Apoio a pessoa	1.921
Embriaguez e desordem	1.770
Furto de veículo	1.652
Colisão/Choque - com vítima não fatal	1.490
Roubo de veículo	1.406
Tráfico de drogas	1.349

Fonte: elaboração própria a partir dos dados da Secretaria de Estado da Segurança e da Defesa Social da Paraíba.

A fim de ilustrar os dados gerais, a Tabela 1 exhibe os registros policiais por tipo de ocorrência,

entre 2017 e 2019, na região da grande João Pessoa. Verifica-se que a maior parte dos registros dizem respeito à questão de perturbação do sossego e da tranquilidade, a exemplo das situações de poluição sonora. Em seguida, aparecem os casos de conflito interpessoal e roubos a transeunte, com mais dez mil casos cada ao longo do período. Acerca das ocorrências de furtos e roubos de automóveis (carros e motocicletas), que correspondem às informações efetivamente usadas neste estudo, estes totalizaram mais de 5.300 casos ao longo desses três anos, ocupando o sexto lugar como registro mais comum. Cabe destacar, ainda, que esta modalidade de crime costuma apresentar uma baixa taxa relativa de subnotificação quando comparado, por exemplo, aos casos de violência doméstica e ameaças.

### 3.2 Algoritmos de Aprendizado de Máquinas

A fim de explorar a distribuição das ocorrências de furtos e roubos de automóveis no tempo e no espaço, optou-se por fazer uso de algoritmos de clusterização. Esses algoritmos procuram classificar observações em grupos específicos (*clusters*), agrupando observações com características semelhantes. As características utilizadas neste trabalho foram a localização geográfica e o horário de cada ocorrência. Os diferentes algoritmos se diferenciam por suas estratégias de mensuração de similaridade. Algoritmos particionais precisam que o número de *clusters*,  $K$ , seja definido *a priori*, a exemplo do K-Means (Macqueen, 1967) e mensuram a similaridade a partir do valor médio dos objetos de um *cluster*. Por outro lado, algoritmos baseados em densidade procuram agrupar em *clusters* os objetos que formam uma região de alta densidade.

Os algoritmos baseados em densidade, como o Clusterização Espacial Baseada em Densidade de Aplicações com Ruído (*Density-Based Spatial Clustering of Applications with Noise*, DBSCAN), OPTICS, DENCLUE e CURD, têm a vantagem de não exigirem a predeterminação de  $K$ . O DBSCAN, em particular, é capaz de identificar grupos de objetos com formatos arbitrários em qualquer banco de dados  $X$  (Ester, Kriegel, Sander & Xu, 1996). Isso o distingue de outros algoritmos particionais que são apropriados apenas para *clusters* convexos e esféricos. Essa flexibilidade o torna mais adequado para dados de crimes, que geralmente se agrupam em formatos arbitrários. Além disto, DBSCAN permite a identificação de ruídos e *outliers*. Por estas razões, optou-se por empregar tal método neste artigo.

#### 3.2.1 *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN)

Dado um conjunto de dados  $X$ , contendo  $N$  objetos,  $X = \{x_1, x_2, \dots, x_n\}$ , o processo de particionar  $X$  em  $C = \{C_1, \dots, C_k\}$ , baseado em alguma medida de similaridade, é chamado de clusterização. Nesta especificação, cada  $C_i$  representa um *cluster*, de modo que  $C_i \subseteq X$ , ( $i = 1, 2, \dots, k$ ),  $\bigcap_{i=1}^k C_i = \emptyset$  e  $\bigcup_{i=1}^k C_i = D$ .

No algoritmo DBSCAN, a densidade associada com um ponto é obtida ao se contar o número de pontos em uma região de raio especificada ao redor do ponto. Pontos com uma densidade acima de um valor especificado são construídos como *clusters*. Essa densidade local é denotada densidade ( $x_i$ ) na vizinhança do  $i$ -ésimo objeto  $x_i \in X$ , onde  $N_\epsilon(x_i)$  representa os objetos na vizinhança de um raio  $\epsilon$  de  $x_i$ . Logo,  $N_\epsilon(x_i) = \{x_j | \forall j, \text{dist}(x_j, x_i) < \epsilon\}$ .

Dentro desta vizinhança, três tipos de objetos podem ser identificados: objetos centrais, objetos de fronteira e ruídos. Dado um número mínimo de objetos na vizinhança, *MinPts*, um objeto central se refere a pontos tais que a vizinhança de um dado raio contenha no mínimo *MinPts* de outros objetos, de modo que  $x_{\text{central}}$  é definido se a densidade ( $x_{\text{central}} \geq \text{MinPts}$ ). Um objeto de fronteira, por seu turno, é identificado dessa forma se a densidade ( $x_{\text{fronteira}} < \text{MinPts}$ ) e um objeto central existe tal que  $x_{\text{fronteira}} \in N_\epsilon(x_{\text{central}})$ . Dito de outra forma, o objeto de fronteira pertence a vizinhança de um objeto central se a densidade é menor que *MinPts*. Por fim, um objeto ruído,  $x_{\text{ruído}}$ , é um objeto que não é classificado nem como central nem como de fronteira. De modo que se ocorre na vizinhança de um dado raio, existem menos objetos que *MinPts*, e nenhum deles é caracterizado como um objeto central.

Para determinar se um conjunto de pontos é similar o suficiente para ser considerado um *cluster*, necessita-se de uma medida de distância,  $\text{dist}(x_i, x_j)$ , entre dois pontos. Considerando a característica espacial do conjunto de dados  $X$ , utilizou-se a fórmula de Haversine, que informa a distância entre dois pontos de uma esfera a partir de suas informações de latitudes e longitudes.

O ângulo central  $\Theta$  entre dois pontos em uma esfera é dado por  $\Theta = d/r$ , onde  $d$  é a distância entre dois pontos ao longo de um círculo máximo de uma esfera e  $r$  é o raio da esfera. A fórmula de Haversine permite que o seno verso de  $\Theta$  seja computado a partir da latitude e longitude de dois pontos:



$$hav(\theta) = hav(\varphi_2 - \varphi_1) + \cos(\varphi_1) \cos(\varphi_2) hav(\lambda_2 - \lambda_1)$$

em que  $\lambda_i$  são as longitudes em radianos dos pontos e  $\varphi_i$  as latitudes em radianos. Após algumas operações, a distância  $d$  pode ser obtida como:

$$d = 2\pi \arcsin \left( \sqrt{\sin^2 \left( \frac{\varphi_2 - \varphi_1}{2} \right) + \cos(\varphi_1) \cos(\varphi_2) \sin^2 \left( \frac{\lambda_2 - \lambda_1}{2} \right)} \right)$$

#### 4. Resultados

Nesta seção, são descritos os principais resultados do estudo. Inicialmente, têm-se os resultados da análise descritiva. Em seguida, analisa-se os resultados obtidos pelo algoritmo DBSCAN referente à identificação de padrões de roubos e furtos de veículos ocorridos na grande João Pessoa.

##### 4.1 Análise Descritiva

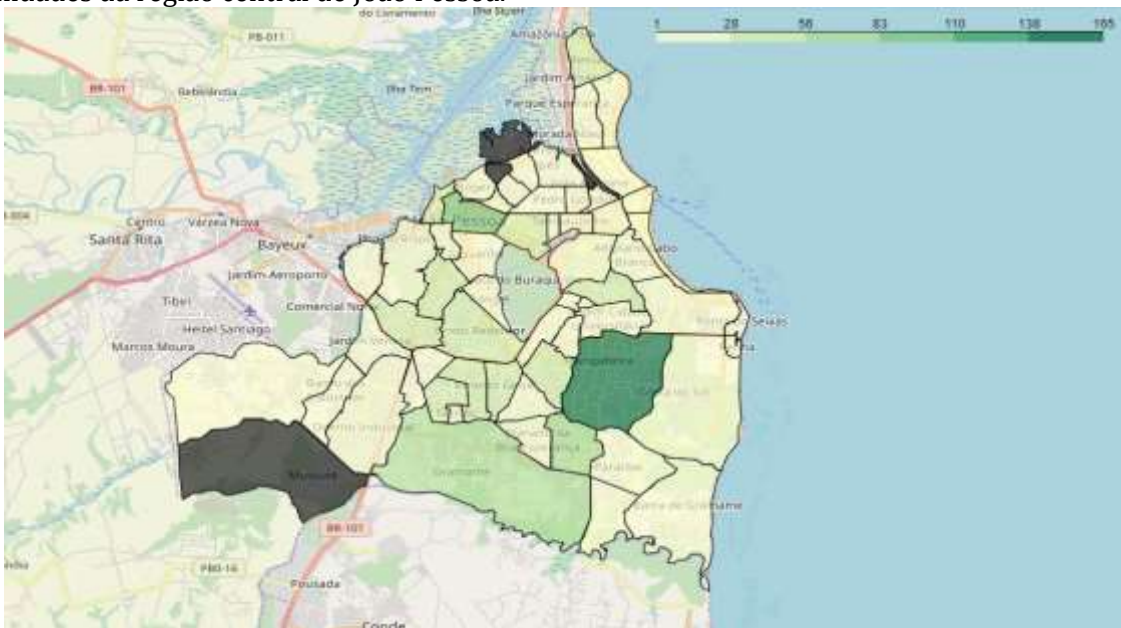
Na Tabela 2 tem-se a frequência de furtos e roubos de automóveis na região composta pelos municípios da grande João Pessoa. É interessante observar a tendência de redução dos casos totais, principalmente, a queda no número de roubos entre 2018 e 2019.

**Tabela 2:** Frequência de furtos e roubos de automóveis nos municípios da grande João Pessoa

	2017	2018	2019	Total
Furto de veículo	578	524	550	1.652
Roubo de veículo	1.314	1.311	1.108	3.733
Total	1.892	1.835	1.658	5.385

Fonte: elaboração própria a partir dos dados da Secretaria de Estado da Segurança e da Defesa Social da Paraíba.

Contudo, como se sabe, dados agregados podem esconder uma variação substancial entre as diferentes regiões. Conforme discutido anteriormente, quanto mais urbanizadas forem as regiões, menores serão as probabilidades de identificação e prisão dos criminosos. Assim, de forma indireta, a urbanização acaba impulsionando a criminalidade. De modo a ilustrar esta situação, a Figura 2 mostra como os roubos e furtos de veículos se configuram em um fenômeno concentrado, com aumento do risco nas proximidades da região central de João Pessoa.



**Figura 2.** Índice de roubos e furtos de veículos em João Pessoa (por 100 mil habitantes)

Fonte: elaboração própria a partir dos dados da Secretaria de Estado da Segurança e da Defesa Social da Paraíba.

A Tabela 3, por sua vez, reforça essa questão da concentração ao exibir os bairros de João Pessoa


com mais elevadas ocorrências de furtos e roubos de automóveis. A região do Centro aparece em primeiro lugar, com uma taxa bem mais elevada do que a registrada nas demais localidades. Cabe ressaltar, porém, que o Centro tem como particularidade o fato de muitas pessoas transitarem neste bairro, mas sem residir nele. De fato, a região central é o local de trabalho de parcela significativa da população, além de concentrar uma série de serviços importantes. Tais características explicam por que a ocorrência de crimes é tão elevada nesta região, apesar de sua população não ser tão alta. Em seguida, tem-se o bairro de Barra de Gramame, cujo destaque ficou por conta do elevado número de roubo de carros. Além destes dois, vale ressaltar que os bairros Ponta do Seixas, Distrito Industrial e Varadouro também apresentaram taxas de ocorrência acima de 2.000 por 100 mil habitantes.

**Tabela 3:** Bairros com maiores números de ocorrências por 100 mil habitantes no município de João Pessoa (2017 a 2019)

	Furto de veículo	Roubo de veículo	Total
Centro	2.881,4	3.430,3	6.311,7
Barra de Gramame	1.152,7	4.322,8	5.475,5
Ponta do Seixas	2.109,7	1.476,8	3.586,5
Distrito Industrial	5.29,9	1.748,8	2.278,7
Varadouro	8.33,3	1.209,7	2.043,0
Penha	6.47,7	1.295,3	1.943,0
Centro	8.13,5	968,5	1.782,0
Bessa	3.43,6	1.282,8	1.626,5
Bancários	4.46,8	1.003,1	1.449,9
Ernesto Geisel	2.82,0	1.149,2	1.431,2

Fonte: elaboração própria a partir dos dados da Secretaria de Estado da Segurança e da Defesa Social da Paraíba.

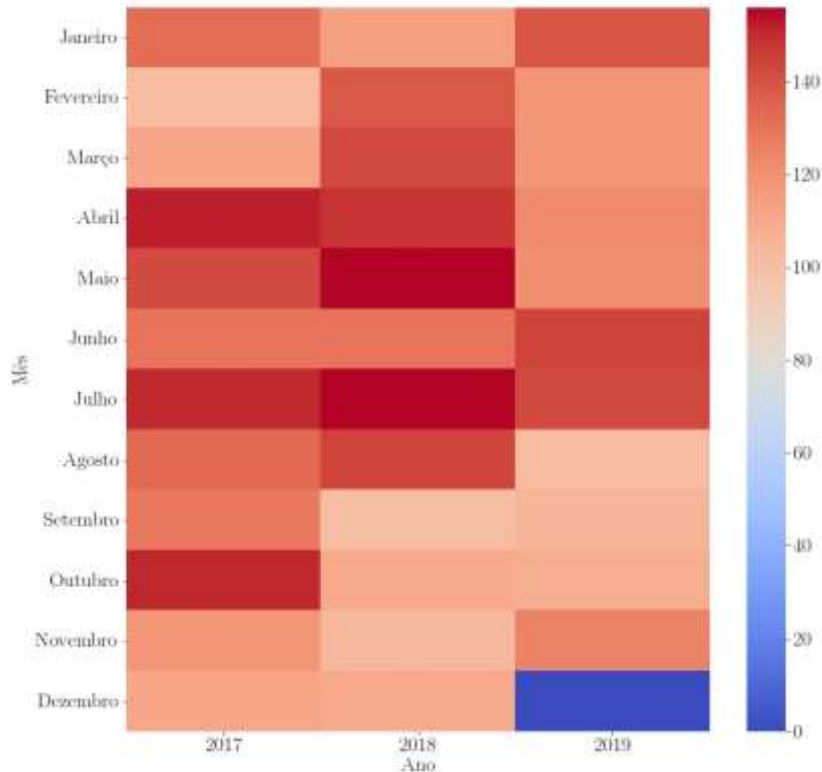
Adicionalmente, também é importante explorar o efeito da dimensão temporal na concentração deste tipo de crime. A Figura 3 indica que os crimes na grande João Pessoa se concentram não apenas no espaço, mas também em determinados períodos, com boa parte das ocorrências acontecendo no turno da noite e durante dias úteis da semana. Porém, se uma parte substancial dessas ocorrências se dá contra veículos estacionados fora da residência dos proprietários, talvez não seja possível encontrar um padrão de concentração tão forte quanto o observado em outros crimes predatórios, como no caso de roubos e furtos contra pessoas. Para este caso específico, entre as ocorrências registradas na região em questão, quase 85% dos roubos e furtos de veículos ocorreram em vias ou locais de acesso público.



**Figura 3.** Ocorrências por horário e dia da semana na região da grande João Pessoa (2017 a 2019)

Fonte: elaboração própria a partir dos dados da Secretaria da Segurança e da Defesa Social da Paraíba.

Finalmente, na Figura 4, é possível observar como os crimes se distribuem ao longo dos meses do ano. Verifica-se uma maior concentração de furtos e roubos de automóveis nos meses intermediários, tais como maio e julho, ao passo que nos meses finais as ocorrências incidem com menos intensidade. Também é interessante observar a expressiva redução dos casos de furtos e roubos de automóveis em 2019, tendência esta que foi observada para a maior parte das Unidades da Federação.



**Figura 4.** Ocorrências conforme os meses do ano na região da grande João Pessoa (2017 a 2019)

Fonte: elaboração própria a partir dos dados da Secretaria de Estado da Segurança e da Defesa Social da Paraíba.

#### 4.2 Identificando *Hotspots*

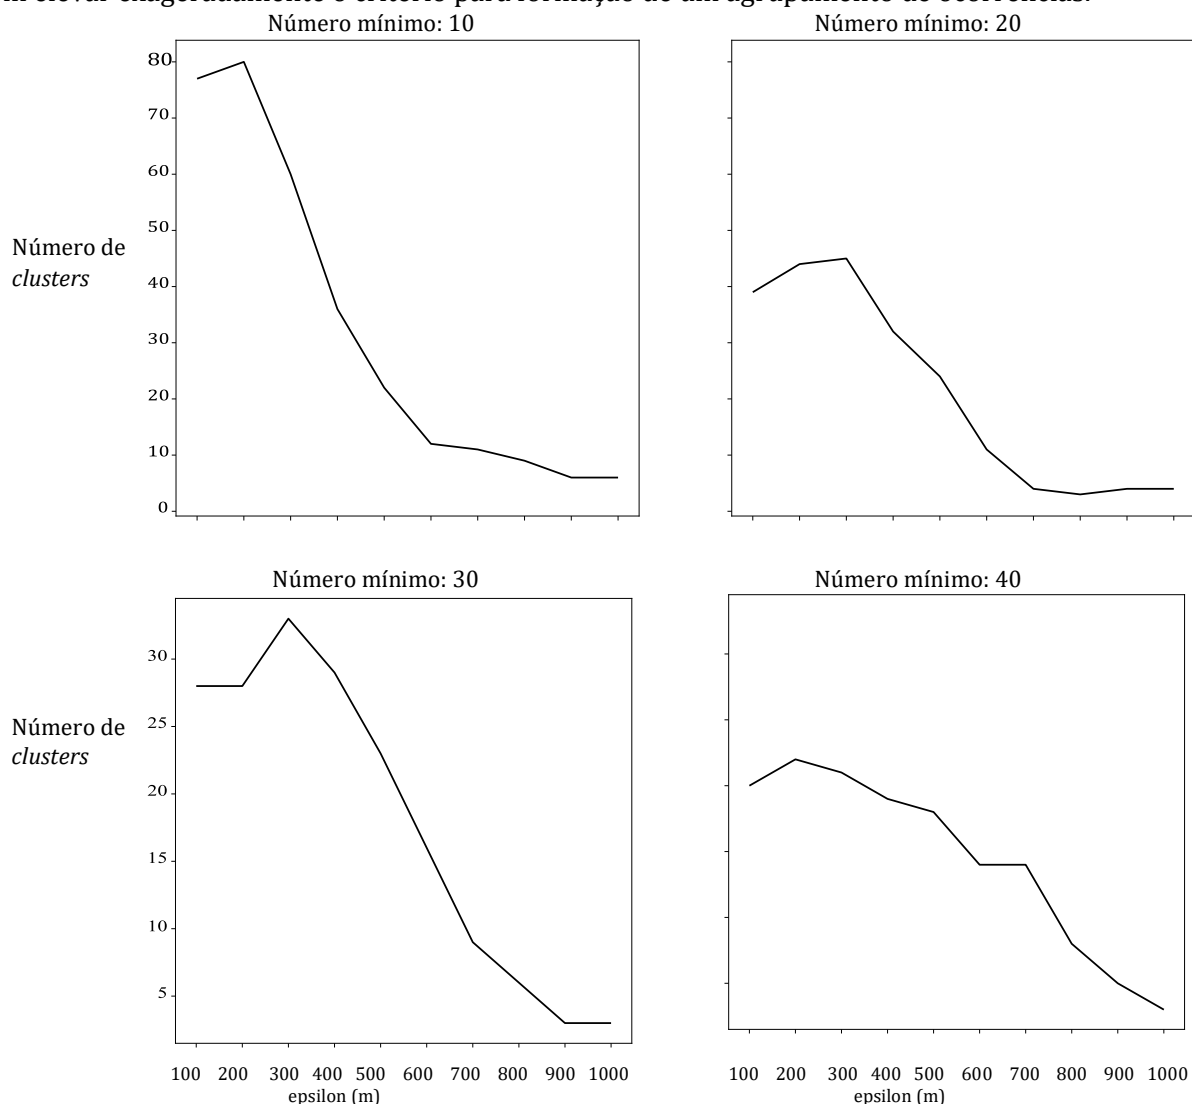
Há razões para se acreditar que a ação criminosa não é totalmente aleatória no espaço e no tempo, principalmente nos crimes contra o patrimônio. O criminoso parece selecionar vítimas e locais de atuação de modo a maximizar os ganhos esperados de suas ações. Nessa abordagem, os criminosos são considerados agentes racionais, agindo de acordo com um processo de otimização que potencializa seus ganhos individuais para cada tomada de decisão, sujeita a custos como prisão e condenação. A racionalidade pressupõe, por exemplo, que penas mais rígidas podem reduzir a criminalidade porque causam dissuasão na ação criminosa (Becker, 1968). Dessa forma, o crime parece não ser espalhado de forma homogênea no espaço, existindo características que explicariam as diferenças nas taxas observadas entre as regiões.

Em suma, a atuação criminosa escolhe racionalmente alguns ambientes em detrimento de outros, e tal comportamento gera incidência criminosa não homogênea no espaço. Com isso, observa-se uma concentração de crimes em alguns locais determinados (*hotspots*). A literatura já vem apontando estudos que identificaram uma distribuição desigual do crime no território, com situações em que pequenos locais concentram até mesmo a metade de todos os crimes ocorridos na região (Pierce, Spaar, & Briggs, 1988; Weisburd et al., 1992; Braga, 2007). Com isso, surge a necessidade de identificar estes pontos de maior incidência de crimes, os *hotspots*, a fim de empregar o efetivo policial de maneira preventiva e mais eficaz (Eck, 1997; Weisburd & Eck, 2004).

Para a construção de *clusters* e identificação desses *hotspots*, o algoritmo DBSCAN necessita de dois hiperparâmetros:  $\epsilon$  e *MinPts*. Entretanto, a escolha desses valores envolve domínio acerca dos da-

dos tratados, uma vez que diferentes combinações podem produzir resultados bastante distintos e muitas vezes não razoáveis. Por exemplo, na Figura 5, é possível observar como o número de *clusters* produzidos se diferencia a depender dos parâmetros escolhidos. Utilizando todas as 5.385 ocorrências para o período em análise, com 10 vizinhos e um  $\epsilon$  de 100 metros, o algoritmo é capaz de produzir 80 *hotspots*. Por outro lado, ao definir um  $\epsilon$  de 1.000 metros e o número mínimo de vizinhos como 40, as ocorrências são agrupadas em apenas três grandes *clusters*.

Ao se escolher um valor de  $\epsilon$  pequeno, particiona-se *clusters* maiores em várias pequenas aglomerações com características muito semelhantes. A literatura aponta que atributos específicos, como má iluminação e a presença de uma construção abandonada ou de um estabelecimento comercial, são importantes para explicar o comportamento criminoso em uma localidade específica (Braga et al., 2014), o que pode tornar interessante a identificação de pequenos *clusters* geográficos. Já a escolha de um  $\epsilon$  demasiadamente grande não é capaz de produzir informação útil na produção de uma intervenção específica. Ademais, na escolha de *MinPts* um valor muito pequeno pode fazer com que determinadas regiões tenham pontos agrupados por mero acaso. No outro extremo, valores muito altos de *MinPts* podem elevar exageradamente o critério para formação de um agrupamento de ocorrências.



**Figura 5.** Número de *clusters* produzidos pelo algoritmo DBSCAN

Fonte: elaboração própria a partir dos dados da Secretaria da Segurança e da Defesa Social da Paraíba.


Desse modo, como exercício empírico, definiu-se um  $\epsilon$  de 500 metros e um *MinPts* de 10 vizinhos. A Tabela 4 mostra como o número de *hotspots* varia ao longo da semana e dos turnos do dia. Como esperado, o número de *hotspots* calculados pelo algoritmo é maior durante os dias de semana, sobretudo no turno da noite.

**Tabela 4:** Número de *clusters* por dia da semana e turno


	Madrugada	Manhã	Tarde	Noite
Segunda-feira	1	4	2	5
Terça-feira	1	2	5	9
Quarta-feira	1	1	4	6
Quinta-feira	2	2	1	1
Sexta-feira	1	1	1	4
Sábado	1	1	4	6
Domingo	1	1	4	9

Fonte: elaboração própria a partir dos dados da Secretaria da Segurança e Defesa Social da Paraíba.

A Figura 6 mostra exercício semelhante, mas exibindo os *hotspots* definidos por turno do dia (Usando  $\epsilon$  de 500 metros, MinPts de 20 vizinhos e aplicando para todas as ocorrências notificadas em cada turno específico). Para o turno da madrugada (00:00 às 05:59), observa-se apenas 7 *hotspots* identificados; no período da manhã (06:00 às 11:59), 17; à tarde (12:00 às 17:59), 16 *hotspots*; e no período noturno (18:00 às 23:59), 22 agrupamentos de ocorrências. Para o período noturno, das 2.002 ocorrências registradas neste horário, 660 foram descartadas como ruídos e não pertencem a nenhum *cluster* específico. Já os demais pontos foram agrupados nos 22 *hotspots* de variados tamanhos e formatos, sendo o maior deles localizado na região compreendida pelos bairros do Ernesto Geisel, Costa e Silva e Funcionários (228 observações), e o menor na região do Bairro de Várzea Nova, em Santa Rita (22 pontos).



(a) Madrugada



(b) Manhã



(c) Tarde



(d) Noite

**Figura 6** Número de *hotspots* por turno na grande João Pessoa (2017 a 2019)

Fonte: elaboração própria a partir dos dados da Secretaria da Segurança e da Defesa Social da Paraíba.

## 5. Relevância dos resultados para fins de planejamento, gestão e política pública

Os resultados encontrados sugerem que os crimes de furto e roubo de veículos ocorridos na grande João Pessoa se distribuem de forma desigual no tempo e no espaço. Tais informações podem ser usadas para tornar mais eficiente a alocação de recursos por parte dos agentes econômicos, principalmente, no sentido de subsidiar a tomada de decisão de famílias, empresas, gestores e entidades do setor público.

No caso das famílias, estas podem tomar medidas preventivas mais eficazes para se protegerem das referidas práticas criminosas. Vem sendo recorrente que os indivíduos utilizem seu próprio veículo como fonte de renda, trabalhando em serviços de moto táxi, moto *boy*, motorista de Uber, frete, dentre outros. Nesse sentido, os resultados buscam auxiliar tais agentes ao reduzir a assimetria de informação, indicando horários e locais mais seguros para estacionar e circular.

O setor empresarial e os gestores privados, por sua vez, também podem fazer uso dos achados da pesquisa por meio da proteção de sua frota com a seleção de locais e horários mais seguros para a circulação e parada de seus veículos. Além disso, há segmentos como bancos e seguradoras que podem incorporar estas informações para elaborar *scores* de risco mais acurados para os seus clientes.

Finalmente, acerca do setor público, este tem condições de incorporar os resultados à sua política de segurança. Com isso, torna-se possível o melhor emprego de viaturas e do efetivo policial, privilegiando os *hotspots* formados ao longo da grande João Pessoa. Ademais, tem-se condições de otimizar o uso de recursos devido à redução de custos explícitos (combustível, por exemplo) e implícitos (custo de oportunidade de rondar em certos bairros). Logo, torna-se possível, a um mesmo custo e tudo o mais constante, ofertar um serviço de segurança mais eficiente e ajustado aos anseios da sociedade.

## 6. Considerações finais

Este estudo teve por objetivo identificar padrões de concentração espacial de furtos e roubos de automóveis (carros e motos) na região da grande João Pessoa. Com isso, buscou-se verificar quais bairros, dias e turnos se destacam pela incidência destas atividades ilícitas, subsidiando a tomada de decisão por parte dos agentes econômicos e produzindo informações úteis para o emprego mais eficiente do efetivo policial.

Os dados utilizados foram obtidos junto à Secretaria de Estado da Segurança e da Defesa Social da Paraíba, e fornecem um histórico detalhado do crime ocorrido, contemplando hora, dia, mês e ano da ação, juntamente com o detalhamento da localização das ocorrências. Acerca da estratégia empírica adotada, utilizou-se um algoritmo de clusterização espacial baseado em densidade, o DBSCAN, que apresenta as vantagens de não exigir a predeterminação do número de *clusters*, encontrar *clusters* com formas arbitrárias, e distinguir pontos caracterizados como ruídos. Por meio do DBSCAN, foi possível identificar *hotspots* de ações criminosas, de modo a determinar os bairros que concentram mais ocorrências de crimes.

Os resultados encontrados indicaram que a região do Centro de João Pessoa se destaca por possuir uma taxa de furto e roubo de automóveis bem mais elevada do que a registrada nas demais localidades. Em seguida, os bairros Barra de Gramame, Ponta do Seixas, Distrito Industrial e Varadouro foram os que exibiram taxas mais altas. Adicionalmente, também se verificou que tais crimes se concentram não apenas no espaço, mas também em determinados períodos, sobretudo no turno da noite e durante dias úteis da semana.

No que diz respeito à identificação de *hotspots*, observou-se que o número destes é maior durante os dias de semana, no período noturno. Tais pontos foram agrupados em 22 *hotspots*, sendo o maior localizado na região do bairro do Ernesto Geisel, Costa e Silva e Funcionários, ao passo em que o menor se encontra na região do Bairro de Várzea Nova.

É importante frisar que os achados dessa pesquisa possuem importantes limitações. Primeiramente, em função da ausência de dados disponíveis, não foi possível considerar na análise certas características em nível de bairro, a exemplo da renda dos moradores, nível educacional e percentual de ruas bem iluminadas. Também se deve ter em mente que o método adotado, o DBSCAN, é sensível à escolha dos seus hiperparâmetros, o que exige domínio acerca dos dados tratados.

Como proposta futura de pesquisa seria interessante estudar como se dá a concentração espacial das demais modalidades de crimes (contra a vida, tráfico de drogas, conflitos violentos etc.) e verificar se o mesmo padrão se repete para os diferentes casos. Outro avanço interessante e com potencial de aplicação para fins de planejamento consiste na elaboração de um modelo de previsão de ocorrência de

crimes. Isso permitiria estimar o risco de vitimização em cada localidade, servindo como guia para uma melhor alocação de viaturas, por exemplo. Já em termos metodológicos, a fim de tornar o modelo mais robusto à seleção dos parâmetros, o método Hierarchical DBSCAN (H-DBSCAN) pode ser utilizado. Caso haja interesse em incorporar as dimensões espaciais e temporais simultaneamente, o Spatial-Temporal DBSCAN (ST-DBSCAN) seria uma alternativa. Ambos os métodos, entretanto, são mais difíceis de serem implementados, além de serem mais intensivos em termos computacionais.

Por fim, acredita-se que os resultados encontrados nesta pesquisa têm potencial para auxiliar a elaboração de um planejamento mais eficaz de segurança pública nos bairros da grande João Pessoa. Ao se determinar as regiões com maior concentração de atividades criminosas, juntamente com o turno e dia da semana, tem-se a possibilidade de deslocar o efetivo policial para as áreas mais necessitadas, de modo a se alcançar maior eficiência na prevenção de crimes e captura de criminosos.

## Referências

- Agnew, R., & White, H. R. (1992). An Empirical Test of General Strain Theory. *Criminology*, 30(4), 475–500.
- Almeida, E. S., Haddad, E. A., & Hewings, G. J. D. (2005). The Spatial Pattern of Crime in Minas Gerais: an exploratory analysis. *Economia Aplicada*, 9(1), 39–55.
- Alves, L. G. A.; Ribeiro, H. V., & Rodrigues, F. A. (2018). Crime Prediction Through Urban Metrics and Statistical Learning. *Physica A*, 505(1), 435–443.
- Andrade, L. H., Wang, Y. P., Andreoni, S., Silveira, C. M., Alexandrino-Silva, C., Siu, E. R., & Viana, M. C. (2012). Mental Disorders in Megacities: findings from the São Paulo megacity Mental Health Survey, Brazil. *PLoS ONE* 7(2), e31879.
- Andresen, M. A., & Malleson, N. (2011). Testing the Stability of Crime Patterns: implications for theory and policy. *Journal of Research in Crime and Delinquency*, 48(1), 58-82.
- Anjos Júnior, O. R. D., Lombardi-Filho, S. C., & Amaral, P. V. M. D. (2018a). Determinantes da Criminalidade na Região Sudeste do Brasil: uma aplicação de painel espacial. *Economía, Sociedad y Territorio*, 18(57), 525-556.
- Anjos Júnior, O. R., Lombardi Filho, S. C., da Silva Ciríaco, J., & da Silva, M. V. B. (2018b). Testando a Hipótese de Dependência Espacial na Taxa de Crime dos Municípios da Região Sul do Brasil. *DRd - Desenvolvimento Regional em Debate*, 8(1), 118-141.
- Araújo Junior, A. F. D. & Fajnzylber, P. (2001). O que Causa a Criminalidade Violenta no Brasil? Uma Análise a partir do Modelo Econômico do Crime: 1981 a 1996 (CEDEPLAR Working Paper nº. 162). Recuperado de [https://www.researchgate.net/publication/4927511\\_O\\_que\\_causa\\_a\\_criminalidade\\_violenta\\_no\\_Brasil\\_Uma\\_analise\\_a\\_partir\\_do\\_modelo\\_economico\\_do\\_crime\\_1981\\_a\\_1996](https://www.researchgate.net/publication/4927511_O_que_causa_a_criminalidade_violenta_no_Brasil_Uma_analise_a_partir_do_modelo_economico_do_crime_1981_a_1996).
- Arneklev, B. J., Grasmick, H. G., Tittle, C. R., & Bursik Jr, R. J. (1993). Low Self-Control and Imprudent Behavior. *Journal of Quantitative Criminology*, 9(3), 225–247.
- Bartz, M., Quartieri, E., & Menezes, G. (2018). Criminalidade no Rio Grande do Sul: uma análise econométrica para os COREDES no ano de 2010. *Revista Brasileira de Estudos Regionais e Urbanos*, 12(1), 110-128.
- Becker, G. (1968). Crime and Punishment: an economic approach. *Journal of Political Economy*, 76(2), 169–217.
- Becker, G. S., & Yona Rubinstein. (2011). Fear and the Response to Terrorism: An Economic Analysis. CEP Discussion Paper Nº 1079.
- Biswas, A. A., & Basak, S. (2019, setembro). Forecasting the Trends and Patterns of Crime in Bangladesh using Machine Learning Model. *Proceedings of the 2nd International Conference on Intelligent Communication and Computational Techniques (ICCT)*, Jaipur, Rajasthan, Índia, 2. Recuperado de <https://ieeexplore.ieee.org/document/8969031>.
- Braga, A. A. Effects of Hot Spots Policing on Crime. (2007). *Campbell Systematic Reviews*, 3(1), 1–36.
- Braga, A. A., Papachristos, A. V., & Hureau, D. M. (2014). The Effects of Hot Spots Policing on Crime: an updated systematic review and meta-analysis. *Justice Quarterly*, 31(4), 633–663.
- Bruinsma, G. J. (1992). Differential Association Theory Reconsidered: an extension and its empirical test. *Journal of Quantitative Criminology*, 8(1), 29–49.
- Cano, I. & Santos, N. (2007). *Violência Letal, Renda e Desigualdade no Brasil* (2a ed.). Rio de Janeiro: 7 Letras.

- Cano, I.; Soares, G. D. (2002). *As Teorias sobre as Causas da Criminalidade*. Rio de Janeiro: IPEA.
- Cardia, N., & Cinoto, R. (2012). Pesquisa nacional, por amostragem domiciliar, sobre atitudes, normas culturais e valores em relação à violação de direitos humanos e violência: um estudo em 11 capitais de estado. *São Paulo: Núcleo de Estudos da Violência da Universidade de São Paulo*.
- Carrera-Fernandez, J., & Pereira, R. (2001). Diagnóstico da Criminalidade na Bahia: uma análise a partir da teoria econômica do crime. *Revista Econômica do Nordeste*, 32, 792-806.
- Carrera-Fernandez, J., & Santo, A. P. E. (2008). A Criminalidade sob a Ótica do Presidiário: o caso da penitenciária Lemos de Brito, na Bahia. *Revista Desenhavia*, 5(9), 233-258.
- Cerqueira, D. R. (2014). *Causas e Consequências do Crime no Brasil*. Banco Nacional de Desenvolvimento Econômico e Social.
- Cerqueira, D., & Lobão, W. (2004). Determinantes da Criminalidade: arcabouços teóricos e resultados empíricos. *DADOS - Revista de Ciências Sociais*, 47(2), 233-269.
- Chainey, S. P., & Monteiro, J. (2019). The Dispersion of Crime Concentration During a Period of Crime Increase. *Security Journal*, 32(3), 324-341.
- Chainey, S. P., Pezzuchi, G., Rojas, N. O. G., Ramirez, J. L. H., Monteiro, J., & Valdez, E. R. (2019). Crime Concentration at Micro-Places in Latin America. *Crime Science*, 8(1), 5.
- Costa, I. F., & Balestreri, R. B. (Orgs.). (2010). *Segurança Pública no Brasil: um campo de desafios*. Salvador: EDUFBA.
- Eck, J. E. (1997). *Preventing Crime at Places*. College Park: University of Maryland, Department of Criminology and Criminal Justice.
- Ehrlich, I. (1975). On the Relation Between Education and Crime. In: F. T. Juster (Org.), *Education, Income, and Human Behavior* (Cap. 12, pp. 313 - 338). Cambridge: NBER
- Eriksson, K. (2020). Education and Incarceration in the Jim Crow South Evidence from Rosenwald Schools. *Journal of Human Resources*, 55(1), 43-75.
- Ester, M., Kriegel, H-P., Sander, J., & Xu, X. (1996, agosto). A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, Portland, OR, Estados Unidos, 2. Recuperado de <https://www.aaai.org/Papers/KDD/1996/KDD96-037.pdf>.
- Fajnzylber, P., Lederman, D., & Loayza, N. (2002). What Causes Violent Crime? *European Economic Review*, 46(7), 1323-1357.
- Gibbs, J. J., Giever, D., & Martin, J. S. (1998). Parental Management and Self-Control: an empirical test of Gottfredson and Hirschi's general theory. *Journal of Research in Crime and Delinquency*, 35(1), 40-70.
- Gill, C., Wooditch, A., & Weisburd, D. (2017). Testing the "Law of Crime Concentration at Place" in a Suburban Setting: implications for research and practice. *Journal of Quantitative Criminology*, 33(3), 519-545.
- Glaeser, E. L., & Sacerdote, B. (1999). Why is There More Crime in Cities? *Journal of Political Economy*, 107(S6), S225-S258.
- Glaeser, E. L., Sacerdote, B., & Scheinkman, J. A. (1996). Crime and Social Interactions. *The Quarterly Journal of Economics*, 111(2), 507-548.
- Gomes, C. E., Evangelista, T. F., Lima, R. L., & Parré, J. L. (2017). Determinantes do crime nos municípios de Minas Gerais e seus possíveis spillovers espaciais. *Revista Economia Ensaios*, 31(2).
- Gottfredson, M. R., & Hirschi, T. (1990). *A General Theory of Crime*. California: Stanford University Press.
- Grogger, J. Certainty vs. Severity of Punishment. (1991). *Economic Inquiry*, 29(2), 297-309.
- Guimarães, J. L. C. (2014). Motivações do crime segundo o criminoso: condições econômicas, interação social e herança familiar. *Revista Brasileira de Segurança Pública*, 8(1).
- Junger-Tas, J. An Empirical Test of Social Control Theory. (1992). *Journal of Quantitative Criminology*, 8(1), 9-28.
- Koppensteiner, M., & Menezes, L. (2019). Violence and Human Capital Investments.
- Kumar, R., & Nagpal, B. (2019). Analysis and Prediction of Crime Patterns Using Big Data. *International Journal of Information Technology*, 11(1), 799-805.
- Kume, L. (2004, dezembro). Uma Estimativa dos Determinantes da Taxa de Criminalidade Brasileira: uma aplicação em painel dinâmico. *Anais do XXXII Encontro Nacional de Economia*, João Pessoa, PB, Brasil, 32. Recuperado de <http://www.anpec.org.br/encontro2004/artigos/A04A148.pdf>.



- Loyola-González, O. (2019). Understanding the Criminal Behavior in Mexico City through an Explainable Artificial Intelligence Model. *Proceedings of the 18th Mexican International Conference on Artificial Intelligence*, Xalapa, Veracruz, México, 18. Recuperado de <https://link.springer.com/conference/micai>.
- Macqueen, J. (1967, junho). Some Methods for Classification and Analysis of Multivariate Observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, Oakland, CA, Estados Unidos, 50. Recuperado de <https://pdfs.semanticscholar.org/a718/b85520bea702533ca9a5954c33576fd162b0.pdf>.
- Mccarthy, B. (1996). The Attitudes and Actions of Others: Tutelage and Sutherland's theory of differential association. *The British Journal of Criminology*, 36(1), 135-147.
- Mckenzie, R. B., & Tullock, G. (2012). *The New World of Economics: a remake of a classic for new generations of economics students* (6a. ed.). New York: Springer
- Oliveira, C. A., & Arcaro, D. A. (2016). Efeitos de Dissuasão do Mercado de Trabalho sobre o Crime na Região Metropolitana de Porto Alegre. *Economic Analysis of Law Review*, 7(2), 577-597.
- OMS (2020). Organização Mundial da Saúde. World Health Statistics 2020: monitoring health for the SDGs. OMS, Paris, França, 2016. Recuperado de [https://www.who.int/gho/publications/world\\_health\\_statistics/2020/en/](https://www.who.int/gho/publications/world_health_statistics/2020/en/)
- Pacheco Junior, J. C. (2019). *Modelos para Detecção de Fraudes Utilizando Técnicas de Aprendizado de Máquina* (Dissertação de Mestrado). Escola de Economia de São Paulo, Fundação Getulio Vargas, São Paulo, SP, Brasil.
- Paula, E. L. (2016). *Mineração de Dados como Suporte à Detecção de Lavagem de Dinheiro* (Dissertação de Mestrado). Instituto de Ciências Exatas, Universidade de Brasília, Brasília, Brasil.
- Pierce, G. L, Spaar, S., & Briggs, L. R. (1988). *The Character of Police Work: strategic and tactical implications*. Boston: Center for Applied Social Research.
- Ratcliffe, J. H. (2010). The Spatial Dependency of Crime Increase Dispersion. *Security Journal*, 23(1), 18-36.
- Resende, J. P. D., & Andrade, M. V. (2011). Crime Social, Castigo Social: desigualdade de renda e taxas de criminalidade nos grandes municípios brasileiros. *Estudos Econômicos (São Paulo)*, 41(1), 173-195.
- Santos, M. J., & Kassouf, A. L. (2008). Estudos Econômicos das Causas da Criminalidade no Brasil: evidências e controvérsias. *Revista EconomiA*, 9(2), 343-372.
- Santos, M. J., & Santos Filho, J. I. (2011). Convergência das Taxas de Crimes no Território Brasileiro. *Revista EconomiA*, 12(1), 131-147.
- Sathyadevan, S., Devan, M. S, & Gangadharan S. (2014). Crime analysis and prediction using data mining. *Proceedings of the First International Conference on Networks & Soft Computing (ICNSC2014)*, Guntur, Andhra Pradesh, Índia, 1. Recuperado de <https://ieeexplore.ieee.org/document/6906719>.
- Shaw, C. R., & Mckay, H. D. (1942). *Juvenile Delinquency and Urban Areas*. Chicago: University of Chicago Press.
- Sherman, L. W., & Berk, R. A. (1984). The Specific Deterrent Effects of Arrest for Domestic Assault. *American Sociological Review*, 49(2), 261-272.
- Shikida, P. F. A. (2016). Economia do Crime: uma análise sobre a maioria penal a partir de detentos paranaenses. *Economic Analysis of Law Review*, 7(1), 249-265.
- Soares, R. R. (2015). Welfare Costs of Crime and Common Violence. *Journal of Economic Studies*, 42(1), 117-137.
- Suliano, D. C., & Oliveira, J. L. (2015). Avaliação do Programa Ronda do Quarteirão na Região Metropolitana de Fortaleza (Ceará). *Revista Brasileira de Estudos Regionais e Urbanos*, 7(2), 52-67.
- UNODC (2013) – Escritório das Nações Unidas sobre Drogas e Crimes (United Nations Office on Drugs and Crime - UNODC). Relatório Regional de Desenvolvimento Humano 2013-2014. Segurança Cidadã com rosto humano: Diagnóstico e proposta para América Latina. Recuperado de [http://www.undp.org/content/dam/rblac/docs/Research%20and%20Publications/IDH/Resumen%20IDH%20portugues\\_completo\\_.pdf](http://www.undp.org/content/dam/rblac/docs/Research%20and%20Publications/IDH/Resumen%20IDH%20portugues_completo_.pdf)
- Vieira, M. A. (2019). *Detecção de Anomalias em Dados da Administração Pública Utilizando Técnica de Aprendizado de Máquina* (Trabalho de Conclusão de Curso). Departamento Acadêmico de Computação, Universidade Tecnológica Federal do Paraná, Medianeira, Paraná, Brasil.

- Weisburd, D. (2015). The Law of Crime Concentration and the Criminology of Place. *Criminology*, 53(2), 133-157.
- Weisburd, D., & Eck, J. E. (2004). What Can Police do to Reduce Crime, Disorder, and Fear? *The ANNALS of the American Academy of Political and Social Science*, 593(1), 42-65.
- Weisburd, D., Braga, A. A., Groff, E. R., & Wooditch, A. (2017). Can Hot Spots Policing Reduce Crime in Urban Areas? An Agent-Based Simulation. *Criminology*, 55(1), 137-173.
- Weisburd, D., Maher, L., Sherman, L., Buerger, M., Cohn, E., & Petrosino, A. (1992). Contrasting Crime General and Crime Specific Theory: the case of hot spots of crime. In F. Adler, & W. S. Laufer (Orgs.), *New Directions in Criminological Theory* (Cap. 3, pp. 45-69). New Jersey: Transaction Publishers.
- Weisburd, D., Morris, N. A., & Groff, E. R. (2009). Hot Spots of Juvenile Crime: a longitudinal study of arrest incidents at street segments in Seattle, Washington. *Journal of Quantitative Criminology*, 25(4), 443-467.