



NOVA

IMS

Information
Management
School

MEGI

Mestrado em Estatística e Gestão de Informação

Master Program in Statistics and Information Management

Modelação e Análise Espacial das Condicionantes do Crime Contra o Património em Portugal Continental

Joana Paulo Tavares

Dissertação apresentada como requisito parcial para
obtenção do grau de Mestre em Estatística e Gestão de
Informação

NOVA Information Management School
Instituto Superior de Estatística e Gestão de Informação

Universidade Nova de Lisboa

NOVA Information Management School
Instituto Superior de Estatística e Gestão de Informação
Universidade Nova de Lisboa

MODELAÇÃO E ANÁLISE ESPACIAL DAS CONDICIONANTES DO CRIME CONTRA O PATRIMÓNIO EM PORTUGAL CONTINENTAL

por

Joana Paulo Tavares

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Estatística e Gestão de Informação, Especialização em Análise e Gestão de Informação

Orientadora: Professora Doutora Ana Cristina Costa

Julho 2021

DEDICATÓRIA

A elaboração da presente dissertação simboliza, não só, o final de um ciclo, mas também, o alcance de mais um objetivo na escada do percurso académico que tenho vindo a trilhar. A sua conclusão comprova, uma vez mais, que com trabalho, perseverança e dedicação, é possível chegarmos onde sempre desejámos e alcançarmos os nossos sonhos.

Dedico este trabalho a duas pessoas muito especiais na minha vida.

À minha mãe, Inês Joaquim Paulo Tavares, vinda de Angola, sozinha com apenas 16 anos. Tão nova, atravessou o continente em busca de segurança, paz, oportunidades, mas principalmente, em busca da esperança de uma vida melhor. A sua postura tranquila, serena, positiva, forte e a sua garra, sempre foram o meu maior motor para continuar, acreditar e nunca duvidar das minhas capacidades. Mesmo nos dias mais difíceis, é a pessoa que tem sempre uma palavra de conforto e motivação para me dar. É a pessoa que luta sempre ao meu lado independentemente do quão difícil possa parecer o caminho. Para ela, "desistir" não é uma palavra que conste no seu dicionário. Dá-me sempre força para continuar, para ir o mais longe possível, para lutar pelos meus objetivos e para nunca me limitar a nada. Para a minha mãe "é importante sabermos fazer de tudo um pouco" e o "saber não ocupa lugar". Com ela aprendi a não passar por cima de ninguém para chegar onde quero e a não esperar a aprovação dos outros para avançar com os meus sonhos e objetivos. A realização dos nossos sonhos, deve partir de nós mesmos. Espero um dia vir a ser um terço da mulher lutadora e batalhadora que ela é.

Ao meu pai, Armindo Martins Tavares, vindo de São Tomé e Príncipe, com apenas 14 anos, com a missão de trabalhar para ajudar a sua família, que até então tinha ficado na sua terra natal. Mais reservado, mas sempre muito cuidadoso. Cresci a ouvi-lo falar da importância da educação e de estudar para ter um futuro melhor. Com ele aprendi que os professores merecem todo o nosso respeito e consideração e que "o livro é o nosso melhor amigo". Guardo com muito carinho todas as memórias que tenho relacionadas com o meu percurso escolar. Desde as idas à "Papeleria Moedas", em agosto, comprar os manuais escolares para o ano letivo seguinte. As suas idas às reuniões de final de período da escola, sem nunca ter faltado a uma! O percurso de autocarro que fez questão de fazer para me ensinar o caminho para a escola São Julião da Barra. Sou grata por toda a sabedoria que me passou e tem vindo a passar ao longo da vida, o sentido de responsabilidade que me incutiu e a missão de que nem sempre o caminho mais fácil é o melhor, mas que devemos sempre trabalhar arduamente, com dedicação, compromisso e responsabilidade para chegarmos onde queremos.

Os meus pais sempre trabalharam para que nunca faltasse nada, a mim e à minha irmã, fazendo longas jornadas de trabalho para que tivéssemos todas as oportunidades e pudéssemos chegar longe e voar cada vez mais alto. Sou grata e orgulho-me imenso do esforço e sacrifício que fizeram para proporcionar os meus estudos e garantir-me um futuro melhor. Não há palavras que cheguem ou descrevam o quão grata sou por vos ter na minha vida, por lutarem e apoiarem os meus sonhos, por estarem sempre do meu lado. É graças a vós, e a Deus, que cheguei onde estou hoje, sem o vosso apoio e amparo, este caminho não seria possível.

AGRADECIMENTOS

Finalizada esta etapa tão importante da minha vida, não poderia deixar de agradecer a todos aqueles que, direta ou indiretamente, me apoiaram nesta caminhada e contribuíram para a concretização deste estudo.

Primeiramente, o meu mais sincero agradecimento à Professora Doutora Ana Cristina Costa, não só pela orientação desta dissertação, mas também por todo o seu apoio, partilha de conhecimento, pela explicitação das questões que surgiram ao longo deste percurso, pelo rigor e disponibilidade com que conduziu este trabalho, e ainda por tantas vezes me contagiar e inspirar com o seu entusiasmo.

Quero agradecer à minha irmã, Teresa Tavares, por ser a melhor irmã que alguém podia ter. Sempre desempenhou muito bem o seu papel de irmã protetora e conselheira, apoiando-me em todas as fases da minha vida, estendendo-me a sua mão e amparando-me sempre. Com ela aprendi que nunca é tarde para seguirmos os nossos sonhos e que não existe uma ordem correta para os realizar. O tempo somos nós que o definimos, e com força, determinação e dedicação é possível alcançar aquilo que tanto sonhamos.

Aos meus sobrinhos, Mara e Hugo, que mesmo sem se aperceberem, serem uma das minhas maiores forças e motivação. Ao meu cunhado Carlos, pela paciência e todo o carinho demonstrado.

Para o meu amor, Nuno Miguel, as palavras nunca serão suficientes para agradecer todo o seu apoio incondicional, e por ser e estar, sempre presente, caminhando comigo lado a lado. Obrigada por seres o meu porto seguro, e estares sempre pronto a ajudar, tranquilizar e a motivar-me. Por não me deixares esquecer e lembrares-me todos os dias, o porquê de percorrer este caminho, e claro, por apoiares os meus sonhos e incentivares-me a voar o mais alto possível.

Ao Professor Doutor Pedro Cabral, fico grata pelas aulas de Metodologias de Investigação, que graças aos seus ensinamentos puderam tornar este trabalho mais rico.

À NOVA IMS, pela instituição de ensino com alto padrão de qualidade, grau de exigência e profissionalismo por parte de todos os seus docentes.

Por último, mas não menos importante, não poderia deixar de agradecer à minha amiga Elsa, por todo o esforço, apoio e dedicação na leitura e revisão deste meu trabalho e às minhas amigas que me acompanham desde o início desta etapa académica, lembrando-me sempre que o apoio dos amigos é fundamental e essencial em todas as fases da nossa vida.

RESUMO

A criminalidade é um dos fenómenos sociais mais problemáticos que tem vindo a ganhar relevo e especial importância desde o final do século XX. É um fenómeno dinâmico e distribuído segundo tendências espaciais. Este tema tem sido objeto de estudo em diversas áreas científicas, ao longo do tempo, com o intuito de identificar novas leituras de informação, que possibilitem compreender os fatores associados à criminalidade, e encontrar soluções para prevenir e combater este problema. O evento criminal, tal como outros, desenvolve-se em torno do território, tendo por isso um cariz geográfico. Assim, a gestão e análise da criminalidade com recurso a ferramentas de informação geográfica têm representado uma importante contribuição para a análise da criminalidade. Esta investigação explora a distribuição espacial dos crimes contra o património em Portugal Continental e tem como objetivo principal investigar fatores demográficos e socioeconómicos, que possam estar associados a este fenómeno em cada município. Para tal, são aplicadas ferramentas de Sistema de Informação Geográfica (SIG), técnicas de análise exploratória, estatística descritiva e modelação espacial. A análise exploratória inicial permitiu identificar a existência de autocorrelação e heterogeneidade espacial na taxa de crimes contra o património, justificando assim a utilização de modelos de regressão espacial. Foram aplicados e comparados entre si, modelos de regressão de Poisson, nomeadamente o modelo global, o modelo local GWPR – *Geographically Weighted Poisson Regression* (Regressão de Poisson Geograficamente Ponderada) –, e o modelo GWPR semi-paramétrico. O modelo que revelou um melhor ajuste aos dados foi o GWPR com oito variáveis explicativas: *Poder de compra per capita*; *Taxa de população jovem residente*; *Taxa de retenção e desistência no ensino básico*; *Taxa bruta de escolarização*; *Número médio de alojamentos de familiares clássicos*; *Taxa de beneficiários do RMG e RSI*; *Taxa de desempregados*; *Proporção de população estrangeira*. Em particular, o modelo apresenta melhor ajuste nos municípios da área metropolitana de Lisboa e do Porto. Os resultados mostram que a magnitude da associação de cada uma das variáveis independentes com os crimes contra o património varia no território. Com este estudo, espera-se contribuir para uma melhor compreensão do fenómeno da criminalidade em Portugal, na medida em que os resultados permitem identificar quais são os fatores demográficos e socioeconómicos mais relevantes em cada município.

PALAVRAS-CHAVE

Padrões de Criminalidade; Análise Espacial; Sistemas de Informação Geográfica; Regressão de Poisson; Regressão de Poisson Geograficamente Ponderada

ABSTRACT

Criminality is one of the most problematic social phenomena that has been gaining special relevance since the late twentieth century. It is a dynamical phenomenon distributed according to spatial trends. Over the course of time, several research fields have focused on the study of this subject, in order to unravel innovative ways of examining the information, making it possible to better understand the factors associated with crime, and find solutions to prevent and address this issue. The subject of criminality, like many others, is strongly related with territorial distribution and therefore, it may be well characterized by a geographical assessment. Thus, crime monitoring through geographic information analysis tools stands as an important contribution to the study of crime. This study explores the spatial distribution of crime against property in mainland Portugal, with the primary goal of investigating which demographic and socioeconomic factors may be associated with this problem in each municipality. For this purpose, Geographic Information System (GIS) tools, exploratory analysis techniques, descriptive statistics, and spatial modelling have been applied. An initial exploratory analysis identified the existence of autocorrelation and spatial heterogeneity in the rate of crimes against property, thus supporting the use of spatial regression models. Hence, Poisson regression models were applied and compared, namely the global model, the local GWPR model – Geographically Weighted Poisson Regression –, and the semi-parametric GWPR model. The model that revealed a better fit to the data was the GWPR model, with eight explanatory variables: Purchasing power per capita; Rate of young resident population; Retention and dropout rates in basic education; Gross school enrollment rate; Average number of households in a classical family; Rate of RMG and RSI beneficiaries; Unemployment rate; Ratio of foreign population. The model presents a better fit in the municipalities on the metropolitan areas of Lisbon and Porto. The results show that the correlation degree between each of the independent variables and the crimes against property varies across the territory. The aim of this investigation is to potentially improve the understanding of the crime problem in mainland Portugal, given that the results allow to identify the most relevant demographic and socioeconomic factors in each municipality.

KEYWORDS

Crime Patterns; Spatial Analysis; Geographic Information Systems; Poisson Regression; Geographically Weighted Poisson Regression

ÍNDICE

1. Introdução	1
1.1. Enquadramento do Tema	1
1.2. Relevância do Estudo.....	2
1.3. Objetivos.....	3
1.4. Estrutura da Dissertação.....	4
2. Revisão da Literatura	5
2.1. Modelação da Criminalidade	5
2.2. Modelação de Crimes Contra o Património.....	9
2.3. Criminalidade em Portugal	14
3. Metodologia	18
3.1. Caracterização da Área de Estudo e Descrição dos Dados	19
3.2. Recolha e Tratamento dos Dados	20
3.3. Análise Exploratória dos Dados.....	24
3.4. Modelos com Distribuição de Poisson.....	25
4. Resultados	28
4.1. Análise Exploratória Espacial dos Crimes Contra o Património	28
4.1.1. Autocorrelação Espacial	31
4.1.2. Análise de Hot Spots	33
4.2. Análise da Relação Entre os Crimes Contra o Património e Variáveis Independentes ..	34
4.3. Modelação dos Crimes Contra o Património	39
4.3.1. Análise e Interpretação dos Parâmetros Locais do Modelo Final.....	42
4.3.2. Qualidade do Ajustamento Local do Modelo Final.....	49
5. Conclusão	50
5.1. Limitações e Recomendações para Trabalhos Futuros	51
Referências.....	53
Anexo	58

ÍNDICE DE FIGURAS

Figura 2.3.1 – Evolução do crime contra o património, entre 1993-2018 (Fonte: DGPJ/MJ, PORDATA).	16
Figura 3.1 – Diagrama da metodologia aplicada.	18
Figura 3.2.1 – Mapa da distribuição espacial do número de crimes contra o património, em 2017.	20
Figura 4.1.1 – Mapa da distribuição espacial da taxa de crime contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.	28
Figura 4.1.2 – Histograma relativo à taxa de crime contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.	30
Figura 4.1.3 – Relatório da autocorrelação espacial (teste Moran Global I) referente à taxa de crime contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.	31
Figura 4.1.4 – Mapa da autocorrelação espacial (teste Moran Local I) referente à taxa de crimes contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.	32
Figura 4.1.5 – Mapa de <i>Hot Spots</i> referente à taxa de crimes contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.	33
Figura 4.3.1 – Resultado da ferramenta Local-To-Global do modelo semi-paramétrico (S-GWPR).	42
Figura 4.3.2 – Resultados do coeficiente local do preditor taxa de população jovem no modelo 8 GWPR.	43
Figura 4.3.3 – Resultados do coeficiente local do preditor taxa de retenção e desistência no ensino básico no modelo 8 GWPR.	44
Figura 4.3.4 – Resultados do coeficiente local do preditor taxa bruta de escolarização no modelo 8 GWPR.	45
Figura 4.3.5 – Resultados do coeficiente local do preditor nº médio de alojamentos de familiares clássicos no modelo 8 GWPR.	45
Figura 4.3.6 – Resultados do coeficiente local do preditor taxa de beneficiários do RMG e RSI no modelo 8 GWPR.	46
Figura 4.3.7 – Resultados do coeficiente local do preditor taxa de desempregados no modelo 8 GWPR.	47
Figura 4.3.8 – Resultados do coeficiente local do preditor proporção de população estrangeira no modelo 8 GWPR.	47
Figura 4.3.9 – Resultados do coeficiente local do poder de compra <i>per capita</i> no modelo 8 GWPR.	48
Figura 4.3.10 – Mapa da percentagem local de <i>deviance</i> explicada.	49
Figura A 1: Crimes de Roubo na União Europeia no ano 2016.	58
Figura A 2: Distribuição espacial da variável <i>DensPop</i> nos municípios de Portugal Continental, em 2017.	58
Figura A 3: Distribuição espacial da variável <i>TxBtEscola</i> nos municípios de Portugal Continental, em 2017.	59

Figura A 4: Distribuição espacial da variável <i>TxRetDesis</i> nos municípios de Portugal Continental, em 2017.....	59
Figura A 5: Distribuição espacial da variável <i>TxPopJov</i> nos municípios de Portugal Continental, em 2017.....	60
Figura A 6: Distribuição espacial da variável <i>BemRMG_RSI</i> nos municípios de Portugal Continental, em 2017.....	60
Figura A 7: Distribuição espacial da variável <i>Desempds</i> nos municípios de Portugal Continental, em 2017.....	61
Figura A 8: Distribuição espacial da variável <i>N_Alojamts</i> nos municípios de Portugal Continental, em 2017.....	61
Figura A 9: Distribuição espacial da variável <i>TxPopEstra</i> nos municípios de Portugal Continental, em 2017.....	62
Figura A 10: Distribuição espacial da variável <i>PodComp</i> nos municípios de Portugal Continental, em 2017.....	62
Figura A 11: Distribuição espacial da variável <i>RemBasMens</i> nos municípios de Portugal Continental, em 2017.....	63
Figura A 12: Gráfico de dispersão entre a taxa de crime contra o património e a densidade populacional.....	63
Figura A 13: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de população jovem residente.....	64
Figura A 14: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de retenção e desistência no ensino básico.....	64
Figura A 15: Gráfico de dispersão entre a taxa de crime contra o património e a taxa bruta de escolarização.....	65
Figura A 16: Gráfico de dispersão entre a taxa de crime contra o património e o nº médio de alojamentos de familiares clássicos.....	65
Figura A 17: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de beneficiários do RMG e RSI.....	66
Figura A 18: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de desempregados.....	66
Figura A 19: Gráfico de dispersão entre a taxa de crime contra o património e a proporção de população estrangeira.....	67
Figura A 20: Gráfico de dispersão entre a taxa de crime contra o património e a remuneração base média mensal.....	67
Figura A 21: Gráfico de dispersão entre a taxa de crime contra o património e o poder de compra per capita.....	68

ÍNDICE DE TABELAS

Tabela 2.2.1 – Revisão da literatura sobre a incidência de crimes.	9
Tabela 2.3.1 – Tabela relativa às variações observadas nas categorias criminais entre 2017-2018 (adaptado do RASI 2018).	15
Tabela 3.2.1 – Variáveis utilizadas no presente estudo.	21
Tabela 4.1.1 – Estatísticas descritivas das variáveis utilizadas no presente estudo.	29
Tabela 4.2.1 – Fator de Inflação da Variância (VIF) das 10 variáveis presentes no estudo.	37
Tabela 4.2.2 – Fator de Inflação da Variância (VIF) das 9 variáveis independentes.	37
Tabela 4.2.3 – Matriz de correlação linear das variáveis do presente estudo.....	38
Tabela 4.3.1 – Resultados dos modelos de regressão Global e Local (GWPR) testados.	39

LISTA DE SIGLAS E ABREVIATURAS

AIC	Akaike Information Criterion
AICc	Corrected Akaike Information Criterion
CAOP	Carta Administrativa Oficial de Portugal
DGEEC	Direção-Geral de Estatísticas da Educação e Ciência
DGT	Direção Geral do Território
ESDA	Exploratory Spatial Data Analysis ¹
GEP	Gabinete de Estratégia e Planeamento
GWR	Geographically Weighted Regression ²
GWPR	Geographically Weighted Poisson Regression ³
IEFP	Instituto do Emprego e Formação Profissional
INE	Instituto Nacional de Estatística
MAI	Ministério da Administração Interna
MTSSS	Ministério do Trabalho, Solidariedade e Segurança Social
OLS	Ordinary Least Squares ⁴
SEF	Serviço de Estrangeiros e Fronteiras
S-GWPR	Semiparametric Geographically Weighted Poisson Regression ⁵
SIG	Sistemas de Informação Geográfica
SOM	Self-Organising Map
VIF	Variance Inflation Factor ⁶

¹ Análise Exploratória de Dados Espaciais

² Regressão Geograficamente Ponderada

³ Regressão de Poisson Geograficamente Ponderada

⁴ Mínimos Quadrados Ordinários

⁵ Regressão de Poisson Geograficamente Ponderada Semi-paramétrica

⁶ Fator de Inflação da Variância

1. INTRODUÇÃO

As características geográficas de um determinado território sempre influenciaram a densidade populacional e a sua distribuição espacial. Com o aumento da população, cresce igualmente a ocorrência de crimes nesse mesmo espaço. A necessidade de compreender o fenômeno criminal, nas grandes superfícies populacionais a que chamamos cidades, levou a realização de estudos prévios que relacionavam a criminalidade com o espaço geográfico onde ocorrem.

Merecendo especial destaque, André-Michel Guerry (advogado e estatístico francês), autor do Ensaio sobre a Estatística Moral de França (1833), apresentou o primeiro trabalho de ecologia social do crime, com uma abordagem geográfica, recorrendo a mapas para relacionar as ocorrências criminais com a localidade e os fatores sociais. Estes mapas revelaram que as taxas de crime contra o indivíduo e contra o patrimônio, permaneceram estáveis ao longo do tempo, quando desagregadas por sexo, idade e região. Nesse sentido, através do estudo dos efeitos de fatores demográficos, ambientais e situacionais sobre a criminalidade, concluiu-se que eram as condições sociais que causavam esse fenômeno, e não os fatores individuais e/ou biológicos (Santos, 2016).

1.1. ENQUADRAMENTO DO TEMA

A criminalidade emerge no início do corrente século como um dos principais problemas sociais que os habitantes das grandes cidades enfrentam no seu cotidiano. É considerado um dos fenômenos do período contemporâneo que mais tem contribuído para um clima de insegurança vivido na sociedade, afetando as nossas vidas pessoais e a vida da comunidade. De acordo com os autores Lourenço & Lisboa (1996), o sentimento de insegurança é definido como o conjunto de manifestações de inquietação, de perturbação ou de medo, quer individuais, quer coletivas, cristalizadas sobre o crime.

Cusson (2007), especialista em ciência criminal, por sua vez, afirma que *“o campo da criminologia consiste na procura de, através do conhecimento científico, prevenir a criminalidade e regular a ordem e segurança pública. O estudo da situação-problema no contexto desta disciplina assenta na compreensão do fenómeno do crime em si, da vítima, do transgressor e da própria resposta da sociedade ao fenómeno”*. Completando, na perspectiva de Brantingham & Brantingham (1995), os *“crimes não ocorrem aleatoriamente ou uniformemente no tempo, espaço ou sociedade”*. São inúmeros os estudos que demonstraram a existência de diferenças geográficas na padronização dos locais de crime, uma vez que esses padrões variam de acordo com o tipo de crime praticado (Hayward, 2012). Assim, *“entender o crime, requer conceitos e modelos que possam ser usados para explicar a não-uniformidade e a não-aleatoriedade padronizadas que caracterizam os fenómenos criminais”* (Brantingham & Brantingham, 1995).

Deste modo, assumindo a complexidade e a importância do tema, assiste-se no presente a uma crescente preocupação e necessidade, por parte de diversas ciências, em estudar e analisar o fenômeno da criminalidade. Nesse sentido, através do desenvolvimento de aplicações de Sistemas de Informação Geográfica (SIG) e ponderação dos princípios da Geografia, os autores especializados em matérias criminais têm vindo a compreender e desenvolver mecanismos de prevenção e segurança da população. Brantingham & Brantingham (1995), explicitam que a análise espacial do crime recorre a dados espaciais para explorar teorias do crime e explicar padrões espaciais. Assim sendo, torna-se

fulcral o desenvolvimento de conceitos e modelos capazes de fazer face à padronização espacial que caracteriza a realidade criminal.

O mapeamento do crime, em termos históricos, desempenha uma função significativa de controlo e análise do crime. Alguns especialistas afirmam que o mapeamento da criminalidade tem um impacto no entendimento do crime e dos problemas sociais. A recente aceleração do avanço tecnológico das técnicas de SIG e mapeamento computacional, tem acompanhado o desenvolvimento de métodos de análise espacial que melhoraram substancialmente a compreensão da dinâmica do crime (Carcach et al., 2001). Mais concretamente, estas ferramentas permitem relacionar as localizações geográficas com os padrões criminais, exibindo graficamente a sua ligação a fatores socioeconómicos, demográficos, entre outros.

Assim, considera-se fundamental o papel da estatística espacial para a análise do fenómeno criminal, uma vez que, ao realizarmos um estudo acerca de uma determinada área e compreendermos a forma como essa afeta as áreas de proximidade, torna-se possível perceber e identificar determinados padrões criminais no território. Desta forma, a geografia aplicada, os sistemas de informação geográfica e as novas tecnologias de informação, desempenham um papel notório na análise da criminalologia, representando uma ferramenta essencial de apoio à decisão em questões de segurança pública e prevenção da criminalidade.

1.2. RELEVÂNCIA DO ESTUDO

A aplicação de uma metodologia científica ao estudo da criminalidade tem vindo a acompanhar os avanços científicos e tecnológicos desde o corrente século. Esta abordagem permitiu desenvolver diversos estudos no âmbito da análise do fenómeno criminal e construção de teorias explicativas gerais.

De acordo com Ferreira (1998), a realidade criminal presente na sociedade, começou a ser identificada, na maioria das sondagens realizadas à opinião pública, como um dos problemas mais graves e com consequências mais negativas para a qualidade de vida nas cidades. A incompreensão deste fenómeno social tão complexo, tem vindo a ser traduzido ao longo dos anos em representações desajustadas da realidade. Com efeito, é premente encontrar mecanismos e políticas para o combate ao crime em Portugal. A compreensão das dinâmicas espaciais deste problema pode contribuir para a melhor tomada de decisão neste contexto.

O fenómeno criminal em Portugal não difere significativamente do quadro que se presencia nos restantes países europeus e na maioria dos países ocidentais em geral. Porém, a criminalidade contra os bens patrimoniais é a mais significativa, segundo afirmam Lourenço & Lisboa (1996). De acordo com os dados do *PORDATA*⁷, em 2016, Portugal apresentava 13.313 ocorrências, uma das mais elevadas taxas de crime de roubo (consultar Anexo – Figura A 1), comparativamente aos restantes países da União Europeia.

Em Portugal, é evidente a existência de uma inquietação notória no que se refere às questões relacionadas com o crime, a sua espacialização e a necessidade de articulação deste fenómeno com a aplicação de estatísticas espaciais. São diversos os estudos de grande notoriedade que contribuíram para o desenvolvimento da criminologia, baseados na criação de mapas de localização de crimes, que

⁷ Consultado em <https://www.pordata.pt/Europa/Crimes+por+categoria-3285-316443>; acedido a 01/12/2020.

revelam uma grande consciencialização do papel da geografia na análise criminal - *“Mapping Crime: Understanding Hot Spots”* (Eck et al., 2005).

Neste sentido, e uma vez que a revisão de literatura realizada não permitiu identificar estudos que analisem a variabilidade espacial do poder explicativo dos diversos fatores que influenciam o fenómeno dos roubos em Portugal, estreita a necessidade do desenvolvimento do presente projeto.

1.3. OBJETIVOS

O desenvolvimento dos SIG trouxe uma nova abordagem ao estudo do fenómeno criminal, permitindo observar desde um simples ponto no mapa até uma visualização tridimensional de um conjunto de dados espaciais e temporais. As ferramentas dos SIG aplicadas à Geografia da criminalidade são determinantes no apoio às decisões em questões de segurança pública e prevenção do crime que a sociedade enfrenta no presente, prevenindo e encontrando soluções para o seu impedimento e erradicação. Visto que a temática do crime engloba diversos contornos, desde crimes mais onerosos a pequenos delitos, a investigação desta dissertação incide sobre o crime contra o património em Portugal Continental.

Esta pesquisa será relevante para responder a questões como: (a) “Quais são os municípios com maior ocorrência do crime contra o património em Portugal Continental?”; (b) “Qual é o padrão espacial do crime contra o património?”; (c) “Quais as características demográficas, socioeconómicas, ou outras, que influenciam a ocorrência do crime contra o património em cada município?”.

Adicionalmente, a dissertação tem como objetivo potencializar o processo de análise de crimes contra o património em Portugal Continental, observados em 2017, através da identificação de padrões geográficos, investigando causas demográficas e/ou socioeconómicas, que possam estar relacionadas com estas ocorrências.

Com esse propósito, foram definidos os seguintes objetivos específicos:

- Caracterizar o padrão espacial do número de crimes contra o património;
- Identificar e recolher dados de potenciais variáveis explicativas do número de crimes;
- Investigar a associação entre as potenciais variáveis explicativas e a variável de estudo;
- Averiguar o padrão espacial (não-estacionaridade) das taxas de crime contra o património;
- Investigar a existência de autocorrelação espacial nas taxas de crime;
- Modelar o número de crimes contra o património para identificar variáveis explicativas globais e/ou locais.

Com a realização deste projeto de investigação, os contributos que se esperam alcançar para a Comunidade Científica são:

- Fornecer uma melhor compreensão da distribuição geográfica do crime contra o património em Portugal Continental;

- Apurar possíveis fatores explicativos da ocorrência de roubos e a variabilidade espacial da sua relevância;
- Visualizar os padrões de distribuição do crime e a sua ligação com fatores socioeconómicos, demográficos, entre outros.

Por fim, para a concretização dos objetivos propostos serão desenvolvidos modelos de regressão de Poisson, tanto globais como locais (*i.e.* espaciais). As potenciais variáveis explicativas serão identificadas através de uma revisão da literatura sobre o tema em estudo.

1.4. ESTRUTURA DA DISSERTAÇÃO

A dissertação que se apresenta, inicia-se com o presente capítulo de Introdução, onde é realizado um breve enquadramento, justificação e relevância do estudo, definição dos objetivos que se pretende alcançar, bem como, a delineação dos objetivos específicos da investigação.

No segundo capítulo, encontra-se a Revisão da Literatura, que consiste numa fase fundamental para a compreensão e contextualização deste trabalho de investigação. Neste capítulo abordar-se-á o tema da modelação da criminalidade, modelação de crimes contra o património e a criminalidade em Portugal. Serão também apresentadas as principais metodologias utilizadas na literatura para modelar a criminalidade, as variáveis de estudo consideradas, os principais resultados e conclusões.

O terceiro capítulo refere-se à metodologia de trabalho para a análise de crimes contra o património em Portugal Continental. Neste contexto será feita a caracterização da área de estudo, descrição dos dados e a metodologia analítica dos mesmos, incluindo o pré-processamento e a análise descritiva dos crimes.

Posteriormente, no quarto capítulo, serão apresentados e discutidos os resultados da investigação dos padrões criminais, incluindo a sua modelação, em particular, associada a crimes contra o património através de modelos de regressão de Poisson.

Por fim, no quinto capítulo, serão mencionadas algumas considerações finais e principais conclusões tal como limitações do estudo e recomendações para trabalhos futuros.

2. REVISÃO DA LITERATURA

Neste capítulo pretende-se fazer um enquadramento que evidencie o estado da arte dos temas abordados ao longo da presente dissertação.

Atualmente, um dos maiores flagelos vivenciados na sociedade moderna é a criminalidade. O desenvolvimento e o crescimento da população são fatores que têm contribuído para o problema em causa, sendo este não só um obstáculo para o desenvolvimento socioeconómico, mas também um entrave para o pleno exercício da cidadania nos locais onde ocorrem os fenómenos de crime. Esta realidade tem levado a que a criminalidade seja uma das ocorrências sociais de maior importância para a opinião pública (Lobo & Fernandez, 2003), sendo discutida e modelada estatisticamente no tempo e/ou no espaço por diversos teóricos da área criminal. Um fenómeno criminal pode ocorrer em qualquer lugar e/ou a qualquer hora. Todavia determinados fatores estão associados há ocorrência de certos eventos em locais particulares. Por consequência, as ocorrências criminais possuem autocorrelação espacial, ou seja, não se distribuem aleatoriamente em todas as áreas, revelando agrupamentos em determinados pontos, frequentemente revelados através de análises espaço-temporais. Adicionalmente, as análises realizadas têm comprovado que a criminalidade é fortemente influenciada por condições do contexto socioeconómico e/ou demográfico.

Dada a complexidade e extrema relevância do tema, surge a necessidade por parte das autoridades de Segurança Pública e do Estado, de compreender as causas que levam à ocorrência de crimes e a sua dinâmica, tendo em consideração os locais geográficos e os espaços em que estes decorrem. Por conseguinte, a presente revisão da literatura abordará temas sobre a utilização de técnicas de Sistemas de Informação Geográfica (SIG) e modelação espacial que contribuam para uma melhor compreensão do fenómeno.

2.1. MODELAÇÃO DA CRIMINALIDADE

A análise espacial de dados consiste no estudo de fenómenos referenciados no espaço através de métodos que procuram descrever e/ou explicar as razões pelas quais determinados eventos acontecem em determinados locais (Nezami & Khoramshahi, 2016). Ainda que estas abordagens permitem obter uma visão global dos padrões geográficos de ocorrências criminais, a maior preocupação consiste em compreender as causas subjacentes à existência de áreas urbanas com taxas e riscos diferentes para o fenómeno da criminalidade. Deste modo, a Sociologia propõe dois métodos para o estudo da criminalidade a partir do conhecimento situacional-ambiental das áreas urbanas. Estas teorias procuram explicar a evolução das taxas de crime, não a partir das características dos criminosos, mas através do ambiente circundante e do contexto em que os crimes decorrem. Posto isto, é possível citar as seguintes teorias:

Teoria da Atividade Rotineira

Cohen & Felson (1979), desenvolveram a Teoria da Atividade Rotineira, que explora os padrões criminais e as ameaças com base nos fatores sociais e nas circunstâncias em que os crimes ocorrem. Estes autores afirmam que as elevadas taxas criminais podem ser explicadas pelas mudanças das atividades rotineiras do dia-a-dia que acompanham o crescimento económico. Segundo estes dois autores, a causa do crime é “...a junção no espaço e no tempo de três elementos de contacto direto: (1) delinquentes motivados, (2) alvos apetecíveis, (3) ausência de segurança eficaz...”.

Teoria da Desorganização Social

O ponto de partida da Teoria da Desorganização Social, iniciou-se com a publicação *Juvenile Delinquency and Urban Areas*, um estudo desenvolvido por Shaw & McKay (1942). Os autores na sua obra destacam, através do mapeamento dos padrões geográficos, o papel das áreas urbanas e a sua influência no comportamento criminal, apontando três fatores estruturais – baixo estatuto socioeconómico, heterogeneidade étnica e mobilidade residencial – considerando que estes fatores levaram à rutura da organização social da comunidade, que, por sua vez, foi responsável por variações no crime e na delinquência (Grooves & Sampson, 1989). Em concordância com esta delimitação, estudos posteriores ao trabalho de Harries (1974), estabelecem que áreas onde predominam habitantes com baixo estatuto socioeconómico (considerados locais mais desfavorecidos), onde o valor das rendas seria mais baixo, e por sua vez, com uma alta mobilidade da população e concentração de grupos pertencentes a minorias (equacionando possíveis dificuldades de integração e privação social), são geralmente positivamente correlacionadas com o crime. Por outro lado, a estabilidade da população num bairro está associada à diminuição das taxas de criminalidade, ou seja, encontra-se negativamente correlacionada com o crime (Harries, 1974). Consequentemente, a Teoria da Desorganização Social evoluiu a partir da pesquisa inicial sobre a geografia do crime, argumentando que um alto grau de privação social e económica, a rotatividade da população e a heterogeneidade étnica num determinado bairro, estão associados à desorganização social (Cahill & Mulligan, 2003).

Com o desenvolvimento dos Sistemas de Informação Geográfica (SIG), ao longo do tempo, os analistas criminais começaram a introduzir em estudos os princípios da geografia e da informação espacial com recurso a estas novas tecnologias, tornando-se ferramentas importantes na análise de dados espaciais, devido às suas inúmeras funcionalidades e aplicações. Estes sistemas permitem a utilização de informação geográfica, podendo realizar o seu armazenamento, modelação, análise e visualização da mesma (Longley et al., 2005).

São diversos os temas estudados e as contribuições científicas resultantes da aplicação de ferramentas SIG, como por exemplo, os estudos de criminalidade (Murray et al., 2001), mapeamento dos fatores de risco da doença de Lyme (Glass et al., 1995), o estudo da poluição aérea (Bellander et al., 2001), investigação do vírus Zika (Rodriguez-Morales et al., 2017) ou, como no caso do presente trabalho, a análise de crimes contra o património.

A Geografia tem vindo a explorar a diversidade espacial da criminalidade, uma vez que o evento criminal manifesta uma forte componente espacial (Batella et al., 2010). É neste prisma que a Geografia Aplicada desempenha um papel preponderante para a compreensão deste fenómeno social que afeta a vida quotidiana do cidadão urbano. Ao estudarmos a dinâmica de uma determinada área e a forma como essa afeta as áreas de circunvizinhança, podemos compreender a razão e a distribuição geográfica de cada ocorrência ou evento. Através da sua análise espacial é possível identificar padrões espaciais de acontecimentos que tomam lugar em determinados locais (Quick et al., 2018), caracterizando e esboçando a realidade criminal de uma determinada área geográfica. Nesta perspetiva, existem duas implicações teóricas e metodológicas fundamentais associadas à análise de dados espaciais: dependência espacial e heterogeneidade espacial (Anselin, 1999).

Existe dependência espacial quando “o valor da variável dependente, em uma unidade espacial de análise, é parcialmente uma função do valor da mesma variável em unidades vizinhas” (Flint et al., 2000). A dependência espacial pode ser testada através da análise de autocorrelação espacial, para

medir o grau de semelhança de objetos ou atividades em diferentes unidades/regiões (Goodchild, 1988). As medidas de autocorrelação espacial mais comuns são os coeficientes de autocorrelação global e local de Moran I e Geary (Althausen & Mieczkowski, 2001). É importante referir que a autocorrelação espacial pode ser positiva ou negativa, indicando um agrupamento não aleatório de valores e uma dispersão não aleatória de valores, respetivamente. Da mesma forma, como a autocorrelação espacial positiva implica que lugares vizinhos são idênticos, estabelece um grau de previsibilidade entre o que ocorre num lugar e nos seus arredores. A autocorrelação espacial negativa resulta no efeito oposto. Se os dados forem espacialmente dependentes, as medições não irão refletir nem acrescentar variação sobre o fenómeno em estudo (C. J. Vilalta, 2013). Em relação à heterogeneidade espacial ou não-estacionariedade, refere-se à distribuição desigual de eventos e relações espaciais (Chen et al., 2017).

A distribuição espacial dos crimes nunca é aleatória (Nezami & Khoramshahi, 2016), ou seja, os incidentes criminais tendem, ao longo do espaço e do tempo, a aglomerar-se em determinadas regiões. Existem, nomeadamente lugares que são mais propensos a episódios de crimes de roubo do que outros (Chen et al., 2017). Diversos estudos geográficos comprovam que o crime é um fenómeno concentrado em *clusters* (Wang et al., 2013), igualmente denominados por *hot spots* (Eck et al., 2005). Conclui-se assim, que o fenómeno em estudo não é nem aleatório nem homogéneo no espaço, especialmente quando se tem em consideração as áreas urbanas (Nezami & Khoramshahi, 2016).

Por outro lado, a modelação espacial tem como objetivo simular fenómenos que têm uma dimensão espacial explícita. Esta tem sido uma das metodologias mais utilizadas para a abordagem estatística de dados sobre crimes espaciais (Bernasco & Elffers, 2010). Embora os modelos espaciais exijam dados espaciais, estes últimos podem ser analisados recorrendo a diferentes métodos. Efetivamente, muitos dados pertencentes a esta categoria foram analisados sem recorrer a modelos espaciais, como os estudos realizados por Heitgerd & Bursik (1987) e (Morenoff, Jeffrey D.; Sampson, Robert J.; Raudenbush, 2001). Nestes estudos investiga-se e analisa-se como as taxas de criminalidade nos bairros são influenciadas pelas condições socioeconómicas, as características dos seus residentes e o meio envolvente, tendo em conta que são entidades claramente espaciais, mas sem recorrer a modelos espaciais (Bernasco & Elffers, 2010). Por sua vez, os dados espaciais *“consistem em observações sobre indivíduos geográficos que só podem ser interpretadas satisfatoriamente quando as suas localizações forem levadas em consideração”* (L. O’Brien, 1992). Assim sendo, dados espaciais representam a variação de um comportamento identificável num sistema de coordenadas geográficas.

Desta forma, considera-se importante a modelação de eventos criminais, uma vez que permite uma melhor compreensão da distribuição de ocorrências, bem como, das suas causas principais e, deste modo, possibilita o desenvolvimento de soluções e planos de ação mais direcionados e eficientes. Com efeito, diversas técnicas e testes estatísticos, como por exemplo, estatísticas de Moran Global e Local, análise de *hot spots* e modelos de regressão linear múltipla, são utilizados na investigação deste fenómeno.

A não-estacionariedade espacial das variáveis consiste numa violação dos pressupostos do modelo OLS (Ordinary Least Squares). De acordo com a primeira lei da geografia, proposta por Tobler (1970), *“everything is related to everything else, but near things are more related than distant things”*, ou seja, o comportamento de fenómenos é influenciado pelas relações de proximidade. Assim sendo, o pressuposto estatístico de independência das observações é geralmente violado quando se utilizam

variáveis geográficas. Por outro lado, a relação entre a variável dependente e as variáveis explicativas poderá não ser idêntica em toda a região de estudo (*i.e.* estacionária). Consequentemente, como técnica de análise espacial alternativa aos modelos de regressão OLS (modelos globais), surge a regressão geograficamente ponderada (GWR – Geographically Weighted Regression) proposta por (Brunsdon et al., 1996). Este modelo tem em consideração as relações espaciais locais e variáveis não estacionárias, permitindo que as relações modeladas possam variar pela área de estudo. Ao passo que, no modelo de regressão linear global é estimado um parâmetro para cada variável independente, comum a todo o território, por sua vez, no modelo GWR é avaliado um parâmetro para cada variável independente em cada local na área de estudo.

Atualmente diversos autores, citando a título de exemplo, os estudos de (Cahill & Mulligan, 2007; Rybarczyk et al., 2015; Vilalta & Muggah, 2016), têm recorrido a modelos que tomam em consideração a não-estacionariedade das variáveis, como é o caso do GWR, para modelar a criminalidade. Estes investigadores destacam o aumento do poder explicativo dos modelos GWR ao englobar relações espaciais locais.

Similarmente, o modelo de regressão Geographically Weighted Poisson Regression (GWPR), tem sido empregue na literatura da modelação da criminalidade (Chen et al., 2017; Vilalta & Fondevila, 2019; Vilalta, Sanchez, Fondevila, & Ramirez, 2018), uma vez que também tem em conta a não-estacionariedade das relações espaciais. A investigação de Osgood (2000), sugere o uso da regressão de Poisson para lidar com questões relacionadas com as taxas de crime, uma vez que, esta distribuição é frequentemente aplicada na modelação de dados de contagem e taxas.

Na cidade de Toronto, no Canadá, realizou-se um estudo que explora o padrão de crime violento entre diferentes estratos socioeconómicos, analisando fatores que podem influenciar a ocorrência deste fenómeno criminal. Os dados são referentes a dois anos de incidentes criminais, entre o período de 2014 e 2016. Os autores Wang, Lee, & Williams (2019), recorrem a modelos OLS e GWR, e utilizam ainda a estatística global Moran I. Com estes métodos, os investigadores destacam que o modelo espacial local GWR é melhor e mais adequado do que o modelo de regressão linear múltipla clássico (modelo OLS) para compreender e explicar as variações nas taxas de criminalidade observadas na cidade de Toronto. De modo semelhante, Fowles & Merva (1996), chegaram a uma conclusão idêntica na modelação da criminalidade nos Estados Unidos. Outros autores, compararam a utilização de modelos globais de regressão de Poisson com modelos espaciais locais de Poisson (GWPR) para a modelação de crimes de homicídio, e concluíram que os modelos locais tinham um melhor ajuste na modelação da criminalidade violenta (Vilalta et al., 2016).

Adicionalmente, alguns autores tentaram ir além da visualização de estatísticas e modelação de resultados de um determinado período, procurando quantificar tendências espaciotemporais na criminalidade. Para uma interpretação eficaz dos padrões espaciotemporais de *clusters/hot spots* de crime, o estudo de Nakaya & Yano (2010), explora a possibilidade de um mapeamento tridimensional de eventos criminais cometidos na cidade de Kyoto, entre 2003 e 2004. Por outro lado, a investigação de Li & Juhola (2014), recorre a uma técnica das redes neurais artificiais, denominada *Self-Organising Map* (SOM), para mapear fenómenos criminais. O objetivo desse estudo foi aplicar o SOM para o mapeamento de um total de 56 países com diferentes situações de crime.

2.2. MODELAÇÃO DE CRIMES CONTRA O PATRIMÓNIO

Atualmente, já existe alguma bibliografia científica com investigações dedicadas à análise espacial de crimes contra o património. Estes estudos dependem essencialmente do tipo de dados utilizados e do objetivo do trabalho. A Tabela 2.2.1 apresenta diversos estudos sobre incidência de crimes em diversas configurações geográficas, que comprovam as ilações anteriormente descritas. Existem algumas variações na seleção das variáveis independentes, dado que provêm de regiões de estudo diferentes.

Tabela 2.2.1 – Revisão da literatura sobre a incidência de crimes.

Artigo	Região	Objetivos	Variáveis Dependentes	Metodologia	Variáveis Independentes	Resultados Adicionais
Vilalta & Fondevila (2019)	Santa Fé, Cidade do México	(1) Identificar as características da incidência de crimes num bairro nobre e rico; (2) Provar que a regressão de GWPR fornece estimativas mais confiáveis da incidência do crime.	(1) Contagem total de investigações criminais registadas pela polícia. – Período de estudo: janeiro 2013 a setembro 2016	(1) Regressão de Zero-Inflated Poisson Regression (ZIPR); (2) Geographically Weighted Poisson Regression (GWPR)	Migrantes (+); Famílias chefiadas por mulheres (+); Desempregados (+); Nível de escolaridade (+); Divorciado/separado (+); Idade da população jovem (+); Abandono escolar (+); Ausência de pontos de venda de álcool (-); Pontos de venda de álcool (+); Avenidas principais (+); Estabelecimentos comerciais (+); Densidade populacional (-).	(1) O ajuste do modelo GWPR foi melhor e o impacto de algumas variáveis seria significativamente maior; os fatores nível de escolaridade e idade da população alcançaram significância estatística;
Sass, Porsse & Silva (2016)	Paraná, Brasil	(1) Identificar os fatores que influenciam as taxas de homicídios dos municípios do estado do Paraná.	(1) Taxa de homicídios por 100 mil habitantes. – Período de estudo: 2010 a 2012	(1) Análise Exploratória de Dados Espaciais; (2) Moran Global I (3) LISA (Indicadores Locais de Associação Espacial) (4) Modelo OLS (5) Spatial Autoregressive Model (SAR)	% de homens entre 15 e 24 anos; Densidade demográfica; Grau de urbanização; Índice de Gini; Taxa de analfabetismo; Taxa de desemprego; Taxa de pobreza; Taxa de polícias por 100 mil habitantes.	(1) Análise exploratória de dados espaciais indicou que existe autocorrelação espacial positiva nas taxas de homicídios; (2) Modelo OLS (explica 15% da variabilidade) – Fatores significativos e positivos: densidade demográfica, grau de urbanização e taxa de pobreza. Fatores significativos e negativos: polícias por 100 mil habitantes;

Artigo	Região	Objetivos	Variáveis Dependentes	Metodologia	Variáveis Independentes	Resultados Adicionais
				(6) Spatial Error Model (SEM) (7) Spatial Durbin Model (SDM)		(3) Modelo SAR (explica 35% da variabilidade) – Fatores significativos e positivos: grau de urbanização e taxa de pobreza. Fatores significativos e positivos: grau de urbanização e taxa de pobreza. Fatores significativos e negativos: polícias por 100 mil habitantes. (4) Modelo SDM (O modelo explica 40% da variabilidade) – Fatores significativos e positivos: grau de urbanização e taxa de pobreza.
Vilalta & Muggah (2016)	Cidade do México	(1) Identificar padrões geográficos das taxas de criminalidade em várias formas de criminalidade; (2) Modelar espacialmente a criminalidade na área metropolitana da Cidade do México.	(1) Taxa de investigações criminais (os tipos de crimes não foram especificados) – Período de estudo: 2010	(1) Modelo OLS; (2) Modelo GWR; (3) LISA; (4) Moran Global I; (5) Moran Local I.	Teoria da desorganização social: Índice de desigualdade social (-); % de habitantes que moravam noutra estado nos últimos 5 anos (+); % de agregados familiares chefiados por mulheres (+); Bares e restaurantes por 100 mil habitantes (+). Teoria da anomia institucional ⁸ : % de participação eleitoral no Congresso Federal (-); Índice de Gini (+); % de retenção no ensino primário (-); % de agregados familiares chefiados por mulheres (+).	(1) As conclusões revelam que os municípios da área metropolitana da Cidade do México não são homogêneos quanto às taxas de criminalidade nem às suas causas. Consequentemente, um modelo global não seria adequado para representar essa realidade, e sim um modelo local, que permite analisar as especificidades locais, determinando melhor as causas e soluções da criminalidade de uma determinada região.
		(1) Demonstrar as vantagens de utilizar modelação espacial local para a	(1) Crimes analisados no presente estudo:	(1) Modelo global OLS; (2) Modelo local GWR; (3) Estatística global Moran I: para	Condição socioeconómica: Número de famílias que falam inglês (-); Residentes de etnia não-caucasiana (+); Habitações	(1) O modelo OLS apresentou um R^2 de 45% e os resíduos não parecem exibir autocorrelação espacial;

⁸ A teoria da anomia institucional surgiu na criminologia, em meados dos anos 90, e refere-se à ausência ou desintegração das normas sociais. Segundo Robert K. Merton, o crime caracteriza uma situação de anomia social (Chamlin & Cochran, 1995).

Artigo	Região	Objetivos	Variáveis Dependentes	Metodologia	Variáveis Independentes	Resultados Adicionais
Rybarczy, Maguffee & Kruger (2015)	Flint, Michigan (EUA)	modelação de crimes; (2) Instituir um sistema cartográfico; (3) Determinar as relações entre fatores socioeconômicos, saúde pública, capital social, impactos ambientais e o crime.	agressão agravada, homicídio, roubo e todas as formas de conduta sexual criminosa. – Período de estudo: 2010	determinar se os resíduos do modelo OLS eram espacialmente autocorrelacionados.	ocupadas pelos inquilinos (+); Número de famílias abaixo do nível de pobreza (+); Saúde pública: Média do índice de massa corporal (+); Impacto ambiental: Níveis de chumbo no sangue (-); Contexto da vizinhança: Trilhas para caminhadas (-); Terrenos baldios (+); Caminhos ferroviários (-); Calçadas pedestres (+); Residentes com um diploma do ensino secundário (+); Pontos de venda de alimentos (+); Saúde geral (+).	(2) O modelo GWR exibiu um R^2 ajustado de 54%, revelando um melhor ajuste.
Lee, Kang & Kim (2009)	Seul, Coreia do Sul	(1) Identificar efeitos locais e globais de variáveis independentes na incidência de crimes.	(1) Crimes analisados no presente estudo: homicídio, roubo, violação, agressão e furto. Por 100 mil habitantes. – Período de estudo: 2003	(1) Modelo GWR; (2) Modelos econométricos espaciais padrão: Spatial Autoregressive Model (SAR), Spatial Error Model (SEM), General Spatial Model (SAC).	Variável socioeconômica: Imposto predial por agregado familiar (-); População estabelecida (-); População flutuante (+); Proporção de jovens entre 15 a 24 anos (+); Proporção de universitários graduados (-); Número de polícias (-); Variáveis de planejamento urbano: Proporção de área de desenvolvida (-); Proporção de área residencial (-); Proporção da área de alojamento (+).	(1) O crime em Seul é um fenômeno regional, que apresenta um efeito diferenciado a nível local e global, em cada variável, sobre a incidência de crime. Estas características afetam de forma diferente a incidência de crimes; (2) A dependência espacial e a heterogeneidade espacial são particularmente importantes na incidência de crimes em Seul, indicando que é mais provável que uma área seja vitimada por algum lugar da mesma cidade do que num lugar de outra área.

Artigo	Região	Objetivos	Variáveis Dependentes	Metodologia	Variáveis Independentes	Resultados Adicionais
Cahill & Mulligan (2007)	Portland, Oregon	(1) Desenvolvimento de um modelo para o crime violento em Portland, que visa explorar padrões espaciais de crime e os seus fatores.	(1) Taxa de crimes violentos: homicídio; agressão sexual; roubo; agressão agravada. – Período de estudo: 1998 a 2002	(1) Modelo global OLS; (2) Modelo local GWR; (3) Teste de Monte-Carlo: para avaliar a variação espacial entre os crimes violentos e as variáveis explicativas.	Índice de Concentração nos Extremos (+); Índice de Heterogeneidade (+); Infraestruturas do metropolitano (+); Percentagem de famílias com casais casados (-); % Áreas comerciais (+); Densidade populacional (-); Estabilidade Residencial (-); Agregados familiares unipessoais (+).	(1) O modelo GWR apresenta uma melhoria estatisticamente significativa em relação ao modelo global. (2) Modelo global OLS (R^2): 36.1% (3) Modelo local GWR (R^2): 86%
Zhang & Peterson (2007)	Omaha, Nebraska	(1) Determinar as vantagens e desvantagens dos Location Quotient of Crime (LQCs) ⁹ para o mapeamento de crimes, <i>i.e.</i> , uma medida alternativa às taxas de crime através da frequência relativa de cada tipo de crime; (2) Averiguar se é possível que modelos que utilizam a densidade como medida do crime produzam um poder explicativo como as taxas de criminalidade.	(1) Número de incidentes de sete tipos de crimes: homicídio, agressão, roubo, furto, roubo automático, roubo e contravenção. – Período de estudo: 2000 a 2001	(1) Modelos OLS, utilizados para explicar a relação entre as características da vizinhança e o crime; (2) Modelos de regressão usando taxas de criminalidade e LQCs como variáveis dependentes.	% População minoritária (+); % Baixa escolaridade (+); % Domicílios chefiados por mulheres (+); % População masculina jovem (15-24) (+); % Alojamentos com mais de 1 pessoa por quarto (+); Densidade populacional (+); Renda média familiar (-); % Casas ocupadas pelo proprietário (-); % Casas desocupadas (+); % Estabilidade residencial (-); Taxa de desemprego (+); % População em situação de pobreza (+); Densidade comerciais (+); Densidade de parcelas multifamiliares (+).	(1) Todas as variáveis independentes são estatisticamente significativas e nas direções esperadas para cada uma das variáveis dependentes; (2) As correlações significativas entre as variáveis explicativas e as variáveis dependentes indicaram que é aplicável o uso da densidade criminal como medida alternativa das taxas de criminalidade; (3) Nenhuma variável independente teve impacto significativo na variação do LQC de assalto.

⁹ “O quociente de localização do crime (LQC) é uma medida da frequência relativa de um tipo de crime numa pequena área, em comparação com a proporção do mesmo tipo de crime numa grande área de referência de interesse (por exemplo, uma cidade).” (Zhang & Peterson, 2007)

Determinados autores tendem a analisar a frequência da ocorrência de crimes violentos e crimes não violentos, como é o caso do trabalho de Vilalta, Sanchez, Fondevila, & Ramirez (2018). Para tal, recorreram a dados provenientes dos registos da polícia da Cidade do México, para testar a relação dos Sistemas Policiais de Circuito Fechado de Televisão (doravante, CFTV), com estes fenómenos criminais. Os autores deste estudo, basearam-se em modelos de regressão de Zero-inflated Poisson Regression (ZIPR) e Geographically Weighted Poisson Regression (GWPR), aplicando posteriormente a estatística global Moran I, que avalia as características espaciais dos dados e indica se os dados se organizam em *clusters* e tendem a aglomerar-se em zonas específicas. Assim, este método permitiu que os autores concluíssem que a distribuição de crimes não violentos (furtos em lojas, furtos e roubos de veículos sem o uso da força) é fortemente espacial.

Adicionalmente, determinaram que fatores como o desemprego masculino e as estações de metro, aumentam a probabilidade de ocorrência de crimes não violentos, enquanto, por outro lado, áreas onde se encontrem localizados estacionamentos e estabelecimentos bancários, tendem a registar uma diminuição na probabilidade da ocorrência de crimes violentos (homicídio intencional, roubo, roubo de carro ou agressão sexual). Por sua vez, o número de sistemas de CFTV não está estatisticamente correlacionado com nenhuma das variáveis dependentes. No geral, o modelo GWPR revelou uma melhoria estatisticamente significativa, quando comparado com o modelo ZIPR, para os crimes violentos e não violentos. Os resultados do modelo GWPR forneceram mais informações sobre a estrutura espacial do crime na área em estudo. Embora o modelo ZIPR não tenha detetado uma relação estatisticamente significativa entre o número de sistemas de CFTV e o número de crimes no bairro, o modelo GWPR foi capaz de detetar relações negativas e estatisticamente significativas (localmente) entre o número de sistemas de CFTV e crimes não violentos.

Destacando uma região da China como área de estudo, os investigadores Chen et al. (2017), identificam o modelo mais adequado para o roubo residencial, comparando a adequação e comportamento de três modelos diferentes; o primeiro, Modelo Binomial Negativo (BN), sem controlo dos efeitos espaciais, o segundo, Modelo Hierárquico Bayesiano (MHB), considerando a dependência espacial e por último o modelo GWPR, visando a heterogeneidade espacial. Complementarmente, é feita uma análise da relação entre o número de roubos residenciais e fatores sociodemográficos. Para este estudo foram utilizados dados, entre 2013 e 2015, provenientes do sistema de chamadas de emergência da China. Com os resultados obtidos, os autores referem que o MHB e GWPR superam o modelo binomial negativo, na medida em que se identifica a existência dos efeitos espaciais. A análise empírica indica que áreas com uma maior percentagem de população residente em habitações alugadas, percentagem de pessoas de outras províncias, densidade da linha de autocarros e densidade de pontos de autocarro têm um impacto significativamente positivo no número de roubos residenciais. A percentagem de residentes com grau de licenciatura ou superior, mostra uma associação significativamente negativa com o roubo, o que significa que uma localidade ocupada maioritariamente por residentes com ensino superior apresenta menos ocorrências de roubo residencial.

2.3. CRIMINALIDADE EM PORTUGAL

Na perspetiva de Picca, crime é “...*todo o acto previsto como tal pela lei, dando lugar à aplicação de uma pena por parte da autoridade superior*” (citado por Cusson, 2007, p.17). Em Portugal, diversos fenómenos criminais são contemplados na categoria de “outros crimes”, apesar da existência das seguintes tipologias de crimes¹⁰:

- Crimes Contra as Pessoas;
- Crimes Contra o Património;
- Crimes Contra o Estado;
- Crimes Contra a Vida em Sociedade;
- Crimes Contra a Identidade Cultural e Integridade Pessoal;
- Legislação Avulsa.

O estudo do fenómeno do crime em Portugal torna-se preponderante para que sejam desenvolvidas políticas de ação, de prevenção e combate contra a criminalidade, tendo por objetivo a redução dos locais e focos de insegurança da população (Oliveira, 2012). Contudo, o estudo e análise da criminalidade em Portugal, não pode ser realizado sem verificar, de uma forma genérica, qual é o panorama da criminalidade a nível europeu. Assim, torna-se necessário observar a evolução, os fenómenos criminais com maior incidência e as categorias de crimes que mais atingem os países considerados desenvolvidos.

À semelhança do que acontece um pouco por toda a Europa, também em Portugal as questões relacionadas com a criminalidade, violência e insegurança, são questões que nos últimos anos têm vindo a ser objeto de debate e de preocupação, por parte dos mais diversos atores da sociedade civil, entre os quais se destacam os partidos políticos (como principais decisores de políticas de proteção e segurança da sociedade), a imprensa (como principal órgão de divulgação) e o cidadão comum (Graça Frias, 2003).

Segundo dados do Eurostat¹¹, baseados em estatísticas oficiais relativas aos crimes registados pelas autoridades policiais (infrações penais) na União Europeia, entre 2008 e 2016, verificou-se uma diminuição no que diz respeito às taxas de crimes de roubo e furtos em países europeus. Ainda assim, diversos autores afirmam que questões como estas devem ser bem fundamentadas, de tal modo que se torna bastante importante estudar, investigar, recolher dados estatísticos fiáveis e interpretá-los de modo a obter as conclusões científicas credíveis (Seabra & Santos, 2005).

Os crimes contra o património e os crimes contra pessoas são, a nível europeu, as categorias do fenómeno criminal com maior incidência e que comportam valores mais elevados. Foram realizados diversos debates acerca das causas subjacentes que impulsionam o fenómeno criminal, como os problemas sociais e económicos que caracterizam a sociedade. A forma como a criminalidade se manifesta em Portugal, não difere muito do quadro dos restantes países da Europa e dos países Ocidentais. A criminalidade contra os bens patrimoniais tem sido a mais significativa, segundo afirma

¹⁰ Consultar Decreto-Lei n.º 48/95 - Diário da República n.º 63/1995, Série I-A de 1995-03-15 <https://dre.pt/legislacao-consolidada/-/lc/107981223/201708230100/73474113/diploma/indice>; acessido a 01/10/2020.

¹¹ Consultado em <https://ec.europa.eu/eurostat/web/crime/publications>; acessido a 07/05/2020.

Lisboa & Lourenço (1999). Porém, Portugal é um dos países Ocidentais que regista uma das menores taxas de criminalidade.

Em Portugal, o registo de incidentes criminais é da responsabilidade de oito Órgãos de Polícia Criminal¹², que reúnem e reportam as ocorrências registadas à Direção-Geral de Política de Justiça (DGPJ). Este organismo público está encarregue de definir as políticas de segurança pública, recolher e analisar os dados das estatísticas oficiais dos incidentes criminais registados. Partindo desses dados, é elaborado o Relatório Anual de Segurança Interna (RASI), um documento de aferição dos modelos de política criminal e um instrumento estratégico de apoio à decisão e definição de medidas de prevenção criminal (RASI, 2018).

De acordo com o Relatório Anual de Segurança Interna, elaborado pela DGPJ, das categorias criminais mais frequentes, entre os crimes registados em 2018, a que assume maior expressividade é a de crimes contra o património, como por exemplo, o furto e o roubo (Tabela 2.3.1; Figura 2.3.1) que constituem 51,1% de toda a criminalidade declarada. Por seu turno, os valores mais baixos reportam-se a crimes contra as pessoas, crimes contra a identidade cultural e integridade pessoal, seguido dos crimes contra animais de companhia e dos crimes contra o Estado, como se pode citar a desobediência e a resistência e coação sobre funcionário.

Tabela 2.3.1 – Tabela relativa às variações observadas nas categorias criminais entre 2017-2018 (adaptado do RASI 2018).

Principais Categorias Criminais	Nº de ocorrências (2017)	Nº de ocorrências (2018)	Var %	Dif
Crimes contra o património	170.832	170.383	-0,3 %	-449
Crimes contra as pessoas	81.901	81.278	-0,8 %	-623
Crimes contra vida em sociedade	52.735	44.207	-16,2%	-8.528
Crimes previstos em legislação avulsa	28.799	29.811	3,5 %	1.012
Crimes contra o estado	5.682	5.497	-3,3 %	-185
Crimes contra animais de companhia	1.950	1.977	1,4 %	27

Nota-se uma diminuição no número de ocorrências de crimes contra o património, contra as pessoas, contra a vida em sociedade e nos crimes contra o Estado. Por outro lado, verifica-se um aumento nas restantes categorias. Desde 2009, que se observa uma tendência de descida, registando-se em 2018 o valor mais baixo dos últimos 13 anos, bem como uma das variações mais baixas.

¹² Desde 2015, que foram integrados no “RASI os registos globais da criminalidade participada e, dentro desta, registos desagregados por tipologias criminais, de oito OPC: Guarda Nacional Republicana (GNR), Polícia de Segurança Pública (PSP), Polícia Judiciária (PJ), Serviço de Estrangeiros e Fronteiras (SEF), Polícia Marítima (PM), Autoridade de Segurança Alimentar (ASAE), Autoridade Tributária e Aduaneira (AT) e Polícia Judiciária Militar (PJM)” (RASI, 2018).




Figura 2.3.1 – Evolução do crime contra o património, entre 1993-2018 (Fonte: DGPI/MJ, PORDATA).

Eduardo Ferreira, em 1998, referiu que *“a respectiva incidência tende a ser significativamente mais elevada em regiões com maior densidade populacional e tendencialmente em regiões mais urbanizadas, com maiores níveis de desemprego e com maiores níveis de rendimento”* (E. V. Ferreira 1998, p. 68). Nessa sequência, a correlação entre a incidência destas categorias criminais com a densidade populacional e com uma maior taxa de urbanização, é forte e positiva.

Embora exista um decréscimo no registo do fenómeno criminal em Portugal, nos últimos anos, as potencialidades de ferramentas como os SIG são notórias na abordagem ao estudo do presente tema. A cidade de Lisboa integra um conjunto de características socioeconómicas que a torna uma das frações estatísticas mais relevantes dos crimes a nível nacional. O tema da investigação dos autores Ribeiro et al. (2018), é desenvolvido no âmbito do projeto SIM4SECURITY, e tem o intuito de elaborar uma solução tecnológica com a finalidade de aprimorar a eficácia da atuação operacional das entidades de segurança. Nesta investigação, onde se apresenta o resultado das projeções demográficas e mapas de uso de solo para 2030 e 2040, também se analisa a atual localização das Forças de Segurança (FS), tendo em conta diferentes cenários demográficos esperados nas próximas décadas. Os autores recomendam a adequação das forças de segurança ao recente perfil demográfico da população, especialmente na região do interior do país. Sugere-se ainda a elaboração de um estudo da dependência espacial da criminalidade, de modo a determinar padrões de crimes e posteriormente cruzar esta informação com o estudo da distribuição geográfica da população.

A análise do fenómeno criminal em Portugal ainda está muito aquém das expectativas, o que também se reflete no baixo número de estudos que realizam a modelação da criminalidade. O estudo de Amaral (2018), teve como objetivo identificar as áreas em que fatores espaciais instituem as condições apropriadas para o crime. Através do Modelo de Risco de Terreno, uma ferramenta preditiva com a capacidade de identificar as áreas em que estes fatores espaciais estabelecem as condições apropriadas para o crime, foi possível prever quais os locais, na Divisão Policial de Loures, que estariam mais expostos a um possível furto no interior de uma residência.

O estudo realizado por Macedo (2016), apresenta uma análise dos determinantes associados à criminalidade nos municípios de Portugal, entre o período temporal de 2004 a 2012. Com recurso a

dados espaciais, são testados empiricamente três tipos de modelos: modelo espacial autorregressivo, modelo espacial autorregressivo com resíduos autorregressivos e o modelo espacial de Durbin. Este trabalho de investigação procurou estimar o efeito espacial de variáveis socioeconómicas, demográficas e educacionais, bem como, estimar coeficientes espaciais autorregressivos que indiquem se a taxa de criminalidade de um município é influenciada positivamente pela taxa de criminalidade de municípios vizinhos. Os resultados permitiram averiguar a existência de um forte impacto positivo na criminalidade incitado por níveis baixos de densidade populacional. Este resultado mantém-se para a taxa de crimes contra o património, no entanto, não manifesta significância estatística na taxa de crimes contra as pessoas. Adicionalmente, aferiu-se que elevadas proporções de jovens do sexo masculino têm a capacidade de dissuadir a criminalidade. Regiões com elevadas taxas de desemprego e população imigrante, apresentam níveis superiores de crimes contra as pessoas. Por fim, concluiu-se que o capital gerado por setores como a agricultura, pecuária, pesca, caça e silvicultura têm influência positiva nos crimes contra o património.

É também relevante de referir o estudo de Rajcic (2015), onde se apresenta uma análise descritiva espaço-temporal dos principais tipos de crimes e dos padrões de evolução espacial do crime nas regiões portuguesas ao nível das regiões NUTS III, entre 1995 e 2013. As principais metodologias utilizadas pelo autor foram a Análise de Componentes Principais e a técnica STATIS de análise descritiva multidimensional de dados. Os resultados permitiram concluir que existem fortes padrões de criminalidade espacial e temporal, e ainda descrever tendências globais de evolução do crime e definir padrões de evolução do crime nas regiões NUTS III.

3. METODOLOGIA

O atual capítulo refere-se à metodologia usada para a concretização do objetivo proposto que, mais concretamente, corresponde à identificação de padrões geográficos e investigação de causas demográficas e socioeconómicas que possam estar relacionadas com os crimes contra o património em Portugal Continental. Inicialmente é elaborada uma caracterização da área de estudo e uma breve descrição dos dados. De seguida, irá realizar-se a identificação de potenciais variáveis explicativas relevantes para o estudo, tendo por base investigações elaboradas em outras regiões.

Através da estatística de Moran I, será investigada a heterogeneidade espacial (não-estacionaridade), bem como a existência de *clusters* e *outliers* espaciais na taxa de crimes contra o património em Portugal. Posteriormente, efetua-se a análise de *hot spots* com a estatística *Getis-Ord Gi*. Por fim, de forma a cumprir um dos principais objetivos desta pesquisa, através de modelos de regressão de Poisson global e local (GWPR), procede-se à modelação da distribuição do crime contra o património. Assim, distingue-se na Figura 3.1, uma representação esquemática dos métodos de trabalho a ser aplicados na resolução do presente estudo, que são abordados detalhadamente nas diferentes secções deste capítulo.

O tratamento da informação geoespacial utilizada é feito recorrendo ao Excel da *Microsoft* (2016) e ao *software* ArcGIS 10.6 da Esri. A modelação é realizada com o *software* GWR4 (Nakaya, Fotheringham, Charlton, & Brunsdon, 2009).

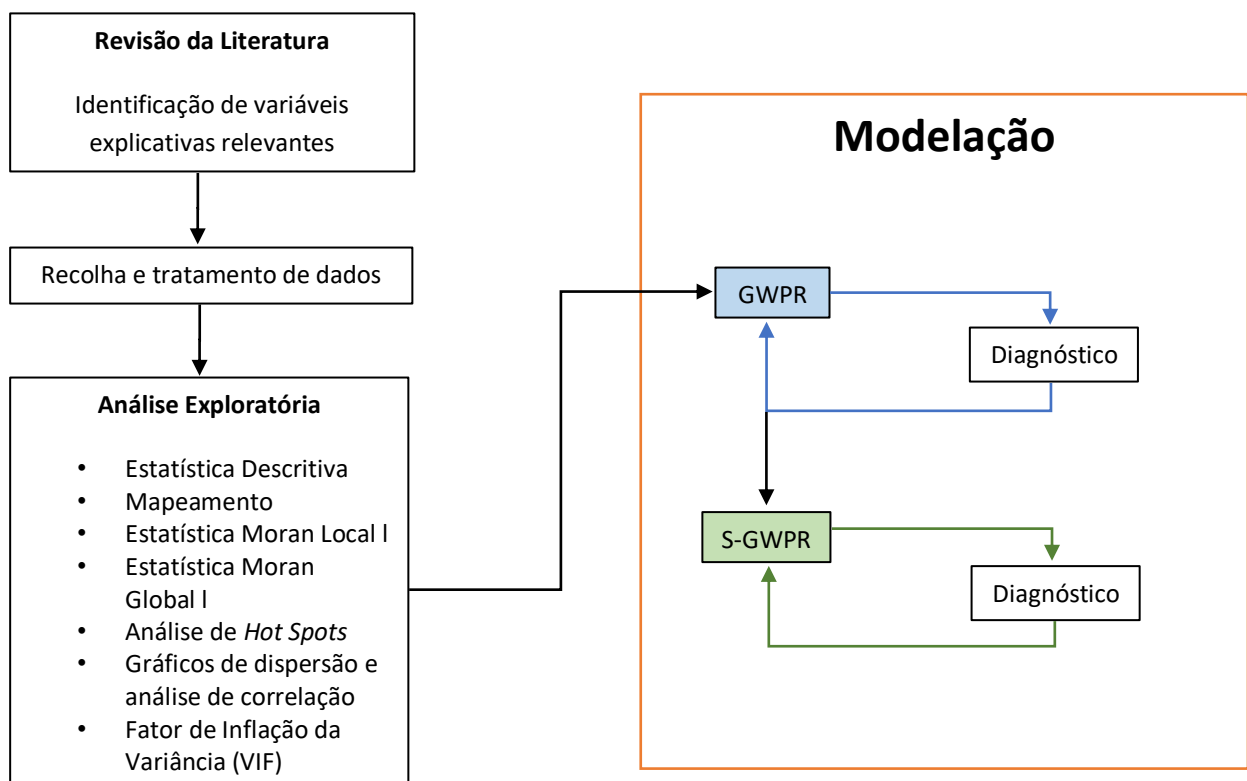


Figura 3.1 – Diagrama da metodologia aplicada.

3.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO E DESCRIÇÃO DOS DADOS

A presente investigação circunscreve-se em termos territoriais a Portugal Continental. A variável de estudo corresponde ao número de crimes contra o património observados em 2017, por município.

Com base na mais recente avaliação da população residente, efetuada em 2011, considerou-se neste estudo a divisão administrativa vigente nesse ano, totalizando 278 municípios numa área total de 92 212 km². Nesse ano, o continente registava 10 562 178 indivíduos residentes, dos quais 5 046 600 eram homens e 5 515 578 mulheres. Registou-se um decréscimo na percentagem de jovens em Portugal, de 16% em 2001 para 15% em 2011, ao passo que a de idosos aumentou de 16% para 19%. O índice de envelhecimento aumentou de 102, em 2001, para 128 em 2011, consequência direta da estrutura demográfica do país. O número de famílias clássicas subiu para 4 043 726, porém, o número médio de pessoas por família diminuiu para 2,58. No que se refere a nível de educação, Portugal progrediu consideravelmente nas últimas décadas. Os resultados do estudo revelaram ainda que a proporção da população com o grau de ensino superior é de 15%, e 50% da população possui pelo menos o 9º ano de escolaridade (Censos 2011 Resultados Definitivos - Portugal, 2012).

No que concerne ao período de estudo, em 2017, a população residente no continente foi estimada em 9 792 797 pessoas, registando-se 4 630 471 homens e 5 162 326 mulheres¹³, permanecendo a tendência de decréscimo populacional, ainda que, atenuado face aos últimos anos. O envelhecimento demográfico continuou a acentuar-se, registando-se um índice de envelhecimento de 156,1¹⁴. No mesmo período de referência, 78 966 indivíduos logravam um diploma universitário¹⁵.

O povoamento do território e as dinâmicas demográficas presenciadas nos últimos dez anos revelam uma distribuição geográfica das cidades muito diversa. O contraste na distribuição espacial entre o interior e o litoral do país é muito grande. Evidenciou-se a desertificação em grandes áreas do interior do país, e densificaram-se os territórios do litoral e as áreas metropolitanas, em particular a de Lisboa. A densidade populacional do país era de 110,5 hab/km², em 2011 (Censos 2011 Resultados Definitivos - Portugal, 2012), e estima-se que fosse de 111,7 hab/km², em 2017, de acordo com os dados do portal PORDATA¹⁶.

¹³ Consultado em <https://www.pordata.pt/Subtema/Municipios/População+Residente-214>; acedido em 19/05/2020.

¹⁴ Consultado em <https://www.pordata.pt/Municipios/Índice+de+envelhecimento-458>; acedido em 19/05/2020.

¹⁵ Consultado em <https://www.pordata.pt/Portugal/Diplomados+no+ensino+superior+por+tipo+de+ensino+e+por+sexo-690>; acedido em 19/05/2020.

¹⁶ Consultado em <https://www.pordata.pt/Municipios/Densidade+populacional-452>; acedido em 07/05/2020.

3.2. RECOLHA E TRATAMENTO DOS DADOS

Os dados recolhidos relativos aos crimes contra o património em Portugal, respeitam ao período de 2017, perfazendo um total de 163 108 registos. O número de crimes em cada município varia entre 15 e 24 817 (Figura 3.2.1). Estes dados foram obtidos pela Direção-Geral de Política de Justiça (DGPJ) e pelo Ministério da Justiça (MJ), sendo posteriormente compilados e complementados pelos dados disponíveis no portal *PORDATA* (<http://www.pordata.pt>). As divisões administrativas de Portugal Continental utilizadas na cartografia correspondem às da Carta Administrativa Oficial de Portugal (CAOP), disponibilizada pela Direção Geral do Território (DGT).

Deste modo, considerou-se como variável de estudo o *Número de crimes contra o património nos municípios de Portugal Continental*. Relativamente à análise e interpretação dos dados referentes à criminalidade, é frequente o uso do conceito de taxa de criminalidade, uma vez que, regiões com mais residentes, tendem a manifestar uma maior incidência de crimes, em valor absoluto, o que não assegura que estas sejam as unidades territoriais com mais violência. Assim sendo, recorre-se à taxa de crime contra o património, por mil habitantes, para efeitos de comparação de unidades de território com diferentes números de habitantes, obtendo-se assim uma perceção mais rigorosa da distribuição geográfica deste fenómeno (veja-se a secção 4.1).

Número de Crimes Contra o Património nos Municípios de Portugal Continental em 2017

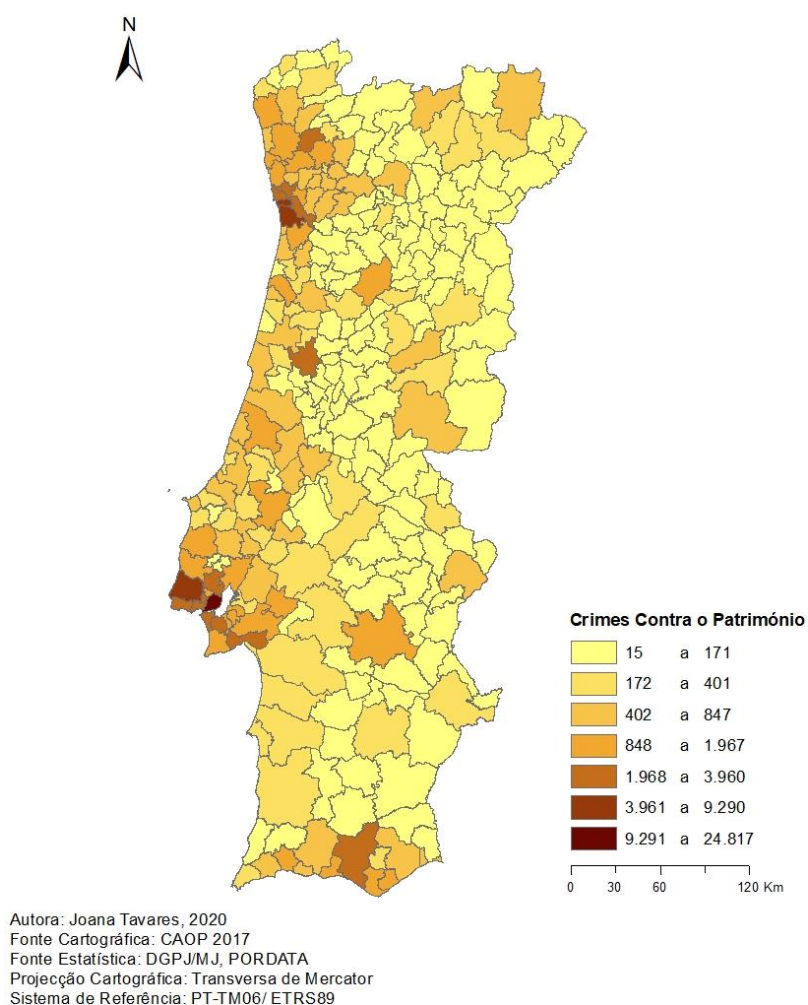


Figura 3.2.1 – Mapa da distribuição espacial do número de crimes contra o património, em 2017.

Tendo em conta a revisão de literatura realizada e os diferentes estudos sobre o presente tema, foram consideradas as variáveis independentes apresentadas na Tabela 3.2.1, dado que são destacadas por outros autores como potenciais variáveis explicativas da criminalidade e representativas dos diversos fatores que influenciam este fenómeno. Estas, foram também selecionadas tendo por base a Teoria da Atividade Rotineira e Teoria da Desorganização Social.

Através do portal *PORDATA*, foram obtidos os dados das variáveis necessárias para conduzir o estudo. Ressalva-se que todos os dados foram recolhidos a nível municipal para Portugal Continental.

Tabela 3.2.1 – Variáveis utilizadas no presente estudo.

Abreviatura	Variável	Descrição	Ano	Fonte
Crimes	Crime contra o património	Valor absoluto de crimes contra o património registados pela polícia, em cada unidade administrativa.	2017	<i>Pordata</i>
TxCrimes	Taxa de crime contra o património	Valor absoluto de crimes contra o património, dividido pelo valor absoluto de residentes, em cada unidade administrativa e multiplicado por 1 000 habitantes.	2017	<i>Pordata</i>
DensPop	Densidade populacional	“Intensidade do povoamento expressa pela razão entre o número de habitantes de uma determinada área territorial e a superfície desse território (Fórmula matemática: Nº de habitantes/Superfície em Km ²)”. (metainformação – INE)	2017	<i>Pordata</i>
TxBtEscola	Taxa bruta de escolarização	“Taxa Bruta de Escolarização, por sexo, nível de ensino, ciclo de estudos e concelho. (Fórmula matemática: (Alunos matriculados no nível ou ciclo de estudo x / População residente com idade normal de frequência do nível ou ciclo de estudo x) * 100)” (metainformação – DGEEC).	2017/ 2018 ¹⁷	<i>DGEEC</i>

¹⁷ Data relativa ao ano Letivo 2017/2018.

Abreviatura	Variável	Descrição	Ano	Fonte
TxRetDesis	Taxa de retenção e desistência no ensino básico	“Proporção de alunos sem aproveitamento escolar” e “Proporção de alunos que abandonam a frequência das atividades letivas de um ano letivo. Nota: inclui-se no abandono, a anulação da matrícula e a exclusão por excesso de faltas (Fórmula matemática: (Alunos do ensino básico que permanecem, por razões de insucesso ou de tentativa voluntária de melhoria de qualificações, no mesmo ano de escolaridade/ Alunos matriculados no ensino básico, nesse ano letivo) * 100)” (metainformação – DGEEC).	2017	<i>Pordata</i>
TxPopJov	Taxa de população jovem residente	“Taxa de indivíduos entre os 15 e os 24 anos. Consideram-se os indivíduos que habitam numa determinada unidade de alojamento a maior parte do ano com a família ou detêm a totalidade ou a maior parte dos seus haveres.” (metainformação – INE)	2017	<i>Pordata</i>
BenRMG_RSI	Taxa de beneficiários do RMG e RSI	“Beneficiários do Rendimento Mínimo Garantido e Rendimento Social de Inserção da Segurança Social no total da população residente com 15 e mais anos (%). Estes rendimentos representam o montante que a segurança social atribui mensalmente às famílias mais carenciadas para apoiar a sua subsistência e progressiva inserção na comunidade e no mercado de trabalho.” (metainformação – INE)	2017	<i>Pordata</i>
Desempds	Taxa de desempregados	“Desempregados inscritos nos centros de emprego e de formação profissional (IEFP) em % da população residente com 15 a 64 anos (Fórmula matemática: (Desempregados inscritos nos centros de emprego e de formação profissional no ano civil / População média residente com 15 a 64 anos) * 100).” (metainformação – INE)	2017	<i>Pordata</i>

Abreviatura	Variável	Descrição	Ano	Fonte
N_Alojamts	Número médio de alojamentos de familiares clássicos por km ²	<p>“Considera-se uma família clássica o conjunto de pessoas que residem no mesmo alojamento e que têm relações de parentesco (de direito ou de facto) entre si, podendo ocupar a totalidade ou parte do alojamento. Considera-se também como família clássica qualquer pessoa independente que ocupe uma parte ou a totalidade de uma unidade de alojamento. Sendo um alojamento familiar clássico uma casa onde moram pessoas, como é o caso dos apartamentos ou moradias.</p> <p>(Fórmula matemática: Total de alojamentos familiares clássicos / Superfície em Km²)”</p> <p>(metainformação – INE)</p>	2017	<i>Pordata</i>
TxPopEstra	Proporção de população estrangeira	<p>“Proporção de pessoas de nacionalidade não portuguesa com autorização ou cartão de residência, em conformidade com a legislação de estrangeiros em vigor em % da população residente. (Fórmula matemática: (População de nacionalidade estrangeira no ano civil / População média anual residente) * 100)”. (metainformação – INE)</p>	2017	<i>Pordata</i>
PodComp	Poder de compra <i>per capita</i>	<p>“Indicador que traduz o poder de compra em termos per capita. É um número índice com o valor 100 na média do país, que compara o poder de compra manifestado quotidianamente, em termos per capita, nos diferentes municípios.”</p> <p>(metainformação – INE)</p>	2017	<i>Pordata</i>
RemBasMens	Remuneração base média mensal	<p>“Montante médio ilíquido (antes da dedução de quaisquer descontos), em euros, pago com carácter regular e garantido ao trabalhador no período de referência e correspondente ao período normal de trabalho.”</p> <p>(metainformação – <i>Pordata</i>)</p>	2017	<i>Pordata</i>

3.3. ANÁLISE EXPLORATÓRIA DOS DADOS

A Análise Exploratória de Dados Espaciais (em inglês, *Exploratory Spatial Data Analysis – ESDA*) tem como objetivo neste estudo identificar padrões globais e locais, tais como, a heterogeneidade espacial e autocorrelação espacial (dependência espacial existente entre os objetos geográficos), através de um conjunto de técnicas estatísticas e de informação geográfica. Em particular, a autocorrelação espacial permite identificar relações de vizinhança relevantes para uma determinada zona, isto é, as zonas próximas de um dado ponto que são suscetíveis de influenciar as observações nesse ponto (Fischer & Wang, 2011). Esta análise permite, igualmente, demarcar observações discrepantes no espaço, ou seja, *outliers* espaciais e sugerir a existência de *clusters* espaciais.

O primeiro passo para a realização da análise exploratória de dados espaciais é verificar se as taxas de crime contra o património são distribuídas aleatoriamente, ou se são, autocorrelacionadas no espaço. Considerando o valor observado, o Índice de Moran Global I permite identificar se o padrão na região de estudo é agrupado (*clustered*; autocorrelação espacial positiva), disperso (*dispersed*; autocorrelação espacial negativa) ou aleatório (*random*), revelando assim se existe semelhança aos valores nas outras localizações.

Recorre-se também a Indicadores Locais de Associação Espacial (em inglês, Local Indicators of Spatial Association – LISA), propostos por Anselin (1995), utilizando a estatística de Moran Local I como forma de identificar se as tendências locais diferem do padrão global. Assim, também é possível reconhecer a presença de *clusters* espaciais (zonas onde existe autocorrelação espacial local positiva) e *outliers* espaciais (autocorrelação espacial local negativa) estatisticamente significantes na taxa de criminalidade. Formalmente o indicador Moran Local I pode ser apresentado da seguinte forma:

$$I = \frac{n}{\sum \sum w_{ij}} \frac{\sum_i \sum_j w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (3.3.1)$$

onde y_i é a variável de interesse, n corresponde ao número de unidades espaciais e w_{ij} é o peso espacial para o par de unidades i e j , medindo o grau de interação entre elas. No presente estudo, as unidades espaciais correspondem aos municípios.

O indicador de Moran I varia entre -1 e 1, sendo que, valores positivos indicam uma tendência de agrupamento (*cluster*) no espaço de valores semelhantes (High-High, Low-Low), denotando a existência de autocorrelação espacial positiva. Por outro lado, um valor negativo indica uma tendência de dispersão (*outliers* espaciais), isto é, revela-se autocorrelação espacial negativa quando áreas geográficas tendem a ser rodeadas por vizinhos com valores muito dessemelhantes (High-Low, Low-High). Qualquer um destes padrões revela a presença de heterogeneidade espacial. A inexistência de autocorrelação espacial significativa entre os valores da região relativamente aos seus vizinhos, é revelada por valores próximos de zero. Por último, a “*magnitude da estatística I de Moran fornece a força da autocorrelação espacial. Quanto mais próximo de um, mais forte é a concentração; quanto mais próximo de -1, mais dispersos estão os dados.*” (Almeida, 2012).

Getis e Ord, em 1992, sugeriram a análise da associação espacial local, baseada num indicador de concentração espacial (Getis & Ord, 1992), frequentemente aplicada na averiguação de padrões da criminalidade. Para cada observação i , a estatística Getis-Ord G_i^* , G_i^* , avalia se existem agrupamentos

de valores semelhantes, isto é, em que medida a observação i é rodeada por agrupamentos de valores altos (*hot spot*) ou agrupamentos de valores baixos (*cold spot*). Formalmente, a estatística $G_i^*(d)$, é expressa por:

$$G_i^*(d) = \frac{\sum_j w_{ij}(d)y_j}{\sum_j y_j}, \quad (3.3.2)$$

em que o somatório em j indica que somente os valores dos vizinhos próximos do município i serão aplicados no cálculo da estatística.

3.4. MODELOS COM DISTRIBUIÇÃO DE POISSON

A variável dependente do presente estudo corresponde ao número absoluto de crimes, que toma valores inteiros maiores que zero. Deste modo, prevê-se a violação do pressuposto da normalidade dos resíduos dos modelos de regressão linear múltipla e, conseqüentemente, que os estimadores sejam enviesados e que exista subestimação dos erros padrão dos coeficientes de regressão. Adicionalmente, nestas circunstâncias, a aplicação de modelos com distribuição de Poisson revela-se a mais adequada, dado que a utilização da função exponencial permite obter valores superiores a zero (Anselin, 2010), para dados de contagem e taxas. É também de referir que alguns autores, por exemplo, Osgood (2000) e Chen et al. (2017), defendem que os modelos de regressão de Poisson e Binomial Negativo são os mais adequados para dados de criminalidade expressos em contagem ou taxas.

Diversos estudos, como é o caso da investigação de Vilalta et al. (2018) e Chen et al. (2017), têm procurado introduzir os efeitos da componente espacial na modelação de dados de contagens. No presente estudo, recorre-se ao modelo GWPR, *Geographically Weighted Poisson Regression*, que consiste numa extensão do GWR com distribuição de Poisson, proposta por Nakaya et al. (2005). Tal como noutros estudos, os resultados do modelo local (GWPR) são comparados com os do modelo global (regressão de Poisson clássica). Adicionalmente, é investigado o modelo espacial misto (GWPR semi-paramétrico; abreviado por S-GWPR), que consiste em incluir tanto variáveis independentes globais como locais.

Seja Y_i o número de crimes contra o património no município i ($i = 1, 2, \dots, n$), e seja X_{ij} a j -ésima variável independente ($j = 1, 2, \dots, k$) no município i . A regressão de Poisson assume que Y tem distribuição de Poisson, ou seja, $Y \sim Poisson(\lambda)$ e, portanto, o valor médio de Y é dado por $E[Y] = \lambda$. A taxa de crimes contra o património no município representa-se por Y/POP , onde POP é o número de habitantes do município, e tem valor médio $E[Y/POP] = \lambda/POP$.

Posto isto, segundo Nakaya et al. (2005), o modelo de regressão de Poisson para a taxa de crimes contra o património apresenta-se de acordo com a seguinte equação:

$$\ln(\lambda_i/POP_i) = \beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \dots + \beta_k X_{k,i}, \quad (3.4.1)$$

onde $\ln(\lambda_i/POP_i)$ denota o logaritmo natural do valor esperado da taxa de crimes contra o património no município i , X_j ($j = 1, 2, \dots, k$) é a j -ésima variável explicativa e β_j ($j = 0, \dots, k$) são parâmetros a estimar pelo método da máxima verosimilhança. Esta equação pode ser reescrita de forma equivalente, tal como:

$$\ln(\lambda_i) = \ln(POP_i) + \beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \dots + \beta_k X_{k,i}. \quad (3.4.2)$$

O valor esperado do número de crimes contra o património no município i é então dado por:

$$\lambda_i = \exp(\ln(POP_i) + \beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \dots + \beta_k X_{k,i}). \quad (3.4.3)$$

Simplificando a fórmula anterior, obtém-se o **modelo global de regressão de Poisson** para o número de crimes contra o património, onde se considera o termo POP_i , usualmente designado por variável *offset*:

$$\lambda_i = POP_i \times \exp(\beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \dots + \beta_k X_{k,i}). \quad (3.4.4)$$

De acordo com Fotheringham et al. (2002), o modelo GWR integra na equação geral as coordenadas do ponto i , permitindo assim que as relações entre variáveis independentes e dependentes variem por localização. Nos modelos GWR, todas as variáveis independentes são locais, uma vez que estão associadas a parâmetros que dependem da localização do município i , para o qual a equação irá ser estimada, recorrendo às observações dos municípios que se encontram na sua vizinhança. O **modelo GWPR** para o número de crimes contra o património, corresponde então a uma extensão do modelo global formulado na equação anterior:

$$\lambda_i = POP_i \times \exp(\beta_0(u_i, v_i) + \beta_1(u_i, v_i) X_{1,i} + \beta_2(u_i, v_i) X_{2,i} + \dots + \beta_k(u_i, v_i) X_{k,i}), \quad (3.4.5)$$

onde (u_i, v_i) são as coordenadas espaciais do centróide do município i , e $\{\beta_0(u, v), \dots, \beta_k(u, v)\}$ são funções contínuas da localização (u, v) .

Algumas das variáveis independentes consideradas nesta investigação poderão ser espacialmente estacionárias, ou seja, a sua influência poderá ser sempre a mesma qualquer que seja o município i . Deste modo, o modelo GWPR semi-paramétrico, proposto por (Nakaya et al., 2009), apresenta-se como uma extensão da equação (3.4.5) e poderá revelar-se adequado para o desenvolvimento do presente estudo. Este modelo permite incluir variáveis que poderão ter um efeito explicativo global (tal como os modelos globais) e outras cujo poder explicativo varia localmente. O **modelo GWPR semi-paramétrico (S-GWPR)** é então dado por:

$$\lambda_i = POP_i \times \exp\left(\sum_k \beta_k(u_i, v_i) X_{i,k} + \sum_g \beta_g X_{i,g}\right), \quad (3.4.6)$$

onde se assume que o parâmetro associado à g -ésima variável independente X_g não depende da localização do município i .

Todos os modelos foram investigados através do programa GWR4.09, no qual foi selecionada a opção *Local-To-Global*, para executar uma sequência que permite eleger iterativamente variáveis globais para o modelo S-GWPR (Nakaya et al., 2009; Nakaya et al., 2016).

A estimação dos parâmetros $\beta_k(u_i, v_i)$ é realizada através de uma função de ponderação espacial, *spatial weighting function*, que pode ser fixa ou variável (*kernel* fixo ou adaptativo). Esta função é baseada na distância, tal que os concelhos mais próximos do município i tenham mais influência na estimativa desses parâmetros. Quando os polígonos que definem as unidades espaciais (*i.e.*, os

municípios) têm diferentes dimensões é preferível usar um *kernel* adaptativo, de modo que a largura de banda (parâmetro *bandwidth*) da função possa variar. Deste modo, o número de municípios vizinhos a considerar em cada equação de regressão local, (3.4.5) e (3.4.6), é otimizado.

Existem diversos métodos para o cálculo dos pesos, porém, no presente estudo recorreu-se a uma função de ponderação adaptativa do tipo *bi-square kernel*. A utilização deste método permite que o esquema de ponderação varie espacialmente de acordo com a densidade dos dados, produzindo melhores resultados quando comparada com a função *adaptive Gaussian*. Posto isto, a função adaptativa do tipo *bi-square kernel* é definida do seguinte modo:

$$w_{ij} = \begin{cases} \left(1 - \frac{d_{ij}^2}{\theta_{i(k)}}\right)^2, & d_{ij} < \theta_{i(k)}, \\ 0, & d_{ij} > \theta_{i(k)} \end{cases}, \quad (3.4.7)$$

em que w_{ij} corresponde ao valor do peso da observação no município j , na estimativa do coeficiente no município i de coordenadas (u_i, v_i) , d_{ij} representa a distância euclidiana entre os centróides dos municípios i e j e θ_i é a largura de banda (*bandwidth*) adaptativa definida como a k -ésima distância do vizinho mais próximo ao local i (Nakaya et al., 2016).

Assim, contrariamente ao *kernel* fixo, em que a distância é definida pelo utilizador, no caso de um *kernel* adaptativo a sua largura varia em função do número de vizinhos. A seleção do número de vizinhos a considerar no cálculo da largura de banda é realizada automaticamente pelo *software*, tendo em consideração o número que minimiza o valor do AICc (*Corrected Akaike Information Criterion*). Note-se que o AICc é uma variante do AIC (*Akaike Information Criterion*), porém corrigido, com o intuito de ter em consideração graus de liberdade pequenos, tal como é o caso dos modelos de regressão local (Nakaya et al., 2005). Este indicador é utilizado como critério para a seleção da largura de banda, sendo que, quanto menor o valor do AICc, melhor o ajuste do modelo.

Salienta-se que, contrariamente ao que sucede nos modelos clássicos de regressão linear, os modelos de regressão de Poisson não têm explícito o termo correspondente ao erro aleatório (Anselin, 2010). Deste modo, a comparação entre os modelos de Poisson será efetuada tendo em conta o indicador AICc, cuja formulação e definição, para os modelos de Poisson foi proposta por Nakaya et al. (2005). Como tal, considera-se o melhor modelo ajustado, aquele que apresentar o indicador AICc mais baixo.

4. RESULTADOS

Inicialmente, são apresentados os resultados preliminares referentes à análise exploratória de dados e respetivas estatísticas descritivas e, de seguida, é realizada a análise exploratória de dados espaciais com a motivação de investigar a distribuição dos dados ao longo do território. Por fim, são exibidos os resultados referentes à modelação dos crimes contra o património em Portugal Continental.

4.1. ANÁLISE EXPLORATÓRIA ESPACIAL DOS CRIMES CONTRA O PATRIMÓNIO

Na Figura 4.1.1 apresenta-se a distribuição espacial das taxas de crimes contra o património nos municípios de Portugal Continental. As áreas mais escuras do mapa representam as regiões com maiores taxas de criminalidade, por mil habitantes, e, por sua vez, as regiões mais claras correspondem aos municípios com as menores taxas.

Através da observação do mapa, é possível identificar diversos municípios com uma baixa taxa de crime ao longo de toda a área de estudo. Por outro lado, nomeadamente na capital portuguesa, ou seja, Lisboa, no Porto, Valença, e em Albufeira, evidenciam-se as taxas de crime mais elevadas. No seguimento, destacam-se alguns dos municípios da região Metropolitana de Lisboa, tais como, Amadora, Almada, Sesimbra, Setúbal, Barreiro e Montijo. Já na região do norte do país, destacam-se os municípios de Matosinhos, Maia, Espinho, Vila Nova de Gaia e Valença.

Taxa de Crime Contra o Património nos Municípios de Portugal Continental em 2017

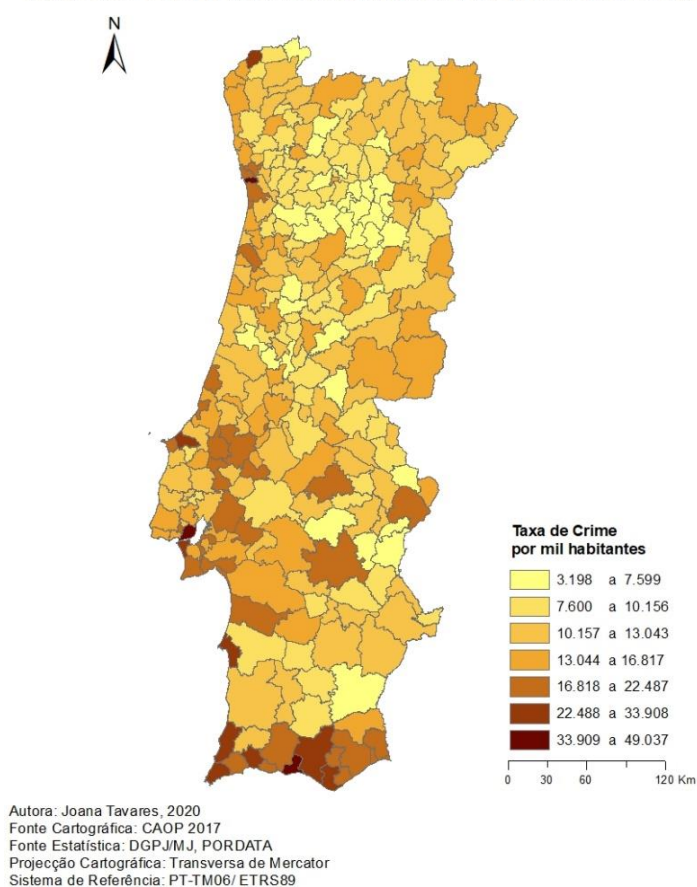


Figura 4.1.1 – Mapa da distribuição espacial da taxa de crime contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.

A Tabela 4.1.1, apresenta um resumo das estatísticas descritivas da variável de interesse e das variáveis independentes utilizadas no presente estudo. Os respetivos mapas da distribuição espacial podem ser encontrados no Anexo.

A densidade populacional é significativamente mais elevada no litoral do país, comparativamente aos municípios do interior. Consequentemente, a variável *N_Alojamts* distribui-se identicamente, apresentando valores mais elevados nas áreas metropolitanas de Lisboa e do Porto. A proporção de população estrangeira evidencia valores elevados nos municípios do sul do país e em Lisboa. As variáveis *BemRMG_RSI* e *Desempds* distribuem-se de forma idêntica entre si, como era expectável, uma vez que os indivíduos desempregados são, por norma, aqueles que beneficiam destes rendimentos que a Segurança Social atribui mensalmente às famílias mais carenciadas. Observam-se maiores percentagens referentes à variável *RemBasMens* ao longo dos municípios no litoral do país e valores mais baixos no interior do país, ao passo que a variável *TxPopJov* revela valores mais elevados na região norte e litoral de Portugal. Quanto às variáveis *TxBtEscola*, *TxRetDesis* e *PodComp* verifica-se que estas não apresentam qualquer tipo de padrão na sua distribuição espacial, exibindo valores diferentes ao longo de todos os municípios do país.

Relativamente à taxa de crime contra o património, a média de ocorrência de crimes, por município, em 2017 foi de aproximadamente 13 crimes por cada 1 000 habitantes, apresentando um desvio padrão de cerca de 6 crimes/1 000 habitantes corroborando a existência de alguma dispersão relativamente à distribuição de crimes no país. No que diz respeito ao valor máximo, este é relativo ao município de Lisboa, que conta com 49 ocorrências por mil habitantes. Em contrapartida, o município de Proença-a-Nova, no distrito de Castelo Branco, apresenta a taxa mais baixa de crimes por 1 000 habitantes.

Tabela 4.1.1 – Estatísticas descritivas das variáveis utilizadas no presente estudo.

Variável	Média	Desvio-padrão	Mínimo	Máximo
Taxa de crime contra o património	12.614	5.927	3.198	49.037
Densidade populacional	303.673	836.688	4.1	7529.7
Taxa de população jovem residente	10.274	1.362	6.488	13.973
Taxa de retenção e desistência no ensino básico	3.137	2.098	0	12.1
Taxa bruta de escolarização	108.875	14.916	72.1	181.9
Nº médio de alojamentos de familiares clássicos	165.585	443.799	5.6	3708.8
Taxa de beneficiários do RMG e RSI	2.988	1.988	0.4	15.5
Taxa de desempregados	6.482	2.328	3.0	15.8
Proporção de população estrangeira	2.970	3.932	0.3	26.6
Remuneração base mensal	782.147	134.464	640.1	2133.5
Poder de compra <i>per capita</i>	80.519	18.677	55.3	219.6

A distribuição das taxas de crimes encontra-se representada no histograma da Figura 4.1.2, com o intervalo de valores dividido em classes, onde a frequência dos dados em cada classe é caracterizada pela altura de cada barra. O histograma indica que os dados se encontram dispostos de forma assimétrica positiva (ou assimétrica à direita), uma vez que a cauda direita da distribuição indica a presença de um número relativamente pequeno de municípios com grandes valores de taxa de crime. Este resultado também pode ser averiguado através do valor de *skewness* (2.661) que, sendo positivo, evidencia a existência de uma distribuição assimétrica positiva. Relativamente à curtose (11.784), medida que caracteriza o “achatamento” da curva da função da distribuição, o seu valor indica que a mesma é mais alta (“afunilada”) e concentrada do que a Distribuição Normal, sugerido que a distribuição possua caudas pesadas.

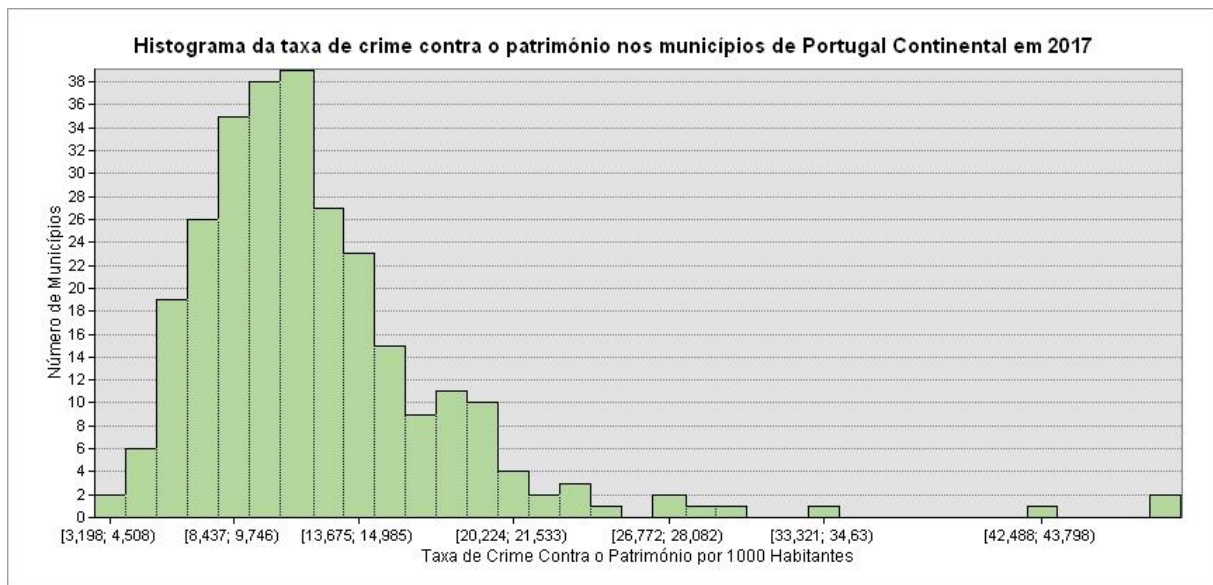


Figura 4.1.2 – Histograma relativo à taxa de crime contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.

4.1.1. AUTOCORRELAÇÃO ESPACIAL

Ao estudar o comportamento da taxa de crime contra o património dos municípios de Portugal, de modo a avaliar a autocorrelação espacial, encontra-se um valor de 0,354 para a estatística de Moran Global I (Figura 4.1.3). Do resultado do teste estatístico conclui-se que o indicador é estatisticamente significativo, com *valor-p* igual a zero, revelando assim que existe autocorrelação espacial positiva na taxa de crimes contra o património, que tendem a agrupar-se espacialmente ao longo do território nacional. Isto é, municípios com elevadas taxas de crimes tendem a ser rodeados por concelhos que apresentam taxas igualmente acentuadas. Por outro lado, municípios que apresentem baixas taxas de criminalidade, encontram-se cercados por municípios também com indicadores criminais reduzidos.

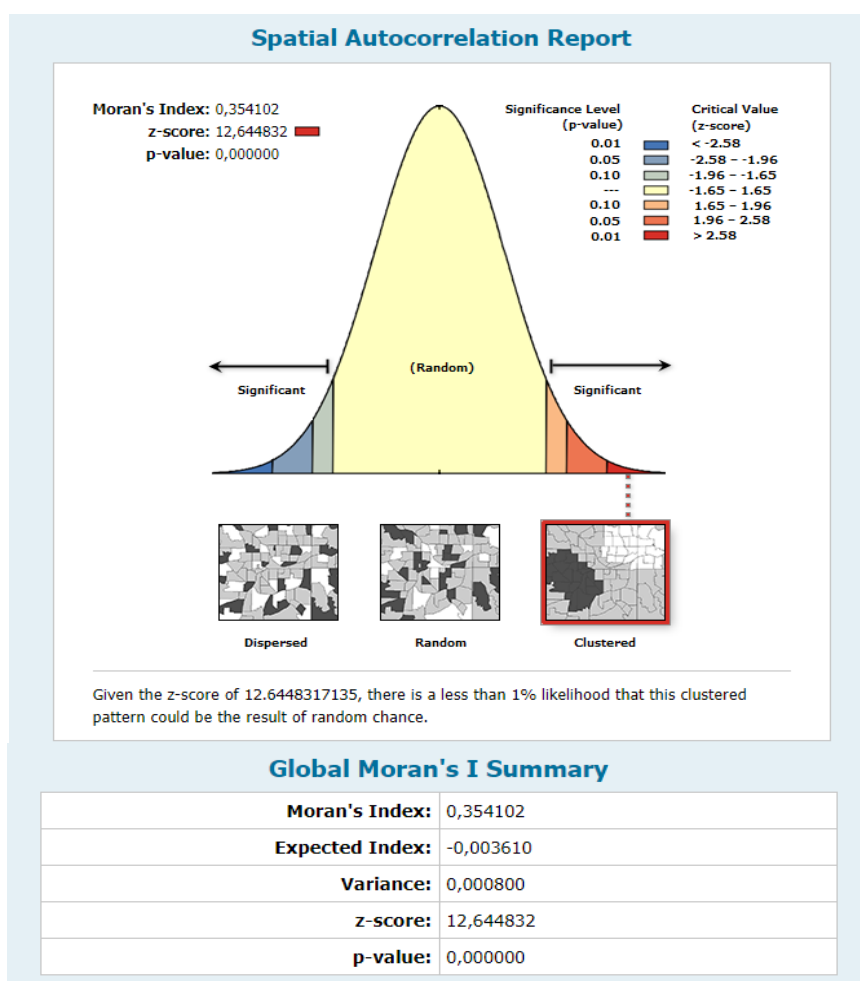


Figura 4.1.3 – Relatório da autocorrelação espacial (teste Moran Global I) referente à taxa de crime contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.

Considerando que os padrões globais podem ocultar padrões locais ou estar associados a certos regimes espaciais (*i.e.*, formas de heterogeneidade espacial), torna-se fundamental averiguar o surgimento de agrupamentos (*clusters*) e *outliers* espaciais.

Ao analisar o mapa da autocorrelação espacial local (usando um nível de significância de 5%) da taxa de crimes (Figura 4.1.4), identifica-se a existência de *clusters* de valores elevados, ou *clusters High-High*, na região do sul do país e nas Regiões Metropolitanas de Lisboa e Porto. Estes aglomerados

correspondem a regiões com valores elevados da variável de interesse e que se encontram significativamente correlacionadas a regiões vizinhas com valores igualmente altos. Já alguns dos municípios localizados na zona central do norte do continente e os concelhos de Reguengos de Monsaraz, Alandroal e Estremoz, no Alentejo, apresentam aglomerações espaciais de valores baixos, ou seja, *clusters Low-Low*, que se referem a regiões com reduzida taxa de criminalidade, rodeadas por municípios também com baixas taxas da variável em estudo.

Além disso, identifica-se também a presença de *outliers* espaciais. Por um lado, existem municípios com valores reduzidos das taxas de crime, correlacionadas significativamente com valores elevados nas regiões vizinhas, ou seja, valores *Low-High* onde se incluem unidades administrativas de Vila Franca de Xira, Odivelas e Monchique. Por outro lado, destacam-se os municípios de Montalegre, Braga, Felgueiras, Mesão Frio, Viseu, Celorico da Beira, Seia, Coimbra, Góis, Castanheira de Pêra e Évora, que representam *outliers* espaciais *High-Low*, ou seja, regiões onde valores elevados da taxa de crime se correlacionam significativamente com valores baixos nas áreas vizinhas.

Note-se que, o resultado relativo às regiões de *clusters* positivos significativos, se encontra em concordância com o previsto na análise exploratória inicial, em que se distinguiu os locais onde taxas elevadas de crime contra o património são mais predominantes.

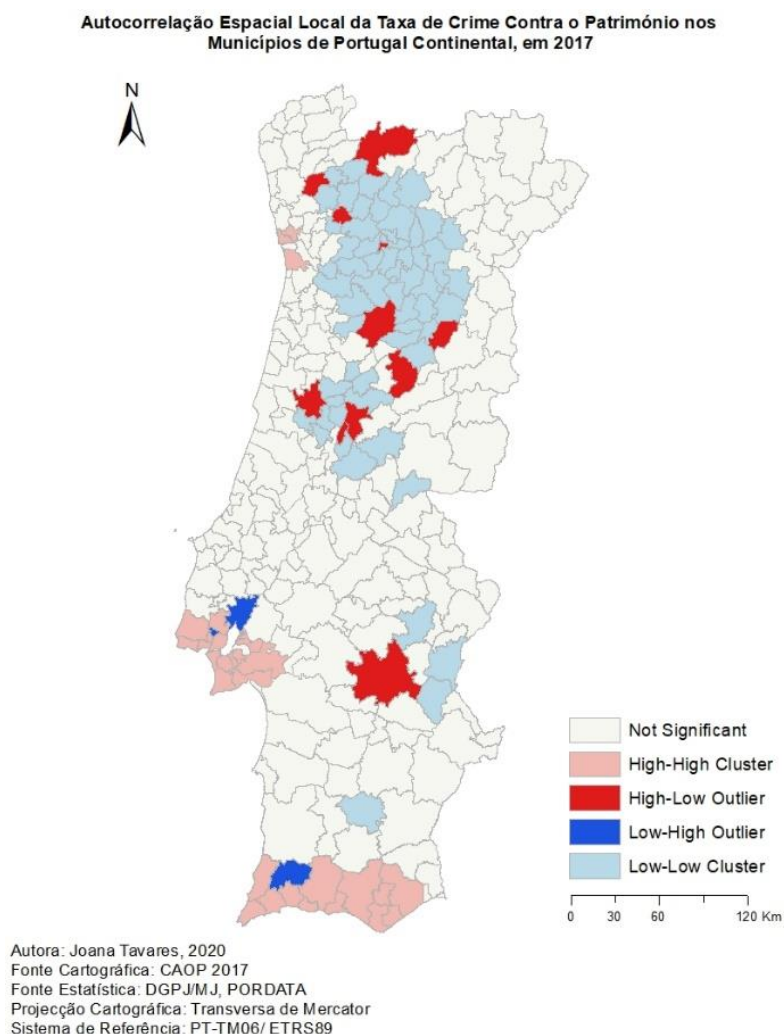


Figura 4.1.4 – Mapa da autocorrelação espacial (teste Moran Local I) referente à taxa de crimes contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.

4.1.2. ANÁLISE DE HOT SPOTS

Através da análise de *hot spots* é possível identificar agrupamentos (*clusters*) de valores altos, denominados *hot spots*, ou em sentido oposto, determinar valores baixos designados por *cold spots*. Deste modo, averigua-se se valores mais altos se encontram agrupados a outros valores elevados e se o mesmo sucede com valores mais baixos.

Uma vez mais, destacam-se as regiões metropolitanas de Lisboa e do Porto e a região do sul de Portugal, revelando agrupamentos significativos de municípios com altas taxas de crime contra o património (Figura 4.1.5). O norte do país contém um *cluster* composto por 43 municípios com menor criminalidade associada a crimes contra o património. Ainda neste seguimento, outro *cold spot* encerra as unidades administrativas de Santa Comba Dão, Penacova, Tábua, Condeixa-a-Nova, Lousã, Miranda do Corvo, Góis, Castanheira de Pêra, Proença-a-Nova, Estremoz, Alandroal e Reguengos de Monsaraz.

Os agrupamentos de demais unidades administrativas não são estatisticamente significativos para serem classificados como *clusters*.

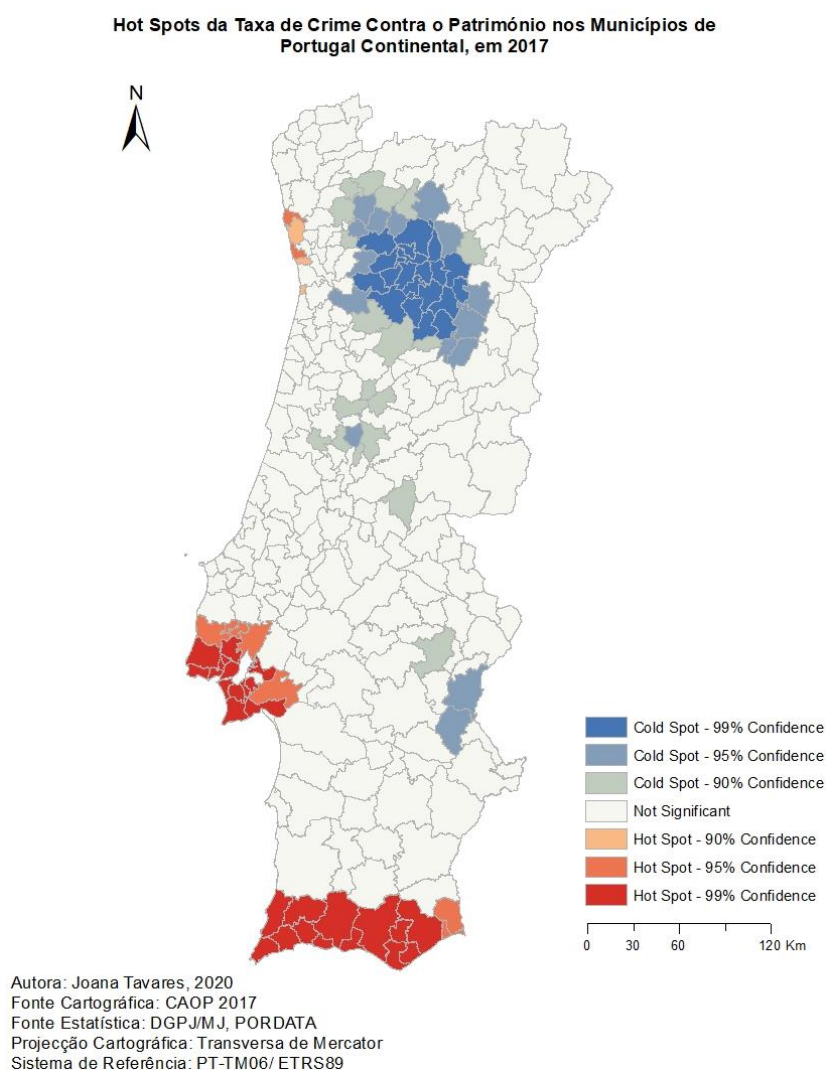


Figura 4.1.5 – Mapa de *Hot Spots* referente à taxa de crimes contra o património, por mil habitantes, nos municípios de Portugal Continental, em 2017.

4.2. ANÁLISE DA RELAÇÃO ENTRE OS CRIMES CONTRA O PATRIMÓNIO E VARIÁVEIS INDEPENDENTES

No sentido de investigar a relação entre cada par de variáveis presentes no estudo, recorreu-se à análise da matriz de correlação linear. O grau de correlação entre duas variáveis, designado por r , varia de -1 (correlação negativa perfeita) a 1 (correlação positiva perfeita). Um coeficiente de correlação positivo revela uma relação linear positiva entre as variáveis, isto é, quando uma das variáveis apresenta uma tendência crescente é expectável que a outra também aumente. Em contrapartida, quando o coeficiente é negativo, também é possível concluir que existe correlação, mas neste caso, quando o valor de uma variável aumenta, a outra tende a diminuir (correlação negativa ou inversa). Em ambos os casos, quanto mais próximo o grau de correlação se encontra dos extremos, *i.e.*, de 1 ou -1, mais forte é a correlação. Por último, um coeficiente de correlação nulo indica que não existe relação linear entre as duas variáveis.

Portanto, ao analisar a matriz de correlação linear (Tabela 4.2.3) de cada potencial variável explicativa e a variável de interesse, averigua-se que a correlação linear mais forte é entre a variável “Taxa de população estrangeira” ($TxPopEstra$; $r = 0.638$), seguindo-se as variáveis “Poder de compra per capita” ($PodComp$; $r = 0.617$), “Nº médio de alojamentos de familiares clássicos” ($N_Alojamts$; $r = 0.454$) e “Densidade Populacional” ($DensPop$; $r = 0.386$). Tem-se como variáveis pouco correlacionadas com a taxa de crime contra o património a “Taxa de população jovem residente” ($TxPopJov$; $r = -0.093$), “Taxa de desempregados” ($Desempds$; $r = -0.050$) e a “Taxa de beneficiários do RMG e RSI” ($BenRMG_RSI$, $r = 0.029$). Algumas das variáveis independentes também se encontram fortemente correlacionadas entre si, de onde se destaca a variável $PodComp$, que possui uma correlação elevada com diversas variáveis. Outra correlação forte, quase perfeita ($r = 0.988$), é encontrada entre as variáveis $N_Alojamts$ e $DensPop$ e, igualmente, entre as variáveis $Desempds$ e $BenRMG_RSI$ ($r = 0.766$). A presença de correlações elevadas pode ser um indício da existência de uma relação explicativa entre as variáveis, contudo não necessariamente.

Encontram-se dispostos no Anexo os respetivos gráficos de dispersão, que permitem obter uma análise mais pormenorizada do tipo e magnitude da relação entre as variáveis e de seguida são apresentadas as correlações lineares entre a variável de estudo e as variáveis independentes. Note-se que estas correlações são globais e, portanto, uma correlação global baixa com os crimes em questão não significa que, para alguns concelhos, a correlação local não seja elevada.

- **Densidade populacional (DensPop):** Segundo Cahill & Mulligan (2007), a densidade populacional aumenta o número de potenciais ofensores e, conseqüentemente, o aumento da atividade criminal verificando-se efetivamente que, em áreas mais urbanas e com uma maior concentração de população, existe uma maior ocorrência de roubos. No entanto, esta variável pode também contribuir com um efeito inverso, visto que, com o aumento populacional existe também um aumento de vigilância, o que leva a uma diminuição da taxa de criminalidade. A correlação linear entre a $DensPop$ e a taxa de crime contra o património é baixa e positiva ($r = 0.386$).
- **Taxa de população jovem residente (TxPopJov):** Variável frequentemente utilizada na revisão de literatura, visto que, representa um dos fatores com uma forte relação direta com a criminalidade. Teoricamente a juventude constitui umas das faixas etárias mais afetadas pela renda e desemprego, gerando assim conflito e desigualdades, que se tornam propensas à

origem de oportunidades para o aumento de ocorrências criminais. Andresen (2006), recorreu a esta variável verificando um efeito positivo da mesma sobre a taxa de criminalidade, revelando também ser o preditor mais significativo das taxas de criminalidade em Vancouver. Quanto à taxa de crime contra o património, a *TxPopJov*, apresenta um resultado inesperado ($r = -0.0933$), revelando uma correlação muito próxima de zero. Este resultado reforça a ideia de que a análise deve ser feita localmente, já que a relação desta variável com a criminalidade pode diferir de região para região, isto é, a resposta a determinado estímulo não é constante.

- **Taxa de retenção e desistência no ensino básico (*TxRetDesis*):** Variável recorrentemente utilizada em estudos sobre a criminalidade, dado que, os comportamentos criminosos são significativamente maiores em locais onde existe uma maior taxa de desistência e abandono escolar (C. J. Vilalta & Fondevila, 2019). Consequentemente, estes indivíduos tornam-se potenciais candidatos para a prática de atividades criminosas. Nesta investigação, a correlação entre a *TxRetDesis* e a variável resposta, revelou-se baixa ($r = 0.151$). No entanto, apresentou uma relação direta com a criminalidade, isto é, quanto maior a taxa de retenção e desistência no ensino básico, maior é a taxa de crimes contra o património.
- **Taxa bruta de escolarização (*TxBtEscola*):** Variável responsável por sintetizar o nível de escolaridade. Apresenta uma correlação relativamente baixa e positiva ($r = 0.193$) o que significa que, quanto mais alta a taxa bruta de escolarização, maior é a taxa de crimes contra o património. Ainda que esta não seja a direção esperada pela teoria, destaca-se que a relação entre as variáveis poderá não ser linear e variar no espaço.
- **Nº médio de alojamentos de familiares clássicos (*N_Alojamts*):** O aumento do número de habitações, é por norma, relacionado ao aumento da atividade criminosa (Andresen, 2006). Conforme os resultados, a correlação linear entre o *N_Alojamts* é moderada e positiva ($r = 0.454$). Portanto, quanto maior número de alojamentos de familiares clássicos, maior a taxa de crime.
- **Taxa de beneficiários do RMG e RSI (*BenRMG_RSI*):** Segundo Fuentes & Jurado (2019), outros estudos realizados em países desenvolvidos identificaram que variáveis que representam medidas de controlo social, têm um impacto positivo na criminalidade. Verifica-se que, embora muito baixa, a variável *BenRMG_RSI* apresenta uma correlação linear positiva ($r = 0.029$).
- **Taxa de desempregados (*Desempds*):** De acordo com a Teoria da Desorganização Social, o desemprego representa frequentemente um dos fatores fortemente ligados aos altos níveis de criminalidade, tendo em conta que contribui para a desorganização social e é também responsável por retratar o estatuto socioeconómico de uma localidade. Os resultados demonstram que esta variável apresenta uma correlação de -0.050 . Além do grau de correlação ser mais baixo do que o esperado, o sinal também é contrário ao previsto pela teoria. Graficamente é possível observar que os pontos se encontram bastante dispersos, sugerindo a inexistência de uma relação linear entre as variáveis. Note-se que a relação das variáveis poderá variar no espaço.

- **Proporção de população estrangeira (*TxPopEstra*):** A Teoria da Desorganização Social sugere que, áreas onde predomina a concentração de grupos pertencentes a minorias (equacionando possíveis dificuldades de integração e privação social), são geralmente positivamente correlacionadas com o crime (Shaw & McKay, 1942). Vilalta & Fondevila (2019), concluíram através do seu estudo que esta variável apresenta um efeito significativamente positivo com o número de roubos residenciais. Os resultados demonstram que esta variável apresenta a correlação linear mais forte ($r = 0.638$) com a variável dependente e os pontos que constituem o gráfico de dispersão seguem uma tendência positiva.
- **Remuneração base média mensal (*RemBasMens*):** Esta variável é igualmente responsável por representar o estatuto socioeconómico dos habitantes de uma localidade, uma vez que aspetos relacionados com a estabilidade da população, está associada à diminuição das taxas de criminalidade. Por outro lado, este resultado pode ser ambíguo, uma vez que este indicador pode revelar-se um alvo e fator de oportunidade para potenciais ofensores. O resultado indica que a relação entre a variável *RemBasMens* e a variável de estudo é relativamente baixa ($r = 0.373$) e, graficamente, é também possível verificar que existe uma relação linear entre estas variáveis.
- **Poder de compra *per capita* (*PodComp*):** Assim como a variável anterior, o poder de compra *per capita* representa o estatuto socioeconómico dos indivíduos. Os resultados permitem afirmar que a correlação entre o *PodComp* e a taxa de crime é elevada e positiva ($r = 0.617$).

Um método estatístico utilizado para investigar a presença de multicolinearidade, que ocorre quando duas ou mais variáveis independentes num modelo de regressão são correlacionadas (Daoud, 2017), recorre-se ao fator de inflação da variância (VIF). Este avalia o nível de aumento da variância de um coeficiente de regressão linear estimado, se as variáveis independentes estiverem correlacionadas. Valores de VIF abaixo de 10, por norma, indicam a ausência de multicolinearidade entre as variáveis independentes (R. M. O'Brien, 2007). Se este valor se encontrar acima de 10, conclui-se que existe redundância entre algumas variáveis, apontado para um modelo com *bias* e consequentemente as suas inferências tornam-se pouco confiáveis.

Os resultados apresentados na Tabela 4.2.1, obtidos no *software* ArcGIS a partir do modelo de regressão linear múltipla, mostram que as variáveis *DensPop* e *N_Alojamts* apresentam valores de VIF superiores a 10, sugerindo assim, que existem problemas de multicolinearidade, conforme averiguado anteriormente na análise de correlação. Este comportamento pode ser problemático para um modelo de regressão e, para evitar a multicolinearidade, recomenda-se que as variáveis sejam removidas dos modelos.

Tabela 4.2.1 – Fator de Inflação da Variância (VIF) das 10 variáveis presentes no estudo.

Variável	VIF
DensPop	51.333
TxPopJov	1.092
TxRetDesis	1.269
TxBtEscola	1.210
N_Alojamts	55.337
BenRMG_RSI	2.885
Desempds	2.627
TxPopEstra	1.243
RemBasMens	2.057
PodComp	3.128

Após a análise anterior, obteve-se novamente os valores dos VIFs, mas desta vez, sem a presença da variável *DensPop*. Pretende-se assim averiguar a alteração do comportamento das restantes variáveis e, em particular, verificar se o valor do VIF da variável *N_Alojamts*, reduz para menos de 10. Optou-se por remover a *DensPop*, dado que esta tem menor correlação com a *TxCrimes* do que a *N_Alojamts*. Por conseguinte, conforme é possível observar de seguida (Tabela 4.2.2), as 9 variáveis independentes apresentam valores de VIF inferiores a 3, pelo que se optou por incluir apenas estas 9 variáveis nos modelos de Poisson.

Tabela 4.2.2 – Fator de Inflação da Variância (VIF) das 9 variáveis independentes.

Variável	VIF
TxPopJov	1.072
TxRetDesis	1.269
TxBtEscola	1.186
N_Alojamts	1.644
BenRMG_RSI	2.885
Desempds	2.599
TxPopEstra	1.225
RemBasMens	2.025
PodComp	2.939

Tabela 4.2.3 – Matriz de correlação linear das variáveis do presente estudo.

	<i>TxCrimes</i>	<i>DensPop</i>	<i>TxPopJov</i>	<i>TxRetDesis</i>	<i>TxBtEscola</i>	<i>N_Alojamts</i>	<i>BenRMG_RSI</i>	<i>Desempds</i>	<i>TxPopEstra</i>	<i>RemBasMens</i>	<i>PodComp</i>
<i>TxCrimes</i>	1										
<i>DensPop</i>	0.386244	1									
<i>TxPopJov</i>	-0.09336	0.004107	1								
<i>TxRetDesis</i>	0.150743	-0.03387	-0.11777	1							
<i>TxBtEscola</i>	0.193367	0.122803	-0.14356	0.052309	1						
<i>N_Alojamts</i>	0.454302	0.988193	-0.01879	-0.02414	0.162511	1					
<i>BenRMG_RSI</i>	0.029097	0.098658	0.045679	0.360749	0.148176	0.116726	1				
<i>Desempds</i>	-0.05002	0.040579	0.035617	0.199579	0.113774	0.059376	0.766281	1			
<i>TxPopEstra</i>	0.637931	0.161859	-0.12579	0.139856	0.047405	0.189855	-0.14272	-0.15704	1		
<i>RemBasMens</i>	0.37291	0.440483	0.061131	-0.06126	0.070514	0.44773	-0.03895	-0.1399	0.177601	1	
<i>PodComp</i>	0.617404	0.566231	0.031188	-0.06272	0.278290	0.603762	-0.01516	-0.13243	0.313388	0.695771	1

4.3. MODELAÇÃO DOS CRIMES CONTRA O PATRIMÓNIO

Nesta secção, analisa-se os resultados da modelação dos crimes contra o património com distribuição de Poisson (Tabela 4.3.1), dos crimes contra o património. As 9 variáveis independentes (especificadas na secção 3.2) incluídas no Modelo 1 foram testadas diversas vezes, com diferentes combinações, em modelos de regressão Global, modelos locais GWPR e modelo GWPR semi-paramétrico (S-GWPR). Note-se que a escolha das combinações em estudo teve por base a análise das relações existentes entre as variáveis do estudo e os resultados encontram-se dispostos por ordem do melhor para o pior AICc dos modelos GWPR.

Uma vez que o número de habitantes é diferente em cada concelho e a quantidade de eventos tende a ser relativamente reduzida em relação ao tamanho da população, torna-se fundamental a inclusão de uma componente no modelo, denominada *offset*, para o ajuste da Regressão de Poisson. Deste modo, todos os modelos elaborados, apresentam a população residente como variável *offset* (cf. o modelo descrito na secção 3.4).

Tabela 4.3.1 – Resultados dos modelos de regressão Global e Local (GWPR) testados.

Modelos	Variáveis Independentes	AICc do Modelo Global	AICc do Modelo GWPR	Percent deviance explained do Modelo Global	Percent deviance explained do Modelo GWPR
Modelo 1	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (9 variáveis)	6328.360	2937.661	0.861976	0.941470
Modelo 8	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (8 variáveis)	6326.444	2938.292	0.861971	0.940991
Modelo 6	PodComp; TxPopJov; TxRetDesis; TxBtEscola ; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (8 variáveis)	6545.357	2999.848	0.857180	0.939530
Modelo 7	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts ; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (8 variáveis)	6326.214	3045.044	0.861976	0.938852

Modelos	Variáveis Independentes	AICc do Modelo Global	AICc do Modelo GWPR	Percent deviance explained do Modelo Global	Percent deviance explained do Modelo GWPR
Modelo 5	TxPopJov; PodComp; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	6324.318	3062.525	0.861970	0.937960
Modelo 3	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (8 variáveis)	6372.742	3092.361	0.860957	0.937563
Modelo 9	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (6 variáveis)	6413.493	3264.871	0.859973	0.932586
Modelo 11	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (5 variáveis)	6749.296	3349.604	0.852578	0.930480
Modelo 10	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (5 variáveis)	6821.190	3465.591	0.851005	0.927567
Modelo 4	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	8219.041	3661.203	0.820509	0.924551
Modelo 2	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (8 variáveis)	8152.876	3669.091	0.822004	0.924930
Modelo 15	PodComp; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	7575.738	3695.206	0.834586	0.923893

Modelos	Variáveis Independentes	AICc do Modelo Global	AICc do Modelo GWPR	Percent deviance explained do Modelo Global	Percent deviance explained do Modelo GWPR
Modelo 14	PodComp ; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	8243.499	3867.498	0.819974	0.920283
Modelo 12	PodComp ; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	7529.236	3900.690	0.835604	0.919182
Modelo 13	PodComp ; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	9165.079	3906.035	0.799808	0.919152
Modelo 17	PodComp ; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	9178.405	4185.598	0.799516	0.913153
Modelo 16	PodComp ; TxPopJov; TxRetDesis; TxBtEscola; N_Alojamts; BenRMG_RSI; Desempds; TxPopEstra; RemBasMens (7 variáveis)	14071.495	4692.504	0.692443	0.902055

Ao comparar os resultados dos modelos de Poisson Global e GWPR, verifica-se que os modelos locais GWPR apresentam menores AICc, revelando assim um melhor ajuste. O indicador *Percent deviance explained* também melhora consideravelmente, em comparação aos modelos globais.

Relativamente ao modelo semi-paramétrico (S-GWPR), o relatório da ferramenta Local-To-Global (Figura 4.3.1) permite aferir que não existe uma melhoria na modelação quando as 9 variáveis independentes são iterativamente selecionadas como variáveis globais.

The summary of the L -> G variable selection model	AICc
GWR model before L -> G selection	2937.661468
GWR model after L -> G selection	2937.661468
Improvement	0.000000

Figura 4.3.1 – Resultado da ferramenta Local-To-Global do modelo semi-paramétrico (S-GWPR).

Apesar das medidas da qualidade do ajuste dos modelos locais serem idênticas, o Modelo 8 tem menos uma variável independente do que o Modelo 1. Posto isto, constata-se que o Modelo 8 (GWPR) com 8 variáveis explicativas, apresenta uma melhor *performance*, uma vez que exhibe o menor valor do indicador AICc e maior valor de *Percent deviance explained*, 94%. Assim, este modelo é considerado o “Modelo Final”, e os seus resultados são analisados em maior detalhe nas secções seguintes.

Por fim, o Modelo 8 Global obtido apresenta-se de acordo com a seguinte equação:

$$\ln(\widehat{\text{Crimes}}) = -5.2838 + 0.0018 \text{TxPopJov} + 0.0309 \text{TxRetDesis} + 0.0006 \text{TxBtEscola} + 0.0009 \text{N_Alojamts} + 0.0680 \text{BenRMGRSI} - 0.0383 \text{Desempds} + 0.0616 \text{TxPopEstra} + 0.0067 \text{PodComp} + \ln(\text{PopResid}) \quad (4.3.1)$$

onde $\widehat{\text{Crimes}}$ representa o valor médio do número de crimes contra o património. Observa-se que os sinais dos parâmetros estão de acordo com o esperado, à exceção da variável taxa bruta de escolarização (*TxBtEscola*) e da taxa de desempregados (*Desempds*), que se esperava apresentarem uma relação com a variável independente negativa e positiva, respetivamente. Por fim, como discutido anteriormente, o Modelo 8 GWPR apresentou uma melhor *performance* do que este modelo.

4.3.1. ANÁLISE E INTERPRETAÇÃO DOS PARÂMETROS LOCAIS DO MODELO FINAL

O modelo final obtido (Modelo 8 GWPR), é considerado com o objetivo de explorar de que forma a relação entre as variáveis explicativas e os crimes contra o património variam no espaço. De seguida são expostos todos os mapas com a distribuição dos coeficientes locais, manifestando a existência de não-estacionariedade através de diferentes padrões espaciais dos valores dos coeficientes de cada variável explicativa. Os mapas dos coeficientes locais são apresentados tendo em consideração os mapas dos respetivos valores *pseudo-t*. Note-se que não existem testes estatísticos para investigar a significância dos coeficientes dos modelos locais (GWR e suas variantes), e, por essa razão, recorre-se a valores *pseudo-t* para a avaliação dos coeficientes. Assim, valores *pseudo-t* absolutos superiores a 1.96 ($|t| > 1.96$, i.e., $t < -1.96$ ou $t > 1.96$) indicam que a relação local da variável explicativa com os crimes poderá ser “significativa”, com 95% de confiança. Não são apresentados os valores dos coeficientes nos restantes municípios (i.e., quando $-1.96 < t < 1.96$).

Ainda, tendo em conta que o modelo de regressão de Poisson expressa o *log* do valor esperado da contagem como uma função das variáveis independentes, a interpretação dos valores dos parâmetros locais não é tão intuitiva. Por conseguinte, a análise dos valores dos coeficientes focar-se-á apenas no seu sinal e ordem de grandeza. Quanto ao sinal do coeficiente, este sugere a direção da relação das variáveis explicativas com a variável de estudo. Se este for positivo, indica que as variáveis têm tendência a aumentar ou diminuir na mesma direção, e por outro lado, um sinal negativo sugere que a relação seja em direções contrárias.

Como pode ser observado na Figura 4.3.2, o mapa dos coeficientes locais da variável taxa de população jovem (*TxPopJov*), no norte de Portugal, apresenta maioritariamente um sinal negativo, o que não é esperado pela literatura. Consequentemente, nesta área a relação desta variável com o número de crimes é negativa. O valor dos coeficientes, vai aumentando, tornando-se positivo na região metropolitana de Lisboa e no sul do país. Ressalva-se que existem algumas regiões a norte do país com sinal positivo (regiões a vermelho). A variável apresenta um maior poder explicativo, *i.e.*, com maior coeficiente “significativo”, nos municípios de Sintra, Cascais e Oeiras. Por último, na área a branco disposta ao longo do país, especialmente na zona centro, parece não existir uma relação significativa entre esta variável explicativa e a variável dependente (estas regiões apresentam valores *pseudo-t* entre -1.96 e 1.96).

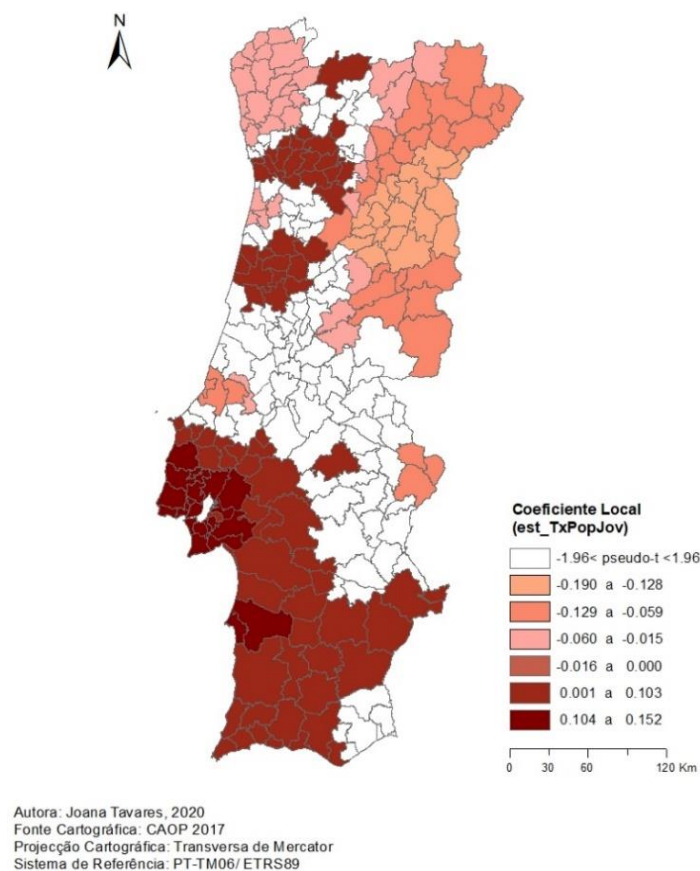


Figura 4.3.2 – Resultados do coeficiente local do predictor taxa de população jovem no modelo 8 GWPR.

A variável taxa de retenção e desistência no ensino básico (*TxRetDesis*), apresenta coeficientes positivos na maior parte da região de estudo (Figura 4.3.3). Este resultado era esperado, considerando a complementaridade entre a desistência e abandono escolar e a prática de atividades criminosas, relatada na literatura. No entanto, os resultados revelam que, em algumas áreas, nomeadamente, na região de Beja e Sines, no Alentejo, e nos municípios de Sabrosa, Vila Real e Santa Marta de Penaguião a variável tem um impacto negativo sobre os crimes. Consistentemente, considera-se que a variável *TxRetDesis* só poderá ser estatisticamente relevante nos concelhos onde os valores *pseudo-t* são $t < -1.96$ ou $t > 1.96$. Assim sendo, destacam-se os municípios de Valença, Monção e Vila Nova de Cerveira como regiões onde a variável apresenta um maior poder explicativo.

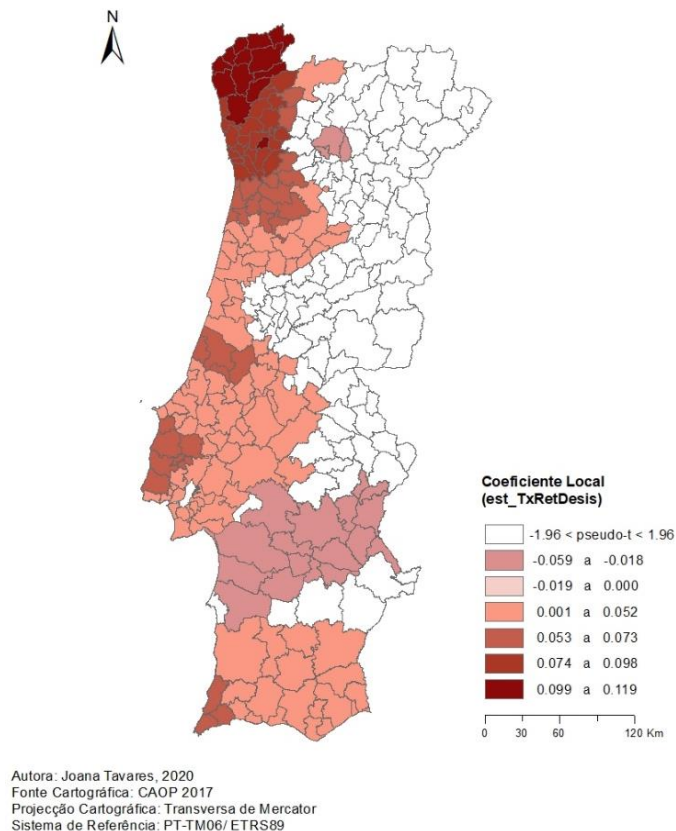
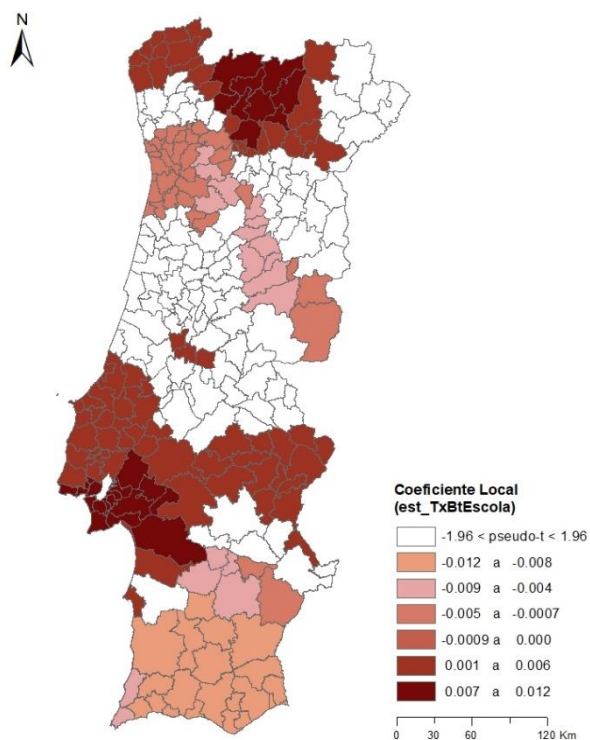


Figura 4.3.3 – Resultados do coeficiente local do predictor taxa de retenção e desistência no ensino básico no modelo 8 GWPR.

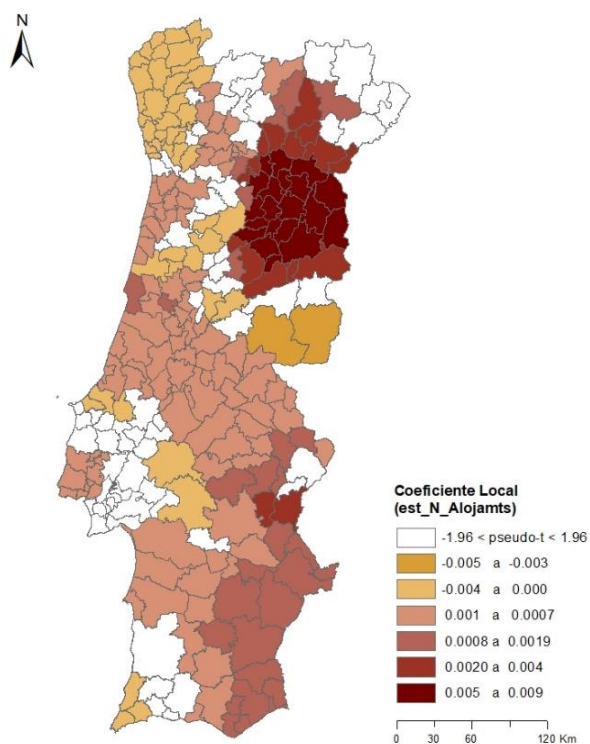
O mapa do coeficiente da variável taxa bruta de escolarização (*TxBtEscola*), explicita bastante bem a não-estacionaridade (Figura 4.3.4), visto que, a mesma variável apresenta variações de magnitude e sinal nos diferentes concelhos. O efeito da variável no Algarve, em Beja, no Porto e em alguns concelhos nos distritos de Viseu, Guarda e Castelo Branco é negativo, como era esperado pela teoria. Por outro lado, nas regiões de Viana do Castelo, Vila Real, alguns concelhos de Bragança, Lisboa, Leiria, Sines, Santarém e Portalegre os coeficientes locais apresentam um sinal positivo. Da análise dos *pseudo-t*, pode-se constatar que existem diversos concelhos em que os coeficientes não são estatisticamente significativos (*i.e.*, nessas regiões a variável pode não ter poder explicativo). Por outro lado, realçam-se os municípios de Montalegre, Boticas e Ribeira de Pena como sendo os mais relevantes, dado que possuem um maior coeficiente positivo “significativo”.

O mapa da Figura 4.3.5, referente à variável número médio de alojamentos de familiares clássicos (*N_Alojamts*), manifesta coeficientes positivos em grande parte da área em análise. Destaca-se, na região do nordeste do país, os municípios que têm coeficientes mais elevados (e positivos) no país, sendo estes os concelhos de Penalva do Castelo, Aguiar da Beira e Fornos de Algodres. Estes apresentam o maior potencial explicativo, onde quanto maior o *N_Alojamts*, maior o número de ocorrências criminais (Andresen, 2006). Já as regiões a amarelo revelam ser áreas onde a variável não tem um papel tão importante, e a relação é negativa.



Autora: Joana Tavares, 2020
 Fonte Cartográfica: CAOP 2017
 Projecção Cartográfica: Transversa de Mercator
 Sistema de Referência: PT-TM06/ETRS89

Figura 4.3.4 – Resultados do coeficiente local do predictor taxa bruta de escolarização no modelo 8 GWPR.



Autora: Joana Tavares, 2020
 Fonte Cartográfica: CAOP 2017
 Projecção Cartográfica: Transversa de Mercator
 Sistema de Referência: PT-TM06/ETRS89

Figura 4.3.5 – Resultados do coeficiente local do predictor nº médio de alojamentos de familiares clássicos no modelo 8 GWPR.

O mapa dos coeficientes locais (Figura 4.3.6) da variável taxa de beneficiários do RMG e RSI (*BenRMG_RSI*) exibe coeficientes positivos em grande parte da região de estudo, isto é, a variável apresenta uma influência positiva sobre o crime nestes locais. Assim, constata-se a tendência de que, quanto maior a taxa de beneficiários, maior o número de crimes (Fuentes & Jurado, 2019). Destacam-se aqui as regiões de Sesimbra, Seixal e Barreiro, onde a variável *BenRMG_RSI* é mais relevante. Por outro lado, na região sul do país a influência é menor e negativa.

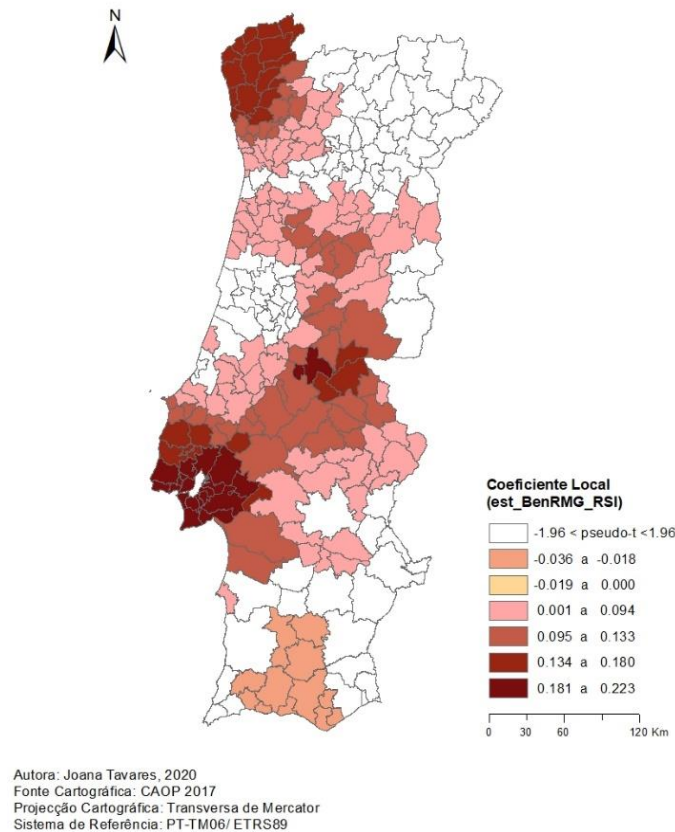


Figura 4.3.6 – Resultados do coeficiente local do preditor taxa de beneficiários do RMG e RSI no modelo 8 GWPR.

Quanto ao coeficiente da variável taxa de desempregados (*Desempds*) (Figura 4.3.7), este apresenta um valor menor (e sinal negativo) em grande parte da região de estudo, permitindo aferir que a variável não tem uma grande influência sobre os crimes. Este resultado não é esperado pela literatura, porém, é também possível identificar, ainda que escassas, algumas regiões pelo país, onde a relação desta variável é positiva. Destacam-se os municípios de Idanha-a-Nova, Santiago do Cacém e Mourão, onde o poder explicativo da variável é maior.

Observa-se no mapa dos coeficientes locais da variável *TxPopEstra* (Figura 4.3.8), que este mantém-se positivo por quase todo o país, sendo este resultado previsto pela maioria dos estudos. Note-se que alguns municípios de Viseu e os concelhos de Mealhada e Baião apresentam uma relação negativa com os crimes contra o património. Na região norte, o coeficiente é mais elevado e positivo e, em particular, verifica-se que a variável tem um maior poder explicativo sobre os crimes contra o património em Moimenta da Beira, Penedono e Tarouca. Portanto, constata-se a tendência de que quanto maior a proporção de população estrangeira nesta região, maior a ocorrência de fenómenos criminais (Vilalta & Fondevila, 2019). Já na restante área de estudo a influência da variável é menor.

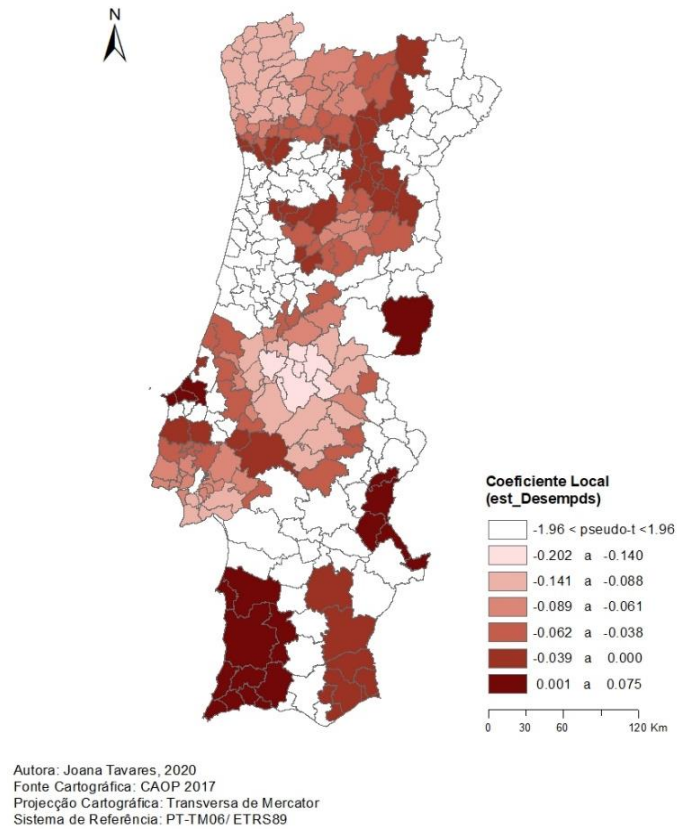


Figura 4.3.7 – Resultados do coeficiente local do predictor taxa de desempregados no modelo 8 GWPR.

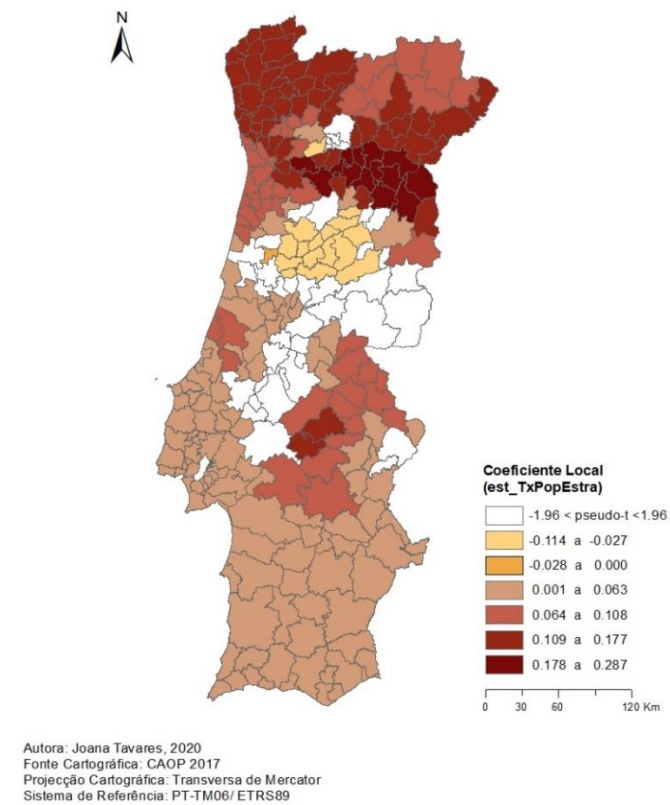


Figura 4.3.8 – Resultados do coeficiente local do predictor proporção de população estrangeira no modelo 8 GWPR.

A variável poder de compra *per capita* (*PodComp*) (Figura 4.3.9) apresenta coeficientes positivos em grande parte das unidades administrativas, isto é, quando o poder de compra é superior, o número de crimes também aumenta. Destacam-se as regiões de Viseu, Paredes e Paços de Ferreira. No entanto, a variável que representa o estatuto socioeconómico dos indivíduos possui uma relação negativa com os crimes no nordeste do país.

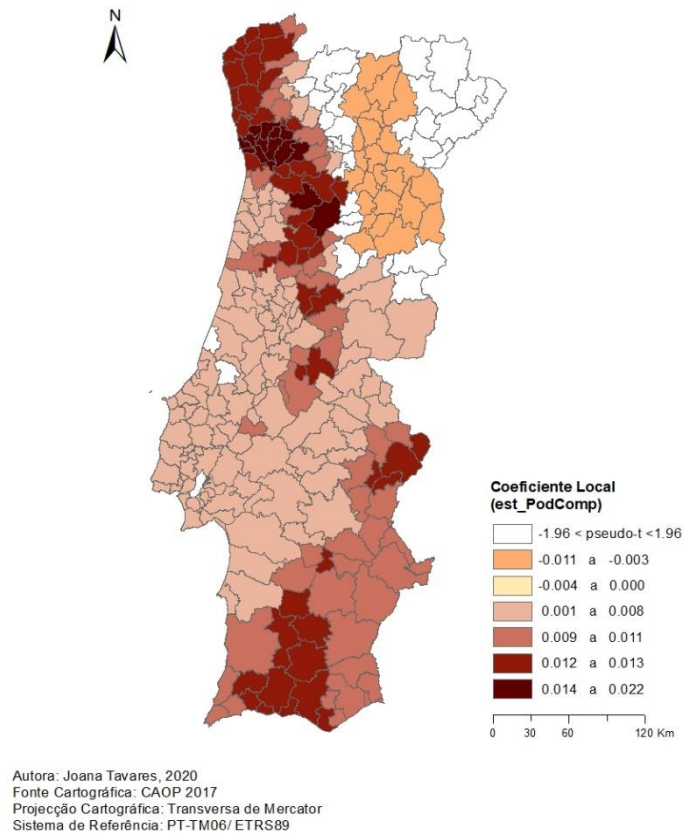


Figura 4.3.9 – Resultados do coeficiente local do poder de compra *per capita* no modelo 8 GWPR.

4.3.2. QUALIDADE DO AJUSTAMENTO LOCAL DO MODELO FINAL

A percentagem local da *deviance* explicada (em inglês, *local percent deviance explained*) é uma medida da qualidade de ajustamento local (*pseudo R² local*) e, portanto, evidencia os municípios onde o modelo tem maior poder explicativo. O mapa desta medida (Figura 4.3.10) permite confirmar que o poder explicativo do modelo varia ao longo do país e aferir que o modelo 8 (GWPR) explica melhor o número de crimes contra o património nos municípios na área metropolitana de Lisboa e do Porto. Por outro lado, nas unidades administrativas de Vila Pouca de Aguiar, Vila Real, Santa Marta de Penaguião, Fundão, Idanha-a-Nova, Castelo Branco, Vila Velha de Ródão, Marinha Grande, Alcobça, Nazaré, Porto de Mós, Batalha e Alcanena o poder explicativo do modelo revela ser menor.

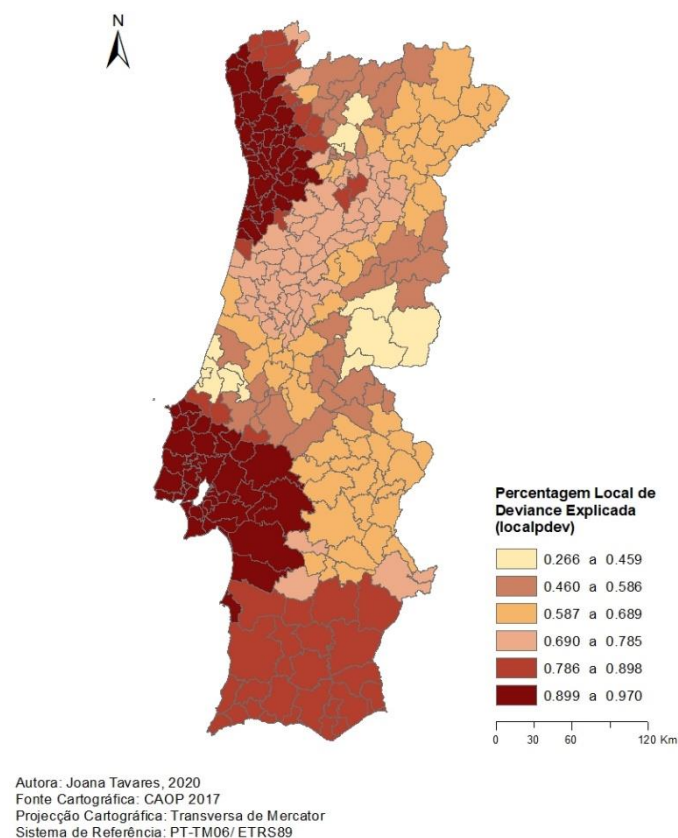


Figura 4.3.10 – Mapa da percentagem local de *deviance* explicada.

5. CONCLUSÃO

Os estudos acerca da criminalidade em Portugal ainda são bastante reduzidos, em particular, dada a dificuldade de acesso a informação sobre o fenómeno criminal por parte das entidades responsáveis pela segurança. Assim, a elaboração do presente trabalho de investigação sobre os crimes contra o património em Portugal Continental, por meio dos Sistemas de Informação Geográfica e análise espacial, representa uma abordagem inovadora e remete para a extrema importância do papel das ciências aplicadas à criminalidade.

A presente dissertação teve como finalidade investigar quais as variáveis socioeconómicas e demográficas que influenciam o número de crimes contra o património nos municípios portugueses, estudar a sua relação e como estas variam no espaço geográfico, e ainda, caracterizar a sua distribuição espacial, considerando dados de 278 unidades administrativas de Portugal Continental, em 2017.

Numa primeira fase, foi efetuada uma análise exploratória descritiva e espacial da taxa de crimes contra o património e das potenciais variáveis explicativas. Estudou-se também a relação entre as variáveis independentes e dependente, a fim de ter a perceção de quais as variáveis apresentam maior influência na ocorrência dos crimes. A análise espacial da taxa de crimes permitiu concluir que esta não se distribui uniformemente pelo país. Foi ainda possível concluir, através da análise de *hot spots*, que os incidentes criminais têm maior frequência nas regiões metropolitanas de Lisboa, do Porto e na região sul de Portugal.

Posteriormente, foram desenvolvidos modelos de regressão de Poisson, de modo a explorar quais os fatores que possuem um maior poder explicativo dos crimes contra o património. Todas as regressões em estudo apresentam na sua composição um fator *offset*, a população residente, de forma a tornar comparável o número de ocorrências criminais em cada um dos concelhos. De entre os modelos Poisson global, GWPR e S-GWPR testados, o modelo local GWPR, com oito variáveis independentes (Modelo 8 GWPR), foi o que apresentou uma melhor performance, especialmente nas áreas metropolitanas de Lisboa e Porto, reforçando a existência de não-estacionariedade evidenciada nos resultados da análise exploratória.

Os resultados do modelo final obtido revelam que as variáveis *Taxa de população jovem residente*, *Taxa de retenção e desistência no ensino básico*, *Número médio de alojamentos de familiares clássicos*, *Taxa de beneficiários do RMG e RSI*, *Proporção de população estrangeira* e *Poder de compra per capita* têm uma associação positiva com o número de crimes contra o património, na grande maioria dos municípios. Por outro lado, a *Taxa de desempregados* apresenta um impacto negativo em relação ao número de crimes, resultado não esperado pela teoria. A *Taxa bruta de escolarização* exibe uma associação negativa com a criminalidade em muitos municípios, mas, contrariamente ao expectável, revela uma associação positiva em diversas regiões (Viana do Castelo e Vila Real, bem como alguns concelhos de Bragança, Lisboa, Leiria, Sines, Santarém e Portalegre).

Note-se que os coeficientes com sinais não expectáveis podem não ser fiáveis, tendo em conta potenciais problemas identificados nos métodos GWR. Em particular os coeficientes podem estar correlacionados mesmo quando não há colinearidade entre as variáveis (Wheeler & Tiefelsdorf, 2005; Griffith, 2008).

Para cada uma das variáveis independentes são de destacar os seguintes resultados:

- A *Taxa de população jovem residente* apresenta maior poder explicativo nos municípios de Sintra, Cascais e Oeiras.
- A *Taxa de retenção e desistência no ensino básico* é um fator importante em Valença, Monção e Vila Nova de Cerveira.
- A *Taxa bruta de escolarização* apresenta uma relação negativa mais forte no Algarve, Beja, Porto e em alguns concelhos nos distritos de Viseu, Guarda e Castelo Branco.
- O *Número médio de alojamentos de familiares clássicos*, destaca-se na região do nordeste com coeficientes positivos mais elevados, em particular, nos concelhos de Penalva do Castelo, Aguiar da Beira e Fornos de Algodres.
- A *Taxa de beneficiários do RMG e RSI* é um fator mais relevante em Sesimbra, Seixal e Barreiro.
- A *Proporção de população estrangeira* apresenta uma relação positiva na maioria dos municípios, sendo mais expressiva em Moimenta da Beira, Penedono e Tarouca, enquanto alguns municípios de Viseu e os concelhos de Mealhada e Baião exibem coeficientes negativos.
- Para a variável *Poder de compra per capita*, destaca-se uma relação positiva mais forte com os crimes contra o património nas regiões de Viseu, Paredes e Paços de Ferreira.
- Os coeficientes da *Taxa de desempregados* têm o sinal esperado (positivo) apenas num número reduzido de concelhos, destacando-se Idanha-a-Nova, Santiago do Cacém e Mourão.

Face ao exposto, a análise e modelação local obtida permitiu explorar em detalhe e localmente o comportamento e a relação das variáveis explicativas identificadas com o fenómeno criminal em estudo. Comprovou-se assim a sua importância, uma vez que, a relação das variáveis explicativas e o número de crimes diferiu de região para região ao longo do país, ou seja, a resposta a determinado estímulo não é constante e varia no espaço.

O presente trabalho de investigação contribuiu para a identificação de variáveis socioeconómicas e demográficas que se encontram relacionadas com as ocorrências de incidências de crimes contra o património em Portugal. Este trabalho responde à escassez de estudos em que são aplicados métodos quantitativos, em particular de modelação espacial, na análise de crimes em Portugal. Os resultados evidenciam a complexidade do fenómeno, comprovando que o mesmo deve ser analisado com modelos espaciais locais.

5.1. LIMITAÇÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Futuramente, seria interessante proceder a um desenvolvimento da análise espacial aqui apresentada, ao longo dos anos 2018, 2019 e 2020, a fim de compreender se as relações identificadas variam ao longo do tempo, e estudar essa evolução. Outra extensão, consistiria em considerar outras variáveis com potencial valor explicativo, de modo a aumentar a *performance* do modelo em alguns municípios.

Uma alternativa possível ao modelo apresentado, consistiria na implementação de um modelo de Regressão Binomial Negativa, utilizado em diversos estudos da literatura, de forma a corrigir eventuais problemas de sobredispersão. Seria também relevante levar a cabo um estudo envolvendo um modelo econométrico espacial enquanto modelo preditivo, bem como proceder à utilização de metodologias de *Geospatial Data Mining* de modo a investigar padrões e relações espaciais.

REFERÊNCIAS

- Althausen, J. D., & Mieczkowski, T. M. (2001). The merging of criminology and geography into a course on spatial crime analysis. *Journal of Criminal Justice Education*, 12(2). <https://doi.org/10.1080/10511250100086181>
- Amaral, R. F. (2018). *Avaliação espacial como estratégia mitigacional preditiva: o crime de furto no interior de residências na divisão policial de Loures* [MSc Dissertation in Police Science, Instituto Superior de Ciências Policiais e Segurança Interna, Portugal]. <http://hdl.handle.net/10400.26/25023>
- Andresen, Martin. A. (2006). A spatial analysis of crime in Vancouver, British Columbia: A synthesis of social disorganization and routine activity theory. *Canadian Geographer/Le Géographe Canadien*, 50(4), 487–502. <https://doi.org/10.1111/j.1541-0064.2006.00159.x>
- Anselin, L. (1995). Local Indicators of Spatial Association-LISA. *Geographical Analysis*, 27(2), 93–115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L. (1999). The future of spatial analysis in the social sciences. *Geographic Information Sciences*, 5(2), 67–76. <https://doi.org/10.1080/10824009909480516>
- Anselin, L. (2010). Ordinary Least Squares and Poisson Regression Models. *CrimeStat Documentation*.
- Batella, B., Diniz, A., & Magno, A. (2010). *Análise Espacial dos Condicionantes da Criminalidade Violenta no Estado de Minas Gerais*. *Revista Sociedade & Natureza*, 22(1), 151–163. <http://www.seer.ufu.br/index.php/sociedadennatureza/article/view/9747>
- Bellander, T., Berglind, N., Gustavsson, P., Jonson, T., Nyberg, F., Pershagen, G., & Järup, L. (2001). Using geographic information systems to assess individual historical exposure to air pollution from traffic and house heating in stockholm. *Environmental Health Perspectives*, 109(6), 633–639. <https://doi.org/10.1289/ehp.01109633>
- Bernasco, W., & Elffers, H. (2010). Statistical Analysis of Spatial Crime Data. In *Handbook of Quantitative Criminology* (pp. 699–724). <https://doi.org/10.1007/978-0-387-77650-7>
- Brantingham, P., & Brantingham, P. (1995). Criminality of place. *European Journal on Criminal Policy and Research*, 3(3), 5–26. <https://doi.org/10.1007/bf02242925>
- Brunsdon, C., Fotheringham, A. S., & Charlton, M. E. (1996). Geographically Weighted Regression: A Method for Exploring Spatial Nonstationarity. *Geographical Analysis*, 28(4), 281–298. <https://doi.org/10.1111/j.1538-4632.1996.tb00936.x>
- Cahill, M. E., & Mulligan, G. F. (2003). The determinants of crime in Tucson, Arizona. *Urban Geography*, 24(7), 582–610. <https://doi.org/10.2747/0272-3638.24.7.582>
- Cahill, M. E., & Mulligan, G. F. (2007). Using geographically weighted regression to explore local crime patterns. *Social Science Computer Review*, 25(2), 174–193. <https://doi.org/10.1177/0894439307298925>
- Carcach, C., Graycar, A., & Muscat, G. (2001). The Victimization of Older Australians. In *Trends & issues in crime and criminal justice* (Vol. 212). Canberra: Australian Institute of Criminology. <https://www.aic.gov.au/publications/tandi/tandi212>
- Censos 2011 Resultados Definitivos - Portugal*. (2012).

- Chamlin, M. B., & Cochran, J. K. (1995). Assessing Messner and Rosenfeld's Institutional Anomie Theory: a Partial Test. *Criminology*, 33(3), 411–429. <https://doi.org/10.1111/j.1745-9125.1995.tb01184.x>
- Chen, J., Liu, L., Zhou, S., Xiao, L., Song, G., & Ren, F. (2017). Modeling spatial effect in residential burglary: A case study from ZG City, China. *ISPRS International Journal of Geo-Information*, 6(5). <https://doi.org/10.3390/ijgi6050138>
- Cohen, L. E., & Felson, M. (1979). Social Change and Crime Rate Trends: A Routine Activity Approach. *American Sociological Review*, 44(4), 608. <https://doi.org/10.2307/2094589>
- Cusson, M. (2007). *Criminologia* (C. das Letras (Ed.); 3ª Edição).
- Daoud, J. I. (2017). Multicollinearity and Regression Analysis. *Journal of Physics: Conference Series*, 949. <https://doi.org/10.1088/1742-6596/949/1/012009>
- Eck, J. E., Chainey, S., Cameron, J. G., Leitner, M., & Wilson, R. E. (2005). Mapping Crime: Understanding Hot Spots. In *National Institute of Justice*. <https://nij.ojp.gov/library/publications/mapping-crime-understanding-hot-spots>
- Ferreira, E. V. (1998). *Crime e insegurança em Portugal: padrões e tendências, 1985-1996* (1.ª edição). Celta Editora.
- Fischer, M. M., & Wang, J. (2011). *Spatial Data Analysis: Models, Methods and Techniques* (1st edition). Springer-Verlag Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-21720-3>
- Flint, C., Harrower, M., & Edsall, R. (2000). But How Does Place Matter? Using Bayesian Networks to Explore a Structural Definition of Place. *New Methodologies for the Social Sciences: The Development and Application of Spatial Analysis for Political Methodology*. https://nanopdf.com/download/but-how-does-place-matter-university-of-colorado-boulder_pdf
- Fotheringham, A. S., Brunson, C., & Charlton, M. (2002). *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships* (Wiley, Ed.). Chichester, UK.
- Fowles, R., & Merva, M. (1996). Wage Inequality and Criminal Activity: An Extreme Bounds Analysis for the United States, 1975–1990. *Criminology*, 34(2), 163–182. <https://doi.org/10.1111/j.1745-9125.1996.tb01201.x>
- Fuentes, C. M., & Jurado, V. (2019). Spatial pattern of motor vehicle thefts in Ciudad Juárez, Mexico: an analysis using geographically weighted Poisson regression. *Papers in Applied Geography*, 5(1–2), 176–191. <https://doi.org/10.1080/23754931.2019.1663755>
- Getis, A., & Ord, J. K. (1992). The Analysis of Spatial Association by Use of Distance Statistics. *Geographical Analysis*, 24(3), 189–206. <https://doi.org/10.1111/j.1538-4632.1992.tb00261.x>
- Glass, G. E., Schwartz, B. S., Morgan, J. M., Johnson, D. T., Noy, P. M., & Israel, E. (1995). Environmental risk factors for Lyme disease identified with geographic information systems. *American Journal of Public Health*, 85(7), 944–948. <https://doi.org/10.2105/AJPH.85.7.944>
- Goodchild, M. F. (1988). Geographic information systems. *Progress in Human Geography*, 12(4). <https://doi.org/10.1177/030913258801200407>
- Graça Frias. (2003). A Construção Social Do Sentimento De Insegurança Em Portugal Na Atualidade. *SociNova – Gabinete de Investigação Em Sociologia Aplicada*, 1–14.

- Griffith, D. A. (2008). Spatial-filtering-based contributions to a critique of geographically weighted regression (GWR). *Environment and Planning A: Economy and Space*, 40(11), 2751–2769. <https://doi.org/10.1068/a38218>
- Grooves, B., & Sampson, R. (1989). Community Structure and Crime: Testing the Social Disorganisation Theory. *The American Journal of Sociology*, 94(4), 774–802. <http://dx.doi.org/10.1086/229068>
- Harries, K. D. (1974). *The Geography of Crime and Justice*. McGraw-Hill Inc., US.
- Hayward, K. J. (2012). Five spaces of cultural criminology. *British Journal of Criminology*, 52(3), 441–462. <https://doi.org/10.1093/bjc/azs008>
- Heitgerd, J., & Bursik, R. (1987). Extracommunity Dynamics and the Ecology of Delinquency. In *American Journal of Sociology* (Vol. 92, Issue 4). <https://www.jstor.org/stable/2780038>
- Lee, S., Kang, D., & Kim, M. (2009). Determinants of Crime Incidence in Korea: A Mixed GWR Approach. *World Conference of the Spatial Econometrics Association, July*, 8–10.
- Li, X., & Juhola, M. (2014). Country crime analysis using the self-organizing map, with special regard to demographic factors. *AI & Society*, 29(1), 53–68. <https://doi.org/10.1007/s00146-013-0441-7>
- Lisboa, M., & Lourenço, N. (1999). *Dez Anos de Crime em Portugal: Análise Longitudinal da Criminalidade Participada às Polícias (1984 - 1993)* [Gabinete de Estudos Jurídico-Sociais do Centro de Estudos Judiciários, Lisboa]. <http://hdl.handle.net/10884/389>
- Lobo, J. C., & Fernandez, L. F. (2003). A criminalidade na região metropolitana de Salvador. *XXXI Encontro Nacional de Economia Da ANPEC*. <https://econpapers.repec.org/paper/anpen2003/d26.htm>
- Longley, P., Goodchild, M., Maguire, D., & Rhind, D. (2005). *Geographic Information Systems and Science* (Second Edition). John Wiley & Sons, Ltd.
- Lourenço, N., & Lisboa, M. (1996). Violência, Criminalidade e Sentimento de Insegurança. *Revista Textos*, 2, 45–64. <https://repositorio-cientifico.uatlantica.pt/handle/10884/338>
- Macedo, A. (2016). *Para uma discussão dos determinantes da criminalidade em Portugal* [MSc Dissertation in Economy, Universidade do Minho, Portugal]. <http://hdl.handle.net/1822/42141>
- Morenoff, Jeffrey D.; Sampson, Robert J.; Raudenbush, S. W. (2001). Neighborhood Inequality, Collective Efficacy, and the Spatial Dynamics of Urban Violence. *Criminology*, 39(3), 517–558. <https://doi.org/10.1111/j.1745-9125.2001.tb00932.x>
- Murray, A. T., McGuffog, I., Western, J. S., & Mullins, P. (2001). Exploratory spatial data analysis techniques for examining urban crime. *The British Journal of Criminology*, 41(2), 309–329. <https://doi.org/10.1093/bjc/41.2.309>
- Nakaya, T, Fotheringham, A. S., Charlton, M., & Brunson, C. (2009). Semiparametric geographically weighted generalised linear modelling in GWR 4.0. *10th International Conference on GeoComputation*. Sydney, Australia.
- Nakaya, Tomoki, Charlton, M., Brunson, C., Lewis, P., Yao, J., & Fotheringham, A. S. (2016). GWR4.09 User Manual. In *Windows Application for Geographically Weighted Regression Modelling*.
- Nakaya, Tomoki, Fotheringham, A. S., Brunson, C., & Charlton, M. (2005). Geographically weighted Poisson regression for disease association mapping. *Statistics in Medicine*, 24(17), 2695–2717. <https://doi.org/10.1002/sim.2129>

- Nakaya, Tomoki, & Yano, K. (2010). Visualising Crime Clusters in a Space-time Cube: An Exploratory Data-analysis Approach Using Space-time Kernel Density Estimation and Scan Statistics. *Transactions in GIS*, 14(3), 223-239. <https://doi.org/10.1111/j.1467-9671.2010.01194.x>
- Nezami, S., & Khoramshahi, E. (2016). Spatial Modeling of Crime by Using of GWR Method. *Proceedings - 2016 Baltic Geodetic Congress (Geomatics), BGC Geomatics 2016*, 222-227. <https://doi.org/10.1109/BGC.Geomatics.2016.47>
- O'Brien, L. (1992). *Introducing Quantitative Geography Measurement, Methods and Generalised Linear Models* (1st Edition). <https://doi.org/10.4324/9780203973356>
- O'Brien, R. M. (2007). A caution regarding rules of thumb for variance inflation factors. *Quality and Quantity*, 41(5), 673-690. <https://doi.org/10.1007/s11135-006-9018-6>
- Oliveira, R. (2012). *A GNR na prevenção dos crimes contra o património* [Academia Militar]. <http://hdl.handle.net/10400.26/8559>
- Osgood, D. W. (2000). Poisson-based regression analysis of aggregate crime rates. *Journal of Quantitative Criminology*, 16(1), 21-43. <https://doi.org/10.1023/A:1007521427059>
- Quick, M., Li, G., & Brunton-Smith, I. (2018). Crime-general and crime-specific spatial patterns: A multivariate spatial analysis of four crime types at the small-area scale. *Journal of Criminal Justice*, 58, 22-32. <https://doi.org/10.1016/j.jcrimjus.2018.06.003>
- Rajcic, S. T. (2015). *Spatial analysis of crime evolution in portugal between 1995 and 2013* [MSc Dissertation in Geospatial Technologies, NOVA Information Management School, Portugal]. <http://hdl.handle.net/10362/14546>
- RASI. (2018). Relatório Anual de Segurança Interna. In *Relatório Anual de Segurança Interna – Ano*.
- Ribeiro, S., Cabral, P., Henriques, R., Bravo, J., Rodrigues, T., & Painho, M. (2018). Modelação do crescimento urbano para a distribuição eficaz das forças de segurança. In *PROELIUM – Revista da Academia Militar* (Vol. 7, Issue 14, pp. 45-68).
- Rodriguez-Morales, A. J., Haque, U., Ball, J. D., García-Loaiza, C. J., Galindo-Marquez, M. L., Sabogal-Roman, J. A., Marin-Loaiza, S., Ayala, A. F., Lozada-Riascos, C. O., Diaz-Quijano, F. A., & Alvarado-Socarras, J. L. (2017). Spatial distribution of Zika virus infection in Northeastern Colombia. *Infezioni in Medicina*, 25(3), 241-246. <https://doi.org/10.2471/blt.16.176529>
- Rybarczyk, G., Maguffee, A., & Kruger, D. (2015). Linking Public Health, Social Capital, and Environmental Stress to Crime Using a Spatially Dependent Model. *Cityscape: A Journal of Policy Development and Research*, 17(1), 17-33.
- Santos, M. A. F. (2016). Abordagens Científicas Sobre As Causas Da Criminalidade Violenta : Uma Análise Da Teoria da Ecologia Humana. *Revista Do Laboratório de Estudos Da Violência Da UNESP*, 17, 46-74. <https://doi.org/10.36311/1983-2192.2016.v0n17.5972>
- Sass, K. S., Porsse, A. A., & Silva, E. R. (2016). Determinantes das Taxas de Crimes no Paraná: Uma Abordagem Espacial. *Revista Brasileira de Estudos Regionais e Urbanos*, 10(1), 44-63. <http://dx.doi.org/10.5380/re.v41i75.68314>
- Seabra, H. M. de, & Santos, T. (2005). *A criminalidade de estrangeiros em Portugal: Um inquérito científico* (1 Edição).
- Shaw, C. R., & McKay, H. D. (1942). *Juvenile Delinquency and Urban Areas: A Study of Rates of*

Delinquents in Relation to Differential Characteristics of Local Communities in American Cities. University of Chicago Press.

- Tobler, A. W. R. (1970). A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geograph*, 46, 234–240. <https://doi.org/10.2307/143141>
- Vilalta, C. J. (2013). How Exactly Does Place Matter in Crime Analysis? Place, Space, and Spatial Heterogeneity. *Journal of Criminal Justice Education*, 24(3), 290–315. <https://doi.org/10.1080/10511253.2012.715659>
- Vilalta, C. J., & Fondevila, G. (2019). Modeling Crime in an Uptown Neighborhood: The Case of Santa Fe in Mexico City. *Papers in Applied Geography*, 5(1–2), 1–12. <https://doi.org/10.1080/23754931.2018.1554502>
- Vilalta, C. J., Sanchez, T. W., Fondevila, G., & Ramirez, M. (2018). A descriptive model of the relationship between police CCTV systems and crime. Evidence from Mexico City. *Police Practice and Research*, 20(2), 105–121. <https://doi.org/10.1080/15614263.2018.1473770>
- Vilalta, C., & Muggah, R. (2016). What explains criminal violence in Mexico City? A test of two theories of crime. *Stability*, 5(1), 1–22. <http://doi.org/10.5334/sta.433>
- Vilalta, C. J., Castillo, J. G., & Torres, J. A. (2016). Violent Crime in Latin American Cities. In *Inter-American Development Bank*. <https://doi.org/10.18235/0000428>
- Wang, L., Lee, G., & Williams, I. (2019). The spatial and social patterning of property and violent crime in Toronto neighbourhoods: A spatial-quantitative approach. *ISPRS International Journal of Geo-Information*, 8(1), 51. <https://doi.org/10.3390/ijgi8010051>
- Wang, D., Ding, W., Lo, H., Morabito, M., Chen, P., Salazar, J., & Stepinski, T. (2013). Understanding the spatial distribution of crime based on its related variables using geospatial discriminative patterns. *Computers, Environment and Urban Systems*, 39, 93–106. <https://doi.org/10.1016/j.compenvurbsys.2013.01.008>
- Zhang, H., & Peterson, M. (2007). A spatial analysis of neighborhood crime in Omaha, Nebraska using alternative measures of crime rates. *Internet Journal of Criminology*, 31, 1–31.

ANEXO




Figura A 1: Crimes de Roubo na União Europeia no ano 2016.

Densidade populacional nos municípios de Portugal Continental em 2017

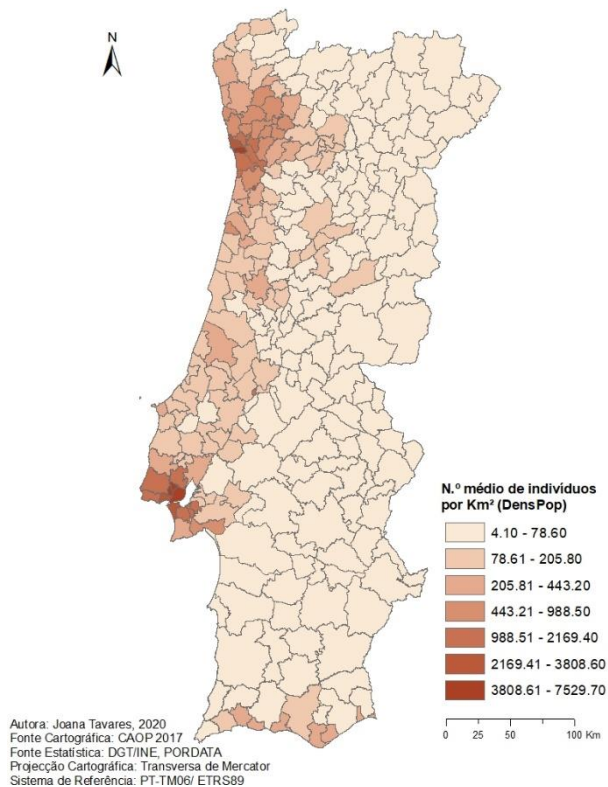


Figura A 2: Distribuição espacial da variável *DensPop* nos municípios de Portugal Continental, em 2017.

Taxa bruta de escolarização nos municípios de Portugal Continental em 2017

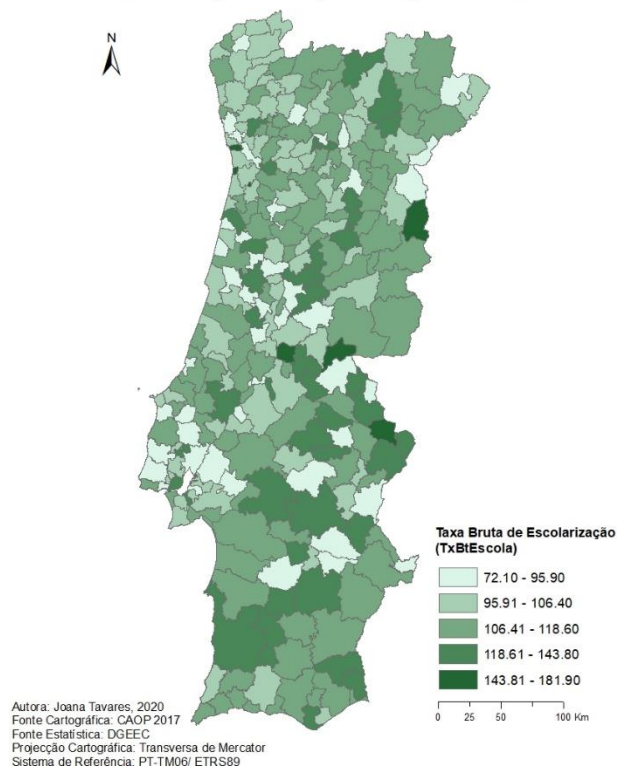


Figura A 3: Distribuição espacial da variável *TxBtEscola* nos municípios de Portugal Continental, em 2017.

Taxa de retenção e desistência nos municípios de Portugal Continental em 2017

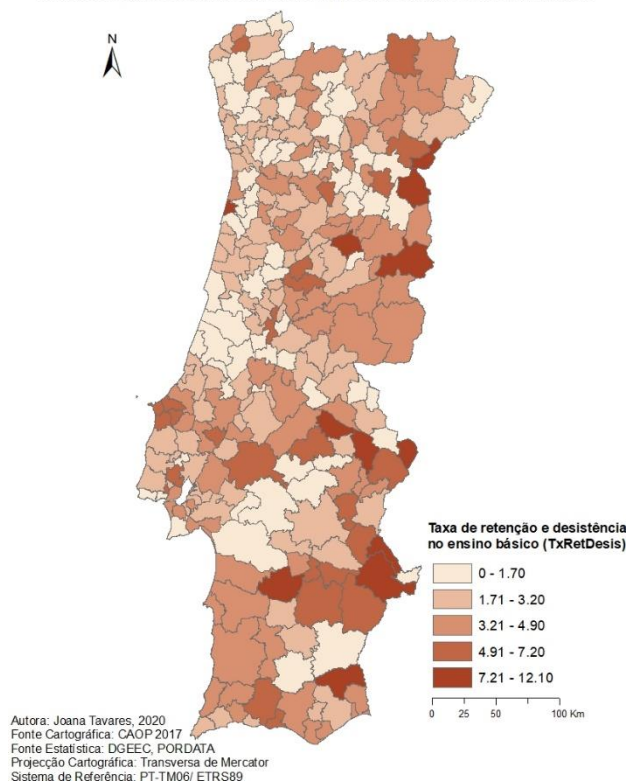


Figura A 4: Distribuição espacial da variável *TxRetDesis* nos municípios de Portugal Continental, em 2017.

Taxa de população jovem residente nos municípios de Portugal Continental em 2017

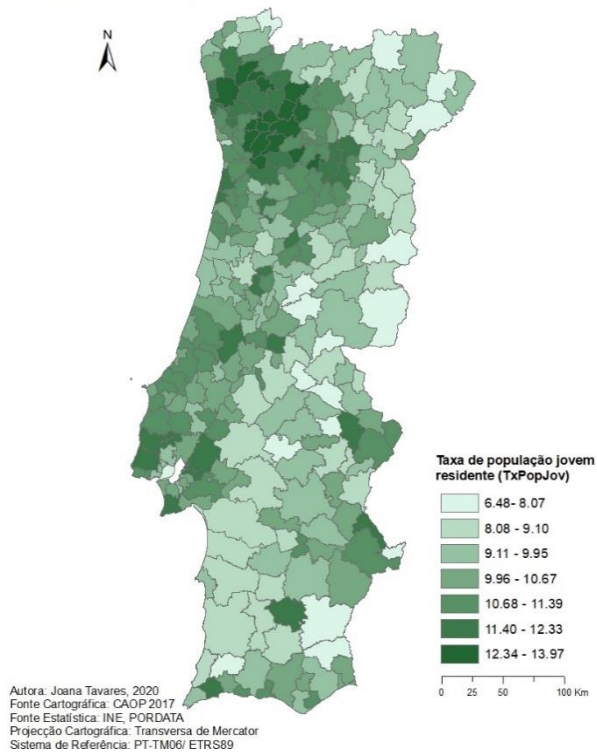


Figura A 5: Distribuição espacial da variável *TxPopJov* nos municípios de Portugal Continental, em 2017.

Taxa de beneficiários do RMG e RSI nos municípios de Portugal Continental em 2017

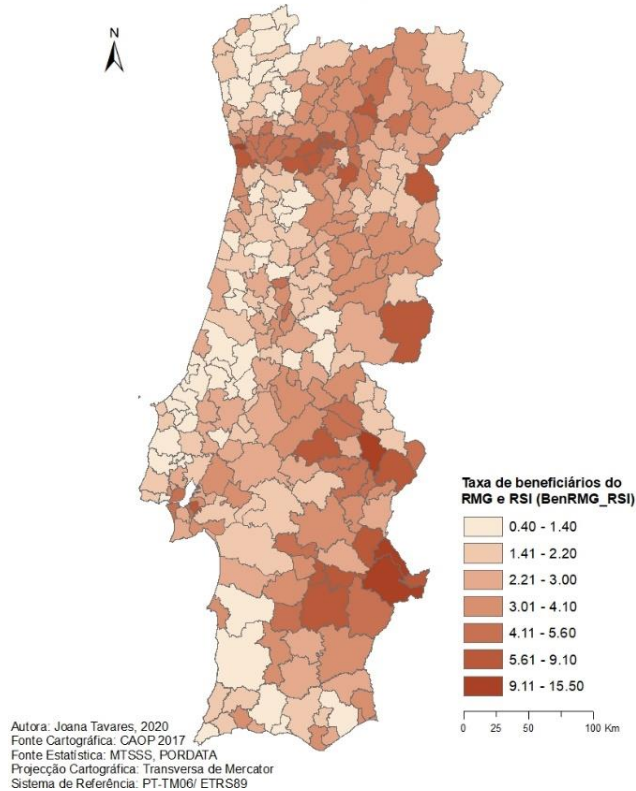


Figura A 6: Distribuição espacial da variável *BemRMG_RSI* nos municípios de Portugal Continental, em 2017.

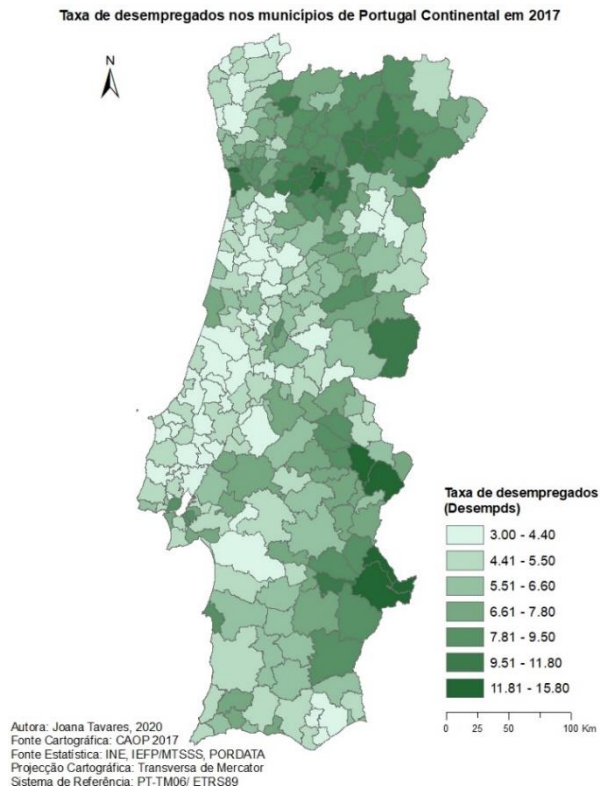


Figura A 7: Distribuição espacial da variável *Desempds* nos municípios de Portugal Continental, em 2017.

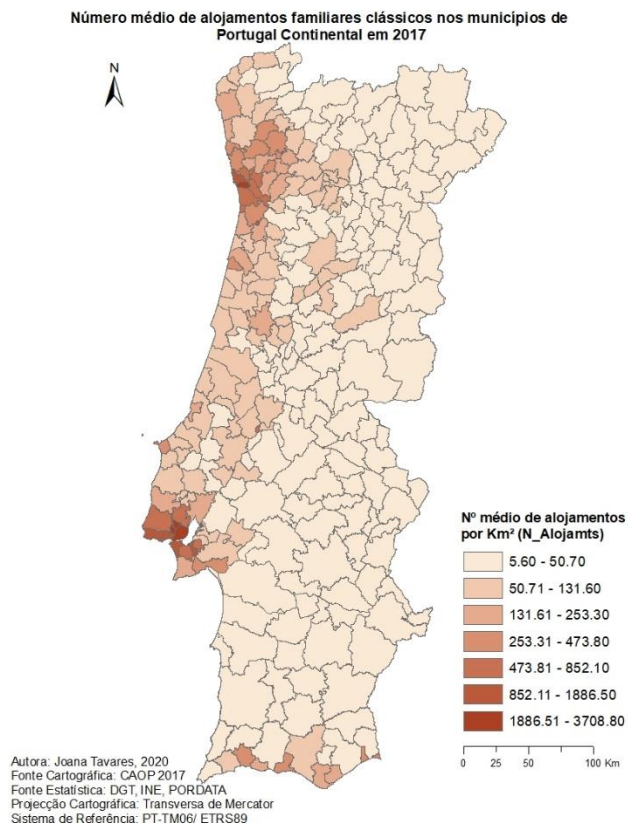


Figura A 8: Distribuição espacial da variável *N_Alojamts* nos municípios de Portugal Continental, em 2017.

Proporção de população estrangeira nos municípios de Portugal Continental em 2017

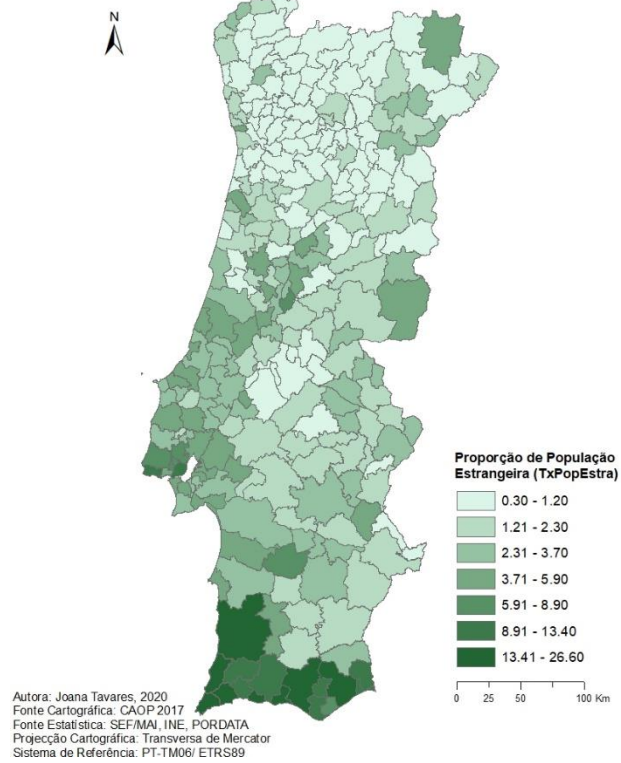


Figura A 9: Distribuição espacial da variável *TxPopEstra* nos municípios de Portugal Continental, em 2017.

Poder de compra per capita nos municípios de Portugal Continental em 2017

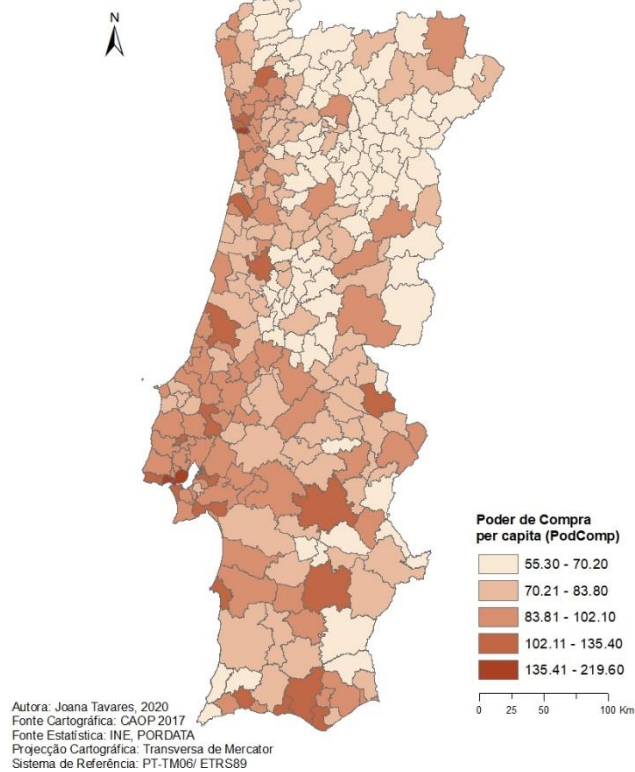


Figura A 10: Distribuição espacial da variável *PodComp* nos municípios de Portugal Continental, em 2017.

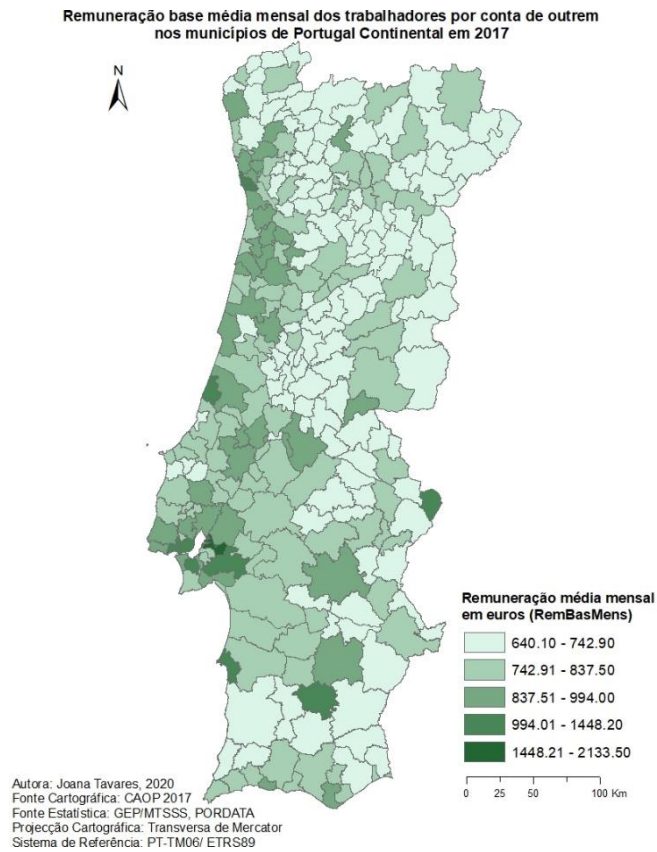


Figura A 11: Distribuição espacial da variável *RemBasMens* nos municípios de Portugal Continental, em 2017.

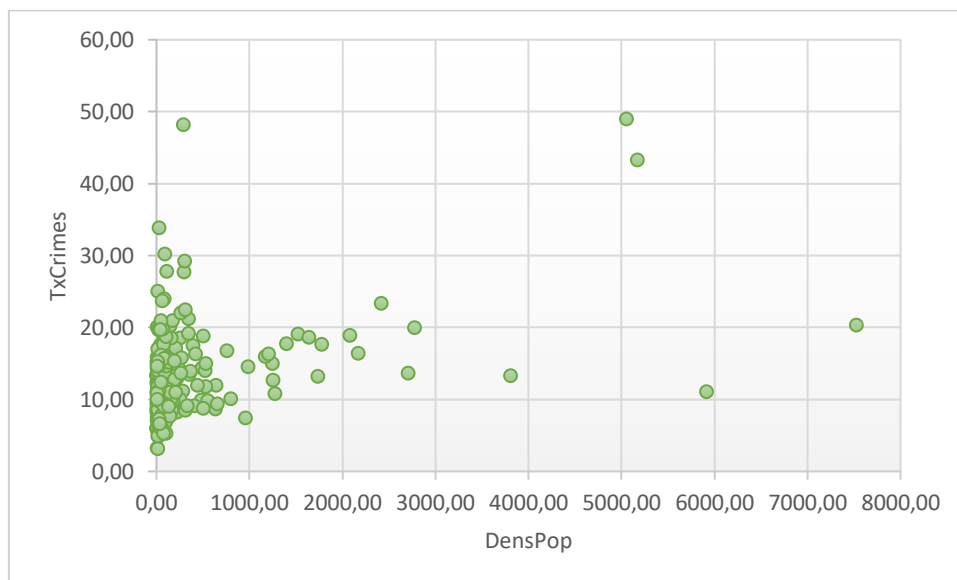


Figura A 12: Gráfico de dispersão entre a taxa de crime contra o património e a densidade populacional.

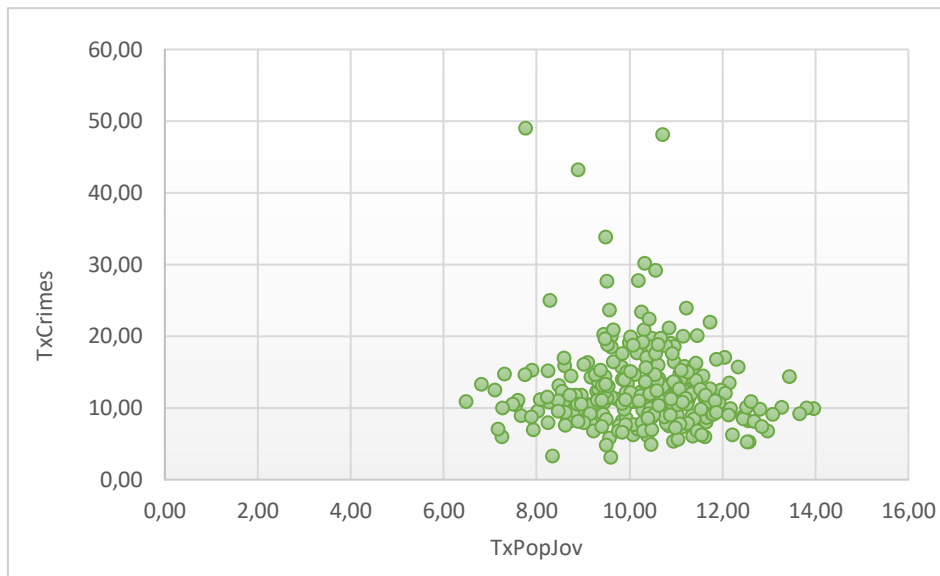


Figura A 13: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de população jovem residente.

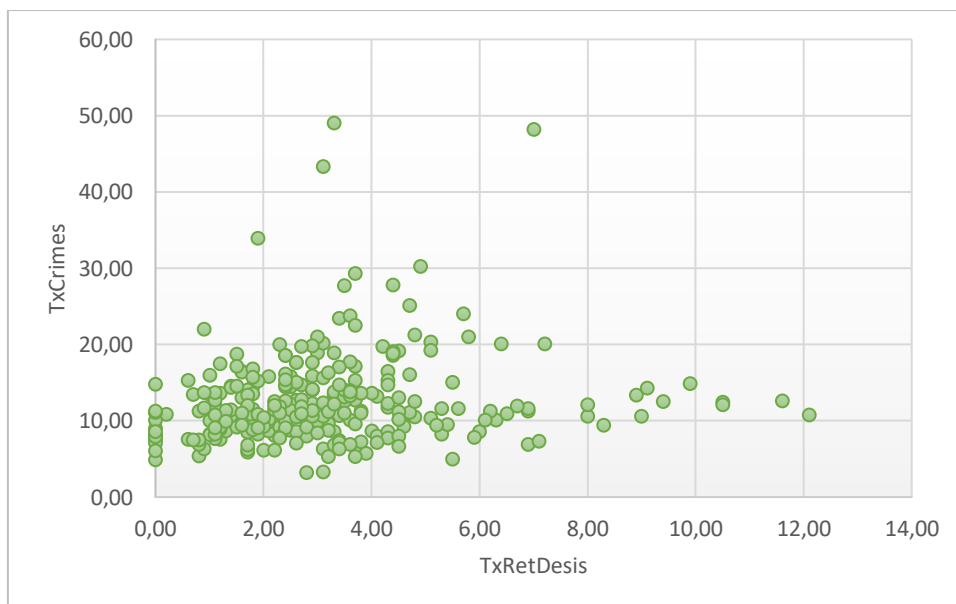


Figura A 14: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de retenção e desistência no ensino básico.

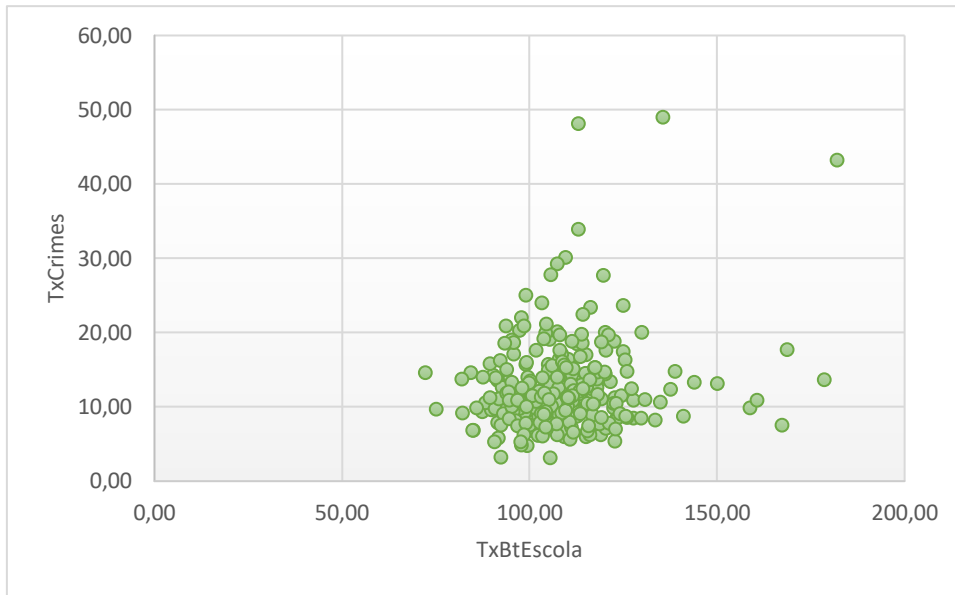


Figura A 15: Gráfico de dispersão entre a taxa de crime contra o património e a taxa bruta de escolarização.

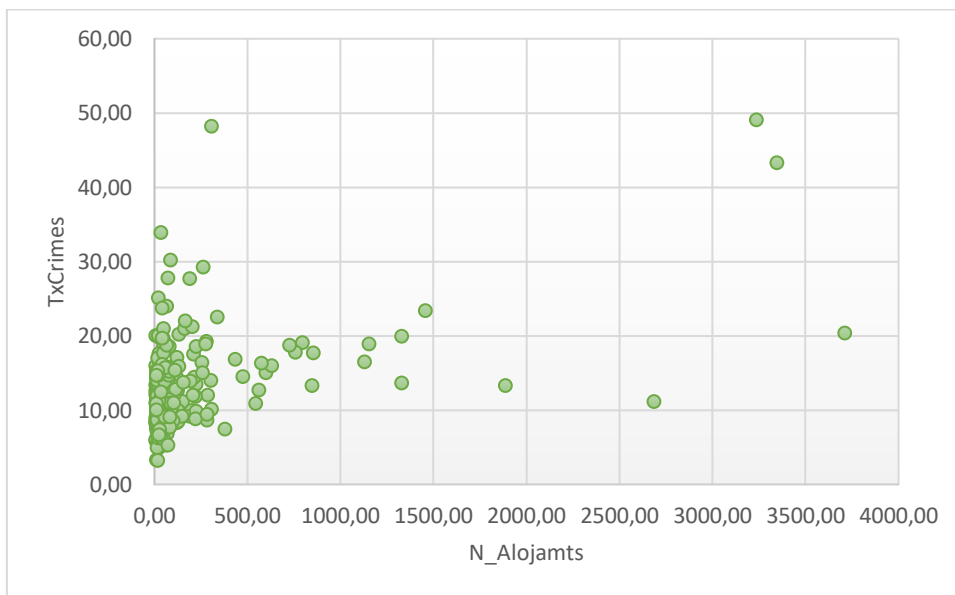


Figura A 16: Gráfico de dispersão entre a taxa de crime contra o património e o nº médio de alojamentos de familiares clássicos.




Figura A 17: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de beneficiários do RMG e RSI.




Figura A 18: Gráfico de dispersão entre a taxa de crime contra o património e a taxa de desempregados.

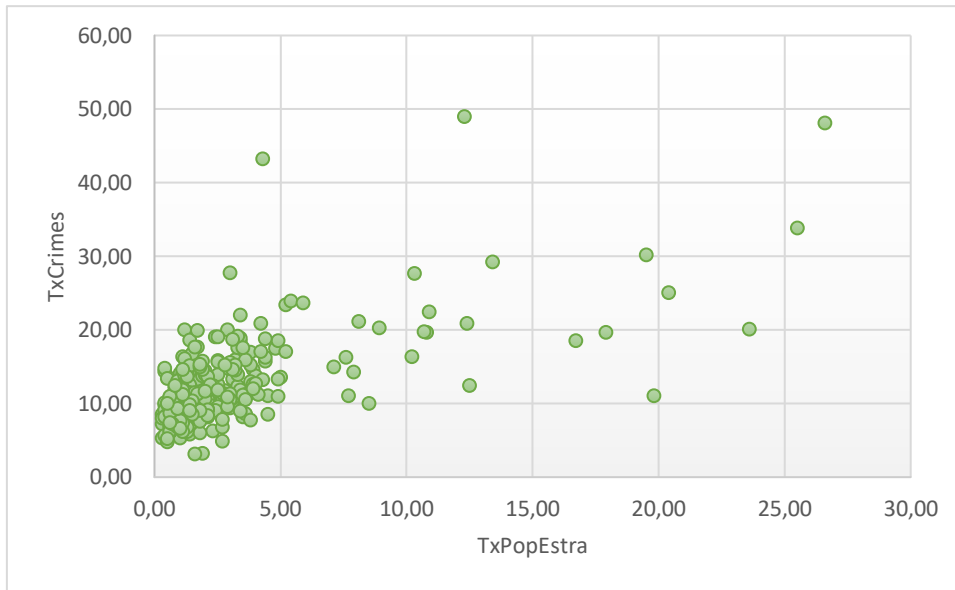


Figura A 19: Gráfico de dispersão entre a taxa de crime contra o património e a proporção de população estrangeira.

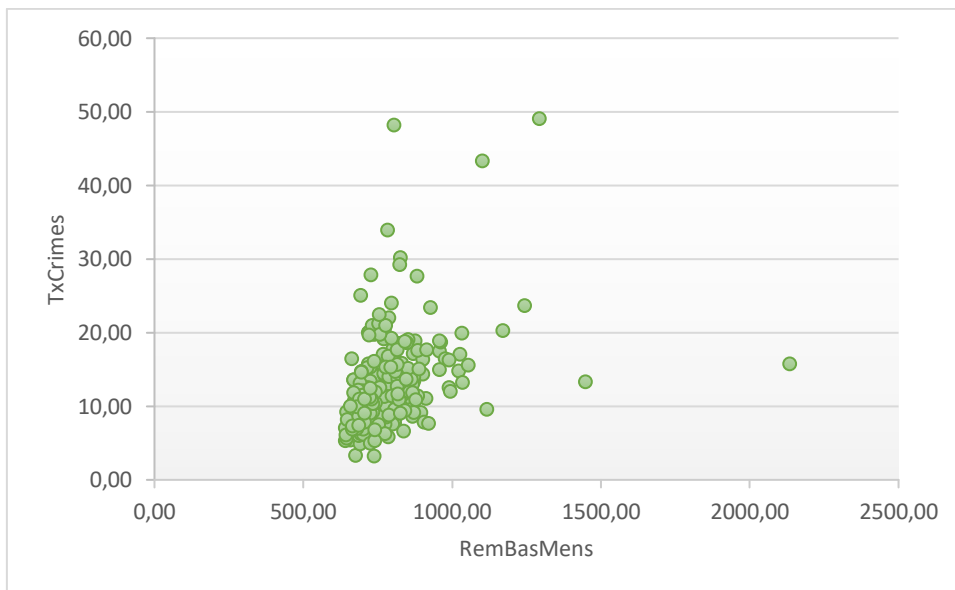


Figura A 20: Gráfico de dispersão entre a taxa de crime contra o património e a remuneração base média mensal.




Figura A 21: Gráfico de dispersão entre a taxa de crime contra o património e o poder de compra per capita.

