



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

ARTHUR PIMENTEL GOMES DE SOUZA

**EFEITOS DA PANDEMIA DE COVID-19 SOBRE A OCORRÊNCIA DE ROUBOS:  
um modelo de decisão espacial**

Recife  
2022

ARTHUR PIMENTEL GOMES DE SOUZA

**EFEITOS DA PANDEMIA DE COVID-19 SOBRE A OCORRÊNCIA DE ROUBOS:  
um modelo de decisão espacial**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de mestre em Engenharia de Produção.

**Área de concentração:** Pesquisa Operacional.

Orientadora: Profa. Dra. Caroline Maria de Miranda Mota.

Recife

2022

Catalogação na fonte:  
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

S729e Souza, Arthur Pimentel Gomes de.  
Efeitos da pandemia de covid-19 sobre a ocorrência de roubos: um  
modelo de decisão espacial / Arthur Pimentel Gomes de Souza. – 2022.  
194 f.: il., figs., quads., abrev. e siglas.

Orientadora: Profa. Dra. Caroline Maria de Miranda Mota.  
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.  
Programa de Pós-Graduação em Engenharia da Produção. Recife, 2022.  
Inclui referências e apêndice.

1. Engenharia de produção. 2. Decisão multicritério. 3. Análise  
estatística. 4. Análise espacial. 5. GIS-MCDA. 6. COVID-19. 7.  
Segurança pública. I. Mota, Caroline Maria de Miranda (Orientadora). II.  
Título.

UFPE

658.5 CDD (22. ed.)

BCTG/2022-297

ARTHUR PIMENTEL GOMES DE SOUZA

**EFEITOS DA PANDEMIA DE COVID-19 SOBRE A OCORRÊNCIA DE ROUBOS:  
um modelo de decisão espacial**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção. Área de Concentração: Pesquisa Operacional.

Aprovada em: 18 / 03 / 2022.

**BANCA EXAMINADORA**

---

Profa. Dra. Caroline Maria de Miranda Mota (Orientadora)  
Universidade Federal de Pernambuco

---

Prof. Dr. Cristiano Alexandre Virgílio Cavalcante (Examinador Interno)  
Universidade Federal de Pernambuco

---

Prof. Dr. Silvio Hamacher (Examinador Externo)  
Pontifícia Universidade Católica

Dedico este trabalho aos meus pais, Rosange e Beto, e à minha avó Dora, por me incentivarem a continuar acreditando na educação como meio de transformar vidas.

## AGRADECIMENTOS

A Deus, por ter me concedido saúde, sabedoria e a benção de trabalhar nesse projeto por tanto tempo, além de ter sido a minha fortaleza para enfrentar os desafios ao longo do caminho.

À minha falecida Tia Sula, por desde cedo ter me mostrado o que é de verdade neste mundo e ter me apoiado com sábios e amorosos conselhos. Este trabalho também é uma conquista sua.

Aos meus amigos, por serem tão compreensivos nos meus momentos de ausência ou de tribulação e por tornarem partes desse processo árduo em momentos leves e felizes.

À minha orientadora Caroline Mota, por todo o apoio, a confiança e a paciência depositados em mim desde quando não entendia sequer o significado de pesquisa científica. Sou grato por todos os valorosos conselhos e ensinamentos, que certamente levarei comigo.

Aos colegas do laboratório PMD, que estiveram comigo em boa parte da minha jornada acadêmica. Solícitos, sempre estiveram disponíveis para me ensinarem coisas novas e aliviarem as pressões do dia-a-dia.

À equipe de docentes do PPGEP, pela humildade em compartilhar não só conhecimento acadêmico, como também experiências enriquecedoras durante as aulas e os contatos mais informais.

À UFPE, por ter sido a minha segunda morada a partir da graduação, com uma boa infraestrutura e um ambiente social diversificado que contribuíram para eu evoluir enquanto acadêmico e principalmente cidadão.

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco, pelo apoio financeiro para o desenvolvimento deste trabalho.

## RESUMO

O programa de combate ao crime em Pernambuco teve resultados oscilantes nos últimos anos. Ademais, a pandemia de COVID-19 afetou a criminalidade devido às restrições para o fluxo de pessoas nas ruas. Neste contexto, o presente estudo busca construir um modelo decisório multicritério para investigar a vulnerabilidade a roubos de uma região da cidade do Recife. A fim de apoiar o decisor na elucidação de preferências, combinou-se técnicas estatísticas e espaciais para explorar a propagação espacial da COVID-19 e a ocorrência de roubos. Em um primeiro instante, explorou-se a situação epidemiológica da doença em Recife frente às restrições governamentais. Então restringiu-se o estudo ao estágio inicial da pandemia (abril a julho de 2020) ao nível de bairros. Inicialmente examinou-se a evolução dos clusters de casos e da taxa de letalidade em dez datas específicas. Logo depois, uma análise de regressão evidenciou a associação dos serviços essenciais e das características socioeconômicas com os casos de COVID-19. Em um segundo instante, o estudo de roubos se limitou aos bairros de Boa Viagem e Pina. Investigou-se, então, a evolução dos clusters de roubos antes e durante a pandemia. Seguiu-se por uma exploração estatística e visual de 37 indicadores censitários e instalações comerciais, visando ressaltar preditores de roubos em cinco meses de estágios distintos da pandemia. Por fim, construiu-se um modelo multicritério para classificar os setores censitários quanto à vulnerabilidade a roubos. A doença se difundiu de áreas mais para menos desenvolvidas, sob influência da idade, renda e escolaridade da população. Houve uma queda acentuada nos roubos no início da pandemia, mas eles gradualmente cresceram rumo a patamares pré-pandêmicos com o relaxamento das restrições; embora os padrões espaciais fossem diferentes. Os tipos de cluster se distinguiram pela densidade populacional e faixas etárias. A evolução espacial da doença e a dos roubos seguiram padrões distintos. O modelo multicritério captou as áreas de maior e de menor concentração de roubos ao longo do tempo. Com esses resultados, almeja-se apoiar decisões estratégicas acerca do avanço da COVID-19 e das ações contra roubos, propiciando melhor qualidade de vida para a população.

**Palavras-chave:** decisão multicritério; análise estatística; análise espacial; GIS-MCDA; COVID-19; segurança pública.

## ABSTRACT

Pernambuco's crime-fighting program has had mixed results in recent years. In addition, the COVID-19 pandemic affected criminal activities due to restrictions on the flow of people on the streets. In this context, the present study aims to build a multicriteria decision-making model to investigate the vulnerability to robbery in a region of the city of Recife. In order to support the decision maker to elucidate his preferences, statistical and spatial techniques were combined to explore the spatial spread of COVID-19 and the occurrence of robberies. In a first step, the epidemiological situation of the disease in Recife was explored in the face of government restrictions. So, the study was restricted to the initial stage of the pandemic (April to July 2020) at the neighborhood level. Initially, the evolution of case clusters and case fatality rate clusters on ten specific dates was examined. Subsequently, a regression analysis revealed how essential services and socioeconomic characteristics were able to explain COVID-19 cases. In a second stage, the study of robberies was limited to the neighborhoods of Boa Viagem and Pina. Then the evolution of robbery clusters was investigated before and during the pandemic. This was followed by a statistical and visual exploration of 37 census indicators and commercial facilities, aiming to highlight predictors of robbery in five months concerning different stages of the pandemic. Finally, a multicriteria model was built to classify the census tracts in Boa Viagem and Pina in terms of vulnerability to robbery. The disease spread from more to less developed areas, under the influence of age, income and education of the population. There was a sharp drop in robberies at the beginning of the pandemic. Then, the gradual relaxation of restrictions led to the growth of these indices towards pre-pandemic levels, but with different spatial patterns. Cluster types were distinguished by population density and age groups. The spatial evolution of the disease and that of robberies followed different patterns. The multicriteria model captured the areas with the highest and lowest concentration of robberies over time. Based on these results, this study seeks to support strategic decisions about the advance of COVID-19 and the fight against robbery, which contributes to improve the population's quality of life.

**Keywords:** multicriteria decision aiding; statistical analysis; spatial analysis; GIS-MCDA; COVID-19; public security.

## LISTA DE FIGURAS

Figura 1 - Formas de contiguidade espacial .....	25
Figura 2 - Fluxo lógico da metodologia .....	61
Figura 3 - Área de estudo .....	62
Figura 4 - Evolução da curva de casos de COVID-19 entre março e julho de 2020	77
Figura 5 - Registro diário dos casos e óbitos por COVID-19 em Recife .....	78
Figura 6 - Acumulado mensal dos casos e óbitos por COVID-19 em Recife .....	79
Figura 7 - <i>Clusters</i> espaciais dos casos reportados de COVID-19 nos bairros de Recife .....	82
Figura 8 - <i>Clusters</i> espaciais da taxa de letalidade por COVID-19 nos bairros de Recife .....	83
Figura 9 - Desempenho do $R^2$ local nos bairros de Recife .....	88
Figura 10 - Desempenho dos coeficientes do modelo GWR nos bairros de Recife ..	89
Figura 11 - Acumulado mensal de roubos em Boa Viagem e Pina nos anos de 2018 a 2021 .....	94
Figura 12 - <i>Clusters</i> espaciais de roubos durante os meses de 2019 .....	98
Figura 13 - <i>Clusters</i> espaciais de roubos durante os meses de 2020 .....	103
Figura 14 - <i>Clusters</i> espaciais de roubos durante os meses de 2021 .....	106
Figura 15 - <i>Clusters</i> espaciais de roubos durante as estações dos anos de 2019, 2020 e 2021 .....	109
Figura 16 - <i>Clusters</i> espaciais de roubos durante os dias da semana no ano de 2019 .....	111
Figura 17 - <i>Clusters</i> espaciais de roubos durante os dias da semana na pandemia .....	112
Figura 18 - <i>Clusters</i> espaciais de roubos durante os períodos do dia em 2019 e na pandemia .....	115
Figura 19 - Distribuição espacial dos quintis dos fatores demográficos e socioeconômicos .....	126
Figura 20 - Densidade espacial das instalações comerciais .....	127
Figura 21 - Matriz de correlação dos fatores demográficos e socioeconômicos ....	130
Figura 22 - Matriz de correlação das instalações comerciais .....	133
Figura 23 - Desempenho do $R^2$ local com base em indicadores censitários .....	142
Figura 24 - Desempenho do $R^2$ local com base em instalações comerciais .....	144

Figura 25 - Construção dos fatores conforme os métodos de fatoração .....	150
Figura 26 - Critérios representativos dos estabelecimentos comerciais .....	153
Figura 27 - Resumo dos critérios .....	153
Figura 28 - Classificação multicritério da vulnerabilidade a roubos .....	157

## LISTA DE QUADROS

Quadro 1 - Tipos de preditores explorados na modelagem estatística da COVID-19 .....	45
Quadro 2 - Modelos preditivos para crimes contra o patrimônio .....	52
Quadro 3 - Estatística descritiva dos indicadores censitários nos bairros do Recife .....	65
Quadro 4 - Descrição dos serviços essenciais na cidade do Recife .....	66
Quadro 5 - Estatística descritiva dos indicadores censitários nos bairros de Boa Viagem e Pina .....	69
Quadro 6 - Descrição das instalações comerciais nos bairros de Boa Viagem e Pina .....	71
Quadro 7 - Modelos de regressão OLS com determinantes combinados em grupo único .....	87
Quadro 8 - Tipos de roubos em Boa Viagem e Pina no ano de 2019 e durante a pandemia .....	96
Quadro 9 - Correlação espacial entre os indicadores censitários e os roubos em Boa Viagem e Pina .....	137
Quadro 10 - Correlação espacial entre as instalações comerciais e os roubos em Boa Viagem e Pina .....	139
Quadro 11 - Regressão <i>stepwise</i> para indicadores censitários .....	141
Quadro 12 - Regressão <i>stepwise</i> para instalações comerciais .....	143
Quadro 13 - Pesos para o método WLC .....	152
Quadro 14 - Pesos do modelo multicritério .....	154
Quadro 15 - Parâmetros do ELECTRE-TRI-nC .....	155
Quadro 16 - Frequência de alocações às categorias .....	156

## LISTA DE ABREVIATURAS E SIGLAS

AIC	<i>Akaike Information Criterion</i>
CVLI	Crime Violento Letal Intencional
CVP	Crime Violento contra o Patrimônio
DRSA	<i>Dominance-based Rough Set Approach</i>
ELECTRE	<i>Elimination and Choice Expressing Reality</i>
EUA	Estados Unidos da América
GIS	<i>Geographic Information System</i>
GWR	<i>Geographically Weighted Regression</i>
HH	<i>High-High</i>
HL	<i>High-Low</i>
LH	<i>Low-High</i>
LL	<i>Low-Low</i>
MAUT	<i>Multi-Attribute Utility Theory</i>
MAVT	<i>Multi-Attribute Value Theory</i>
MCDA	<i>Multiple Criteria Decision Making</i>
MSA	<i>Measures Sampling Adequacy</i>
MV	Medida governamental
OLS	<i>Ordinary Least Squares</i>
OMS	Organização Mundial de Saúde
PIB	Produto Interno Bruto
PPV	Programa Pacto pela Vida
PROMETHEE	<i>Preference Ranking Organization Method for Enrichment of Evaluations</i>
SDS	Secretaria de Defesa Social
WLC	<i>Weighted Linear Combination</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>15</b>
1.1	Justificativa e Relevância .....	17
1.2	Objetivos .....	20
<b>1.2.1</b>	<b>Objetivo geral .....</b>	<b>20</b>
<b>1.2.2</b>	<b>Objetivos específicos .....</b>	<b>20</b>
1.3	Estrutura do trabalho .....	21
<b>2</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>22</b>
2.1	Fundamentos em criminologia .....	22
2.2	Análise espacial .....	25
<b>2.2.1</b>	<b>Autocorrelação espacial .....</b>	<b>25</b>
2.2.1.1	<i>Global Moran's I</i> .....	26
2.2.1.2	<i>Global Moran's I bivariado</i> .....	27
2.2.1.3	<i>Local Moran's I</i> .....	28
<b>2.2.2</b>	<b>Geographically Weighted Regression .....</b>	<b>29</b>
2.3	Apoio a Decisão Multicritério .....	32
<b>2.3.1</b>	<b>Conceitos básicos.....</b>	<b>32</b>
<b>2.3.2</b>	<b>Tomada de decisão espacial .....</b>	<b>35</b>
2.3.2.1	<i>Sistema de Informação Geográfica (GIS)</i> .....	35
2.3.2.2	<i>GIS-MCDA</i> .....	36
<b>2.3.3</b>	<b>Weighted Linear Combination.....</b>	<b>37</b>
<b>2.3.4</b>	<b>ELECTRE-TRI-nC.....</b>	<b>38</b>
<b>3</b>	<b>REVISÃO DE LITERATURA .....</b>	<b>43</b>
3.1	Estudos estatísticos-espaciais sobre COVID-19 .....	43
3.2	Modelos matemáticos sobre a ocorrência de crimes .....	47
<b>3.2.1</b>	<b>Modelagem estatística e espacial no contexto criminal.....</b>	<b>47</b>
<b>3.2.2</b>	<b>Estudos criminais durante a pandemia .....</b>	<b>51</b>
<b>3.2.3</b>	<b>Abordagem MCDA e GIS-MCDA no contexto criminal .....</b>	<b>57</b>
3.3	Considerações do capítulo .....	58
<b>4</b>	<b>METODOLOGIA.....</b>	<b>60</b>
4.1	Área de estudo .....	62
4.2	Análise estatística-espacial da COVID-19 .....	64
4.3	Análise estatística-espacial-multicritério dos roubos.....	68

4.3.1	Evolução espaço-temporal dos <i>clusters</i> de roubos .....	68
4.3.2	Análise estatística-espacial dos fatores preditivos de roubos .....	70
4.3.3	Análise multicritério de áreas vulneráveis a roubos .....	73
5	<b>ANÁLISE DA PANDEMIA DE COVID-19 EM RECIFE.....</b>	76
5.1	Estudo epidemiológico .....	76
5.2	Análise de <i>clusters</i> espaciais .....	81
5.3	Análise de regressão.....	85
5.4	Discussão .....	89
6	<b>ROUBOS EM BOA VIAGEM E PINA: ANÁLISE DE CLUSTERS.....</b>	94
6.1	Análise descritiva do acumulado de roubos .....	94
6.2	Estudo dos <i>clusters</i> espaciais por meses .....	96
6.2.1	<b><i>Clusters</i> espaciais mensais em 2019.....</b>	97
6.2.2	<b><i>Clusters</i> espaciais mensais em 2020.....</b>	102
6.2.3	<b><i>Clusters</i> espaciais mensais em 2021.....</b>	105
6.3	Estudo dos <i>clusters</i> espaciais por estações do ano .....	108
6.4	Estudo dos <i>clusters</i> espaciais por dias da semana .....	110
6.5	Estudo dos <i>clusters</i> espaciais por períodos do dia .....	114
6.6	Discussão .....	116
6.6.1	<b>Acumulados mensais .....</b>	116
6.6.2	<b><i>Clusters</i> espaciais.....</b>	117
7	<b>ROUBOS EM BOA VIAGEM E PINA: ANÁLISE ESTATÍSTICA E GIS-MCDA .....</b>	123
7.1	Análise estatística-espacial dos fatores preditivos de roubos .....	123
7.1.1	<b>Estatística descritiva das variáveis explanatórias.....</b>	123
7.1.1.1	<i>Análise de quintis .....</i>	123
7.1.1.2	<i>Análise de correlação não-espacial.....</i>	129
7.1.2	<b>Associação entre roubos e variáveis explanatórias.....</b>	135
7.2	Análise multicritério de áreas vulneráveis a roubos .....	145
7.2.1	<b>Construção dos critérios .....</b>	145
7.2.1.1	<i>Aspectos demográficos e socioeconómicos .....</i>	145
7.2.1.2	<i>Fluxo comercial e de pessoas .....</i>	148
7.2.2	<b>Aplicação do modelo multicritério .....</b>	154
7.3	Discussão .....	157
8	<b>CONCLUSÃO.....</b>	163

8.1	Considerações finais .....	163
8.2	Limitações e Estudos futuros .....	166
	<b>REFERÊNCIAS .....</b>	<b>169</b>
	<b>APÊNDICE A – ANÁLISE FATORIAL.....</b>	<b>192</b>

## 1 INTRODUÇÃO

O Brasil é um dos países mais inseguros do mundo em termos de proteção e segurança social, conflitos internos e externos e grau de militarização. Isso é comprovado pelo Índice Global da Paz publicado em 2021, com base no qual o país ocupa apenas a 99<sup>a</sup> posição de uma lista com 163 países – atrás de vizinhos latinos como Peru, Argentina, Paraguai, Chile e Uruguai (GPI, 2021). Os números reverberam percepções da própria sociedade brasileira, que recorrentemente critica e debate sobre a atuação do Estado na área de segurança pública.

Os entes federativos (a nível federal, estadual e municipal) devem atuar na redução da atividade criminal, conforme especificado na Constituição brasileira (BRASIL, 1988). Responsáveis pelo gerenciamento das polícias civil e militar, os governos estaduais despesceram 80,8% do orçamento de segurança pública no país no ano de 2020 (ASP, 2021). Logo, é natural que sejam fortemente cobrados por desempenho. Nas últimas décadas, os estados desenvolveram iniciativas regionais de combate à violência, como as Unidades de Polícia Pacificadora (2008) no Rio de Janeiro (CANO; RIBEIRO, 2016) e o programa Fica Vivo (2002) em Minas Gerais (ALVES; ARIAS, 2012).

Em Pernambuco, no ano de 2007 foi implementado o programa Pacto pela Vida (PPV). Com a missão central de reduzir os homicídios, o PPV conseguiu reverter uma das maiores taxas desses crimes no Brasil para um período de forte queda entre 2007 e 2013. Por meio da integração da informação, treinamento de policiais e repressão qualificada, o estado conseguiu ser o único do Nordeste brasileiro a apresentar redução na criminalidade neste período, embora possua semelhanças regionais históricas com os estados vizinhos (HOELSCHER, 2017).

Após anos de sucesso absoluto, houve uma tendência oscilatória no desempenho do PPV. Entre os anos de 2014 e 2017 houve um aumento vertiginoso nos índices criminais ao ponto de retomar patamares anteriores ao programa, devido a dificuldades de governança no cenário político estadual (RATTON; DAUDELIN, 2018). Segundo os dados divulgados pela Secretaria de Defesa Social (SDS, 2021), contudo, nota-se uma tendência descendente nas taxas de crimes violentos e patrimoniais a partir do ano de 2018. Todavia, os recentes esforços contra as ocorrências criminais ainda não geraram o retorno esperado, pois há evidências de

que Pernambuco figura entre os estados mais perigosos do país (em assassinatos e na média ponderada de todos os tipos de crime) (PRADO; COLAÇO JÚNIOR, 2020).

Em locais como o Recife (capital de Pernambuco), onde não há forte controle territorial por criminosos (WOLFF, 2017), a violência segue uma lógica análoga à de uma doença infecciosa: como um “surto”, há padrões discerníveis de clusterização, disseminação e transmissão (HADDON JR, 1968; SLUTKIN, 2013). Deste modo, o sistema criminal da cidade é caracterizado por iniciativas altamente difusas e sobrepostas, mas que são territorialmente fluidas – com o PPV atuando na identificação e tratamento de “surtos” (WOLFF, 2017).

Nos últimos meses de 2019, a rotina das pessoas ao redor do mundo passou a ser fortemente impactada pelo surgimento de um novo vírus, o SARS-CoV2. Ele é o agente etiológico da doença vascular COVID-19, a qual perturba múltiplos sistemas do corpo humano (ROBERTS et al., 2020; SIDDIQI; LIBBY; RIDKER, 2021). A alta transmissibilidade do vírus tem representado uma ameaça aos sistemas de saúde (SINGHAL, 2020), o que incitou a Organização Mundial de Saúde a registrar a conjuntura como pandemia em março de 2020 (OMS, 2020).

Medidas não-farmacológicas foram adotadas para mitigar a propagação do vírus (ADHIKARI et al., 2020). Assim, restrições de circulação nas ruas (como *lockdowns*) foram impostas em mais de 90 países, o que propiciou interrupções significativas na rotina das pessoas e, com isso, alterou as condições ambientais sob as quais os diferentes tipos de crime ocorrem (CECCATO et al., 2021). Nivette et al. (2021) concluíram que as taxas criminais diminuíram em 37% ao redor do mundo após as ordens de permanência em casa, porém, enquanto os crimes contra a propriedade diminuíram substancialmente, os homicídios permaneceram quase inalterados. O impacto das medidas restritivas sobre os crimes dependia do rigor e da localização onde eram implementadas, sendo que a diminuição delas propiciou o gradual aumento dos crimes até os níveis pré-pandemia (NIVETTE et al., 2021).

A criminalidade em Pernambuco seguiu um padrão semelhante no ano de 2020, primeiro impactado pela pandemia (março a dezembro). De acordo com o Anuário de Segurança Pública (ASP, 2021), houve uma redução de todos os crimes patrimoniais a nível nacional (- 25,3%), enquanto Pernambuco atingiu um índice abaixo dessa média (- 33,9%). Discriminando por tipos desses crimes no estado, destacam-se as quedas nos roubos a transeunte (- 35,1%) e a estabelecimento comercial (- 35,7%). Os pesquisadores atribuem esse padrão dos crimes

patrimoniais à redução da circulação das pessoas. Por outro lado, as mortes violentas intencionais (cuja maioria são homicídios) tiveram um aumento significativo a nível nacional (4%) e em Pernambuco (7,2%). Segundo analistas, esse cenário pode decorrer indiretamente da piora das condições econômicas, do crescimento do desemprego e da piora da saúde mental da população (ASP, 2021).

### 1.1 Justificativa e Relevância

A sociedade brasileira tem vivenciado uma crise disseminada e persistente em termos políticos, sociais e econômicos, a qual foi agravada pela eclosão da pandemia de COVID-19. Nesse contexto, o papel do Estado no combate à criminalidade é um tema habitualmente debatido, tendo em vista a sensação persistente de insegurança das pessoas. A Constituição assegura que as esferas governamentais devem proteger a população, porém a escassez de recursos técnicos e financeiros impede que intervenções produzam um impacto igualitário sobre todas as localidades.

Nesse sentido, o poder público necessita compreender como a criminalidade se comporta nos diferentes lugares, de modo que aqueles onde a periculosidade se mostre mais latente possam receber uma atenção prioritária na prevenção e repressão a delitos. Consequentemente, a concepção de políticas públicas que considerem a carência diversificada pela atuação do Estado contribui para estender a abrangência espacial das melhorias, o que tende a refletir numa redução significativa dos eventos criminais.

Parte da estratégia de segurança pública em Pernambuco é compreendida há cerca de 15 anos pelo programa Pacto pela Vida (PPV). Ele se mostrou eficiente durante um longo período, mas tem demonstrado oscilações evidentes acerca dos efeitos nas taxas criminais, antes mesmo da pandemia. Do ponto de vista financeiro, o aporte de recursos per capita para a segurança pública em Pernambuco tem reduzido levemente desde 2018, tornando-se o sexto estado com menor gasto em 2020 (ASP, 2021). Embora o importante seja a efetividade na aplicação dos recursos, isto serve de indicativo para a situação atual do estado. Ademais, a estrutura metodológica do PPV não é divulgada.

Nesse contexto, entende-se a necessidade de elaborar políticas públicas que complementem o PPV. Há margem para a construção de um processo de tomada de

decisão formal, transparente, sistemático e replicável em outros entes federativos. Logo, coopera-se para disseminar conhecimentos acerca de mensurar o nível de vulnerabilidade local a crimes e, então, direcionar medidas de intervenção cabíveis.

A princípio, o padrão de ocorrência dos eventos criminais deve ser compreendido. Eles tendem a se concentrar em um número reduzido de locais dentro de uma região de estudo, porém os padrões espaciais variam consideravelmente de acordo com o tipo de crime (ANDRESEN; CURMAN; LINNING, 2016). Logo, entender onde os *clusters* espaciais destes eventos (no presente estudo, roubos) são formados e as características do ambiente que atraem a atenção dos criminosos auxilia na definição de abordagens de enfrentamento.

Em um cenário de pandemia de COVID-19, é relevante identificar como a doença se espalhou pela região de estudo numa perspectiva espaço-temporal. Deste modo, consegue-se investigar possíveis conexões entre os perfis socioeconômico, demográfico e de circulação de pessoas notados nas áreas que são mais suscetíveis à doença e nas que são mais aos roubos. Embora estudos tenham sido conduzidos para o estado de Pernambuco como um todo (QUININO et al. 2021; FIGUEIREDO et al., 2022), a capital, Recife, requer análises mais aprofundadas. Isto se deve à alta vulnerabilidade da cidade à COVID-19 em diferentes estágios da pandemia (FIGUEIREDO et al., 2022) e à concentração do maior número de casos e óbitos pela doença no estado até o presente momento (janeiro de 2022) (SEPLAG, 2022).

A criminalidade em Pernambuco já tinha sido investigada recentemente em termos de crimes contra a pessoa (PEREIRA; ANDRESEN; MOTA, 2016; PEREIRA; MOTA; ANDRESEN, 2017a, 2017b; SILVA et al., 2020; MOTA; FIGUEIREDO; PEREIRA, 2021) e contra o patrimônio (FIGUEIREDO; MOTA, 2016; ROSA et al., 2019; SOUZA et al., 2020a). Contudo, a pandemia afetou a dinâmica espaço-temporal destes eventos devido à severidade variável das restrições de circulação, à situação econômica preocupante (que tem reduzido o poder de compra) e à lenta recuperação do setor de serviços (o que mais impacta no PIB brasileiro) (MENDES, 2021). Ademais, mesmo com as flexibilizações do Estado, o retorno das pessoas aos serviços presenciais também foi afetado pelo crescimento do *e-commerce* (CRUZ, 2021) e pela disseminação do trabalho em *home office* (MARTINS; GÓES; NASCIMENTO, 2021). Assim, presume-se que houve alterações no volume de pessoas circulando em vias públicas e no valor agregado que carregam consigo, o

que impacta os alvos em potencial para roubos e, consequentemente, a atratividade de áreas à prática criminal.

Por conseguinte, necessita-se explorar as mudanças nos padrões espaciais da criminalidade e no conjunto de fatores explicativos de roubos ao longo das diferentes fases da pandemia. O emprego de ferramentas estatísticas e espaciais se sobressaem para este fim. Todavia, estes modelos possuem um caráter predominantemente explicativo e preditivo. Para o suporte a decisão acerca de alternativas de ação (neste caso, a identificação de áreas mais vulneráveis), a modelagem multicritério mostra-se mais apropriada.

A elaboração de um modelo multicritério propicia avaliar um conjunto amplo de fatores qualitativos e quantitativos que descrevem as partições espaciais da região de interesse, o que fornece sustentação mais consistente do que apenas dados históricos criminais. A análise multicritério viabiliza ampliar a perspectiva além de testes estatísticos acerca de variações na quantidade de roubos, ou apenas da concentração espacial destes. Em um contexto criminal, pode-se obter resultados baseados na avaliação de preferências de um decisor acerca de características socioeconômicas e aspectos ambientais que tornam os locais mais atrativos aos criminosos. O decisor agrega conhecimentos sobre a dinâmica criminológica local ao modelo matemático, o que contribui para a assertividade dos resultados.

A construção de um modelo multicritério requer a escolha e definição de parâmetros. Entretanto, um processo mal estruturado pode fazer com que a subjetividade do decisor afete a qualidade dos resultados. Em um cenário com elementos explicitamente espaciais isto se agrava, visto que a própria disposição e interação deles na região pode interferir no estudo da propensão a crimes. Deste modo, as análises estatísticas e espaciais previamente discutidas cooperam fortemente nas etapas de modelagem multicritério, enriquecendo o modelo com a representação da realidade local. Além disso, contribui-se para o entendimento do decisor acerca do problema, propiciando julgamentos melhor embasados e maior crença na credibilidade das recomendações finais.

O presente estudo almeja identificar, por meio de discussões sinérgicas de ordem estatística, espacial e multicritério, as áreas mais vulneráveis a roubos em uma região da cidade do Recife, Pernambuco. Com os resultados do modelo decisório, espera-se apoiar os órgãos dedicados à Segurança pública na definição estratégica de prioridades de locais de atuação em caráter preventivo e repressivo.

Assim, tende-se a reduzir os índices criminais e a elevar a sensação de segurança da população na região mesmo em uma conjuntura de excepcionalidade decorrente da pandemia.

## 1.2 Objetivos

De acordo com o contexto apresentado, definiu-se um conjunto de objetivos para o presente trabalho.

### 1.2.1 Objetivo geral

O presente estudo busca investigar a propensão à ocorrência de roubos na cidade do Recife, especialmente sob o impacto da pandemia de COVID-19, por meio de modelos matemáticos de caráter estatístico, espacial e multicritério.

### 1.2.2 Objetivos específicos

- Identificar padrões espaciais na evolução dos *clusters* de casos notificados e taxa de letalidade por COVID-19 ao longo da pandemia em Recife;
- Especificar conjuntos significativos de fatores demográficos e socioeconômicos e de serviços essenciais que influenciaram a difusão dos casos de COVID-19 em Recife durante diferentes fases da pandemia, considerando as medidas restritivas vigentes;
- Comparar a concentração espacial dos roubos em Boa Viagem e Pina antes e durante a pandemia em termos de localização e características socioeconômicas;
- Relacionar as diferentes fases da pandemia com o impacto de fatores demográficos e socioeconômicos e de estabelecimentos comerciais sobre a ocorrência de roubos em Boa Viagem e Pina;
- Construir critérios de avaliação da vulnerabilidade a roubos que sejam capazes de representar o contexto local quanto à atratividade a criminosos;
- Classificar divisões espaciais dos bairros de Boa Viagem e Pina em relação à vulnerabilidade a roubos.

### 1.3 Estrutura do trabalho

A dissertação está estruturada em oito capítulos. O primeiro capítulo contextualiza os temas de interesse do estudo e apresenta a justificativa para realizá-lo, assim como os objetivos gerais e específicos. O segundo capítulo comprehende os principais conceitos teóricos abordados. O terceiro capítulo apresenta publicações recentes sobre COVID-19 e criminalidade. O quarto capítulo descreve a metodologia empregada em termos de suas principais etapas. O quinto capítulo desenvolve a análise sobre a pandemia de COVID-19 na cidade do Recife. O sexto capítulo investiga a concentração espacial de roubos nos bairros de Boa Viagem e Pina, ao passo que o sétimo capítulo aborda a mesma área quanto à vulnerabilidade a roubos, porém sob a ótica de técnicas estatísticas e multicritério. Por fim, o oitavo capítulo apresenta as conclusões, limitações e sugestões para trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

Neste capítulo os principais conceitos utilizados no trabalho são descritos. O conteúdo encontra-se dividido em cinco seções: Fundamentos em criminologia, Análise espacial e Apoio a decisão multicritério. A primeira parte contém definições clássicas sobre crimes e fatores condicionantes que influenciam sua ocorrência. A segunda aborda as principais estatísticas espaciais empregadas. A terceira apresenta os conceitos gerais acerca da modelagem multicritério em contexto espacial, assim como detalhes sobre os métodos *Weighted Linear Combination* e *ELECTRE-TRI-nC*.

### 2.1 Fundamentos em criminologia

A ocorrência de crimes é explicada com enfoque multidisciplinar, envolvendo áreas como Psicologia, Biologia e Geografia. A Criminologia aborda o crime como um fenômeno social, a qual inclui de forma sequencial e interativa a criação de leis, a violação das leis e a reação à violação delas (SUTHERLAND, 1939). Esta área de pesquisa serve para embasar estratégias de prevenção, intervenção, aprisionamento e reabilitação, o que contribui para alcançar a justiça criminal e gerar políticas sociais (MILLER, 2009).

Os estudos criminais compreendem as dimensões legal, do criminoso, da vítima e do local. A primeira foca na criação e interpretação de leis, enquanto a segunda discerne a motivação do delinquente e como isto pode variar com o tempo. A dimensão da vítima busca compreender o motivo de pessoas ou locais serem vitimados e, por fim, a dimensão do local é voltada à análise espaço-temporal do crime (BRANTINGHAM; BRANTINGHAM, 1981a).

A categorização dos delitos, segundo Miller (2009), pode ser feita em: crimes contra o patrimônio (roubo, furto, arrombamento, etc.), crimes contra a pessoa (homicídio, agressão, estupro, etc.), crimes de ordem social ou moral (vandalismo, jogos de azar, etc.) e crimes tecnológicos ou cibernéticos. Em Pernambuco, a Secretaria de Defesa Social divulga os dados criminais com base em duas classes: crimes violentos letais intencionais (CVLI; basicamente homicídios) e crimes violentos contra o patrimônio (CVP; roubos e extorsão) (SDS, 2021).

Uma das vertentes da Criminologia consiste no desenvolvimento de teorias para analisar as causas dos eventos delituosos e os processos de controle social. Dentre as teorias existentes, destaca-se a da Desorganização Social (SHAW; MCKAY, 1942). Ela aponta que o nível de organização social em termos de coesão das pessoas é inversamente proporcional ao nível de atividade criminal. Isto decorre de um isolamento natural das pessoas em seus domicílios devido à rotina contemporânea, ao receio de crimes e à pouca identificação com o local de residência (SHAW; MCKAY, 1942). De acordo com os autores, a interação dos residentes é capaz de produzir mecanismos de prevenção ao crime. Segundo Pereira, Mota e Andresen (2017a), na literatura de criminologia espacial, a teoria da Desorganização Social é representada na prática pelos seguintes fatores ressaltados por Sampson e Groves (1989): baixo status econômico, heterogeneidade étnica, mobilidade residencial, ruptura familiar e urbanização.

O presente estudo também considera a Criminologia Ambiental (ANDRESEN, 2014). Esta abordagem afirma que a violência pode ser explicada de acordo com o entorno em termos das características do espaço e de suas variações temporais. Além disso, ela defende que os crimes ocorrem frequentemente em poucos locais específicos, o que se deve à rotina das pessoas em termos de residência, trabalho e deslocamento ser restrita a poucos ambientes. Assim, de acordo com Andresen (2014), investigar estes elementos espaciais junto às construções que restringem (ou atraem) deslocamentos serve de embasamento para a análise de crimes.

A Criminologia Ambiental é fundamentada por quatro teorias criminais clássicas voltadas à motivação do crime: Teoria da Atividade de rotina, Teoria Geométrica do crime, Teoria da Escolha racional (também denominada Teoria Econômica do crime) e Teoria do Padrão criminal (ANDRESEN, 2014).

A da Atividade de rotina (COHEN; FELSON, 1979) afirma que eventos criminais precisam de criminosos motivados e alvos adequados que convirjam no espaço e no tempo, na ausência de guardiões capazes. Além disso, esses atos ocorrem durante atividades regulares do alvo em espaços sociais e são afetados por tendências e flutuações na estrutura social. Por sua vez, a Teoria da Escolha racional (BECKER, 1968) afirma que os comportamentos criminosos são escolhidos intencionalmente com base numa função utilidade ponderada pelos custos (como o encarceramento) e benefícios (quantia arrecadada, valor agregado, etc.) relativos às alternativas de cometer o crime ou não.

A Teoria Geométrica do crime (BRANTINGHAM; BRANTINGHAM, 1981b) afirma que os padrões criminais numa região dependem da distribuição espacial dos infratores e dos alvos adequados, do conhecimento geral dos infratores sobre o local e da troca dinâmica de informações entre infratores. Por fim, a Teoria do Padrão criminal (BRANTINGHAM; BRANTINGHAM, 1993) aborda uma visão racional, dinâmica e recursiva da decisão de praticar o delito no tempo e no local ideais.

Deve-se ater, além das teorias, aos elementos do ambiente que interferem na escolha de alvos e áreas-alvo pelos infratores. Locais geradores de crimes são aqueles que fomentam eventos criminais devido à congregação pública de pessoas em grande escala para propósitos não-criminais, como shopping centers e estações de ônibus; logo, há mais alvos para crimes de oportunidade (como roubos) (BRANTINGHAM; BRANTINGHAM, 1995; KINNEY et al., 2008; BERNASCO; BLOCK, 2011). Por outro lado, locais atrativos de crimes promovem e reforçam oportunidades criminais amplamente conhecidas devido a padrões locais atraentes – como a falta de vigilância e a presença de estabelecimentos comerciais (BRANTINGHAM; BRANTINGHAM, 1995; BERNASCO; BLOCK, 2011; GROFF; MCCORD, 2012).

Sob o foco espacial, recomenda-se avaliar o menor nível de desagregação de dados possível para evitar a perda de informações, em especial porque fatores sociodemográficos tendem a variar significativamente em pequenas distâncias (BATTY, 2005). Contudo, depende-se da disponibilidade de dados criminais. Eles podem ser fornecidos em modo agregado (ao nível de bairros, por exemplo) ao invés de pontos georreferenciados, o que dificulta investigar dimensões espaciais personalizadas (MALLESON; STEENBEEK; ANDRESEN, 2019).

A decisão de cometer delitos é influenciada por fatores condicionantes que descrevem a região-alvo. Como exemplos têm-se: a densidade demográfica de residentes, trabalhadores e visitantes; o nível de desenvolvimento humano; o grau de riqueza; o nível de desigualdade de renda; a infraestrutura local; aspectos educacionais e imigração (KINNEY et al., 2008; BATELLA; DINIZ, 2010). Ademais, cada tipo de evento criminal é reflexo de variações no mosaico urbano em termos da diversidade e da concentração de instalações, pois ambos afetam a rotina e a circulação de pessoas (KINNEY et al., 2008).

## 2.2 Análise espacial

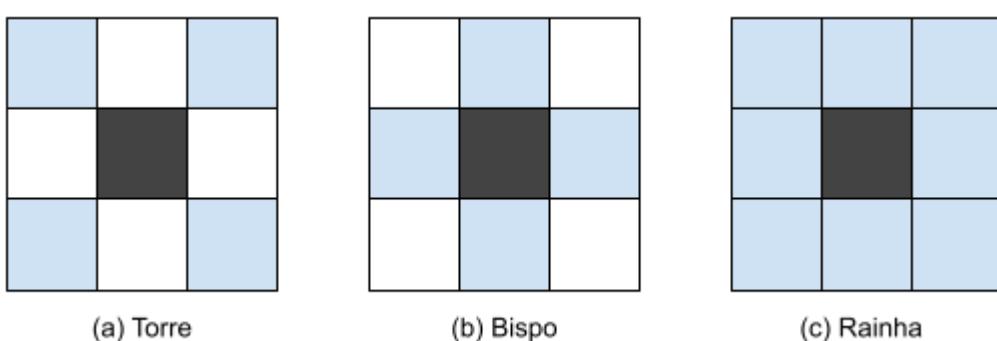
Esta seção apresenta os principais conceitos relativos às abordagens espaciais empregadas neste estudo.

### 2.2.1 Autocorrelação espacial

A autocorrelação (ou associação, ou dependência) espacial consiste na correlação (ou covariação) entre as observações de uma única variável devido estritamente à proximidade dessas observações no espaço geográfico (FISCHER; WANG, 2011). Esta noção é representada pela Lei da Geografia de Tobler, a qual afirma que tudo está relacionado a todo o restante, mas os elementos próximos estão mais relacionados do que os que estão mais distantes (TOBLER, 1970).

Para implementar os testes de dependência espacial é necessário especificar a relação de vizinhança entre as áreas. Isso geralmente é capturado por uma matriz quadrada de pesos espaciais, cujos elementos indicam a proximidade entre os locais (WONG; WANG, 2017). As duas abordagens mais comuns são a contiguidade e a distância. No primeiro caso, constrói-se uma matriz de elementos binários onde pares de áreas que compartilham uma fronteira física recebem valor 1; caso contrário, recebem 0. Essa fronteira pode ser definida conforme as movimentações de xadrez na Figura 1: uma aresta (tipo Torre), um vértice (tipo Bispo) ou uma aresta e/ou um vértice (tipo Rainha) (ALMEIDA, 2012). No segundo caso, forma-se uma matriz de elementos contínuos cujos pesos baseiam-se em uma função da distância geográfica entre os vizinhos (o inverso da distância, por exemplo) (RADIL, 2016).

Figura 1 - Formas de contiguidade espacial



Fonte: Adaptado de Almeida (2012)

As medidas de autocorrelação espacial investigam dois tipos de informação: a similaridade de observações (ou de valores) de atributos e a similaridade entre locais (GRIFFITH, 2003). Aquelas que resumem o nível de similaridade em toda a região de estudo são conhecidas como medidas globais (WONG; WANG, 2017). Assim, todos os elementos da matriz de pesos espaciais são utilizados na avaliação a fim de abranger todas as associações existentes. Avalia-se até que ponto o arranjo espacial se afasta da hipótese nula de que o espaço não importa, isto é, as áreas próximas não afetam umas às outras e o padrão espacial é aleatório. (FISCHER; WANG, 2011).

À medida que os estudos passam a envolver grandes extensões espaciais, aumenta-se a chance de o conjunto de dados violar a suposição de estacionariedade. Aplicar estatísticas espaciais globais neste contexto mascara a heterogeneidade espacial em níveis de análise pequenos, pois tendem a aparecer máximos locais de dependência espacial (DRUCK et al., 2014). Essas estatísticas geram um único valor médio de autocorrelação espacial para representar toda a região de estudo, logo não há informação sobre a variabilidade da dependência espacial nem a localização exata dos padrões (DALE; FORTIN, 2014).

Assim, é preciso utilizar indicadores de associação espacial que possam representar, em cada localidade, os padrões da variável distribuída espacialmente. Então surgiram as estatísticas locais a fim de medir o grau em que cada unidade de área é autocorrelacionada em relação a seus vizinhos (WONG; WANG, 2017). Elas realizam uma busca nos dados visando descobrir o tamanho e a localização de possíveis *clusters* espaciais (DRUCK et al., 2014).

#### 2.2.1.1 Global Moran's I

Um dos índices amplamente empregados na mensuração da autocorrelação espacial é o Global Moran's I (MORAN, 1948). Ele pode ser tratado como uma versão espacial do coeficiente de correlação de Pearson, mas aplicado apenas a uma variável (WONG; WANG, 2017). O índice é adequado para dados intervalares ou ordinais (OYANA, 2020).

O cálculo do índice consiste em dividir a covariação espacial pela variação total. Formalmente, ele é definido como:

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

onde  $x_i$  é o valor da variável  $x$  na unidade espacial  $i$ ;  $x_j$  é o valor da variável  $x$  na unidade espacial vizinha  $j$ ;  $\bar{x}$  é a média da variável  $x$  ao longo da região de estudo;  $w_{ij}$  é o peso espacial entre as unidades espaciais  $i$  e  $j$  com base na proximidade geográfica entre elas;  $n$  é o total de unidades espaciais; e  $W$  é a soma dos valores na matriz de pesos espaciais (ROGERSON, 2001).

O índice Global Moran's I pertence ao intervalo de -1 (dispersão perfeita) a 1 (correlação perfeita). O sinal positivo representa autocorrelação espacial positiva (isto é, tende a haver *clusters* espaciais de valores semelhantes da variável  $x$ ), enquanto o sinal negativo indica o agrupamento de áreas com valores de magnitude oposta (similar a um tabuleiro de xadrez). Por fim, o valor zero representa a inexistência de autocorrelação (FISCHER; WANG, 2011).

#### 2.2.1.2 Global Moran's I bivariado

A estatística de autocorrelação espacial global discutida anteriormente é aplicável apenas a uma variável. Então, ela foi estendida para investigar se existe, e em que medida se verifica, um padrão de correlação espacial entre duas variáveis em toda a região de estudo (LEE, 2001). Assim, ao invés de correlacionar uma variável e as defasagens espaciais para a mesma variável, o índice Global Moran's I bivariado analisa a correlação entre uma variável e as defasagens espaciais de outra variável. Em síntese, captura-se a relação entre o valor de uma variável  $x_a$  no local  $i$  e a média dos valores vizinhos  $j$  para outra variável  $y_b$ .

O índice bivariado é calculado como a seguir:

$$I_B = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} \left( \frac{x_{i,a} - \bar{x}_a}{\sigma_a} \right) \left( \frac{y_{j,b} - \bar{y}_b}{\sigma_b} \right)}{(n - 1) \sum_{i=1}^n \sum_{j \neq i} w_{ij}} \quad (2)$$

onde  $n$  denota o total de unidades espaciais;  $w_{ij}$  representa os pesos espaciais entre as unidades  $i$  e  $j$ ;  $x_{i,a}$  indica o valor do atributo  $a$  na unidade espacial  $i$  (assim

como  $y_{j,b}$  refere-se ao desempenho do atributo  $b$  na unidade  $j$ ); e  $\sigma_a$  e  $\sigma_b$  são os desvios-padrão dos atributos  $a$  e  $b$ , respectivamente.

Os valores de  $I_B$  pertencem ao intervalo  $[-1, 1]$ . Uma estatística  $I_B$  positiva indica uma correlação espacial positiva entre  $a$  e  $b$ , o que significa que uma unidade espacial com um valor  $a$  elevado está rodeada por áreas com valores elevados de  $b$ . Inversamente, um  $I_B$  negativo assinala uma correlação espacial negativa, revelando que uma unidade espacial com um valor alto de  $a$  será circundada por áreas com valores baixos do atributo  $b$ . Assim como ocorre para o coeficiente de correlação de Pearson, quanto maior for o valor absoluto de  $I_B$ , mais forte será a correlação espacial entre o par de atributos (LEE, 2001).

A significância estatística do índice Global Moran's I bivariado pode ser avaliada usando testes de permutação aleatória gerados com base no método de Monte Carlo. A probabilidade  $p$  calculada a partir desses experimentos de Bernoulli, sob a hipótese de correlação nula, reflete o nível de pseudo-significância dos índices de correlação espacial (ANSELIN, 2005).

#### 2.2.1.3 Local Moran's I

O Global Moran's I mede a autocorrelação espacial global, logo ignora a variabilidade do fenômeno de interesse dentro da região de estudo (WONG; WANG, 2017). A fim de refletir as associações espaciais locais, foi desenvolvido o índice Local Moran's I (ANSELIN, 1995). Ele é indicado para dados espaciais que são heterogêneos entre áreas, visto que consegue distinguir sub-regiões do conjunto de dados em uma escala local (BOOTS; OKABE, 2007).

Essencialmente, fixa-se cada unidade espacial  $i$  para compará-la com os valores do atributo de interesse nas unidades vizinhas. O índice Local Moran's I pode ser definido como:

$$I_i = n(x_i - \bar{x}) \sum_{j \neq i} w_{ij} (x_j - \bar{x}) \quad (3)$$

onde  $x_i$  é o valor da variável  $x$  na unidade espacial  $i$ ;  $x_j$  consiste no valor da variável  $x$  na unidade espacial vizinha  $j$ ;  $\bar{x}$  representa a média da variável  $x$  em toda a região

de estudo;  $w_{ij}$  denota o peso espacial entre as unidades espaciais  $i$  e  $j$ ; e  $n$  é o total de unidades espaciais (ROGERSON, 2001; ALDSTADT, 2010).

Os resultados do Local Moran's I podem ser representados em quatro quadrantes cujos rótulos possuem duas letras. A primeira letra indica se o valor de  $x_i$  é maior (H) ou menor (L) do que a média referente a todos os valores. De forma análoga, a segunda letra indica se o valor de  $x_j$  é maior (H) ou menor (L) do que a média de todas as defasagens espaciais (isto é, o valor da variável de interesse nas áreas vizinhas) (ALDSTADT, 2010).

Em suma, *clusters* do tipo High-High (HH) denotam áreas com valores altos circundadas por valores semelhantes; por sua vez, os do tipo Low-Low (LL) ocorrem da mesma forma, porém para valores baixos. Finalmente, os agrupamentos High-Low (HL) e Low-High (LH) contêm unidades espaciais com associação negativa com os vizinhos e são considerados *outliers* espaciais (OYANA, 2020).

Ao passo que a significância estatística do Local Moran's I foi investigada, recomenda-se gerar um mapa a fim de apresentar as áreas cuja autocorrelação espacial local se distingue na região de estudo. Essas localidades se destacam pela dinâmica espacial não-estacionária, logo devem ser priorizadas em análises minuciosas (DRUCK et al., 2004).

## 2.2.2 Geographically Weighted Regression

Em um modelo de regressão linear típico, OLS (*Ordinary Least Squares*, ou Regressão de mínimos quadrados, em tradução livre), aplicado a dados espaciais, assume-se que há um processo estacionário. Isto é, considera-se que, em toda a região de estudo, as mesmas relações são mantidas e o mesmo estímulo provoca a mesma resposta. Como resultado deste modelo global, obtém-se estimativas dos parâmetros que são constantes no espaço (FOTHERINGHAM, 2009).

Contudo, em caso de não-estacionariedade espacial, esses parâmetros representam apenas uma média dos diferentes processos que operam no espaço. Uma abordagem possível é relaxar as suposições do OLS, permitindo que as estimativas dos parâmetros no modelo variem ao longo do espaço. Essa é uma das prerrogativas do método de regressão espacial GWR (*Geographically Weighted Regression* ou Regressão Geograficamente Ponderada, em tradução livre), o qual

inclusive permite modelar a variação explicitamente (BRUNSDON; FOTHERINGHAM; CHARLTON, 1996; GETIS, 2010).

A ideia é ajustar um modelo de regressão a cada ponto observado (que representa uma unidade espacial), ponderando todas as demais observações como função da distância a este ponto. Desta forma, serão feitos tantos ajustes quantas observações existirem e o resultado será um conjunto de parâmetros, sendo que cada ponto terá seus próprios coeficientes de ajuste (DRUCK et al., 2004). O modelo GWR pode ser descrito como (FOTHERINGHAM, 2009):

$$y_i = \beta_{0i} + \beta_{1i}x_{1i} + \beta_{2i}x_{2i} + \dots + \beta_{ni}x_{ni} + \varepsilon_i \quad (4)$$

onde  $y_i$  é o valor da variável dependente observada na unidade espacial  $i$ ,  $x_{1i}, x_{2i}, \dots, x_{ni}$  são os valores das variáveis independentes observadas em  $i$ ,  $\beta_{0i}, \beta_{1i}, \dots, \beta_{ni}$  são parâmetros a serem estimados pra cada local  $i$ , e  $\varepsilon_i$  é um termo de erro. O estimador para os parâmetros é o seguinte:

$$\beta'(i) = (\mathbf{X}^T \mathbf{W}(i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(i) \mathbf{Y} \quad (5)$$

onde  $\mathbf{W}(i)$  é uma matriz de pesos atribuída à unidade espacial  $i$ , a qual tem a seguinte forma:

$$\mathbf{W}(i) = \begin{bmatrix} w_{i1} & 0 & \dots & \dots & 0 \\ 0 & w_{i2} & \dots & \dots & 0 \\ 0 & 0 & w_{i3} & \dots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & w_{in} \end{bmatrix} \quad (6)$$

onde  $w_{in}$  é o peso atribuído ao dado pontual  $n$  para a estimativa dos parâmetros locais na unidade espacial  $i$ .

No GWR, a matriz de pesos locais,  $\mathbf{W}(i)$ , é calculada a partir de uma função kernel que atribui pesos inversamente relacionados à distância entre as unidades espaciais. A ponderação, portanto, segue a suposição de autocorrelação espacial, que, se existir, deve resultar em padrões não-estacionários nos coeficientes estimados. A função de kernel tem como entrada a distância entre dois locais, tem um parâmetro de largura de banda que define a faixa espacial do kernel e retorna

um peso entre os dois locais. A partir dos pesos se pode calcular os coeficientes de regressão locais e, então, estimar a variável resposta (WHEELER, PÁEZ, 2010).

Existem dois tipos de funções de kernel, fixas e adaptativas. As funções fixas assumem que a largura da banda é constante para toda a região de estudo. Por outro lado, as funções adaptativas tentam se ajustar à densidade subjacente dos pontos de dados, isto é, as larguras de banda são maiores onde os dados são esparsos e menores onde os dados são mais densos (FOTHERINGHAM, 2009). A maioria das aplicações de GWR privilegia funções contínuas cujos pesos gerados diminuem de forma monotônica com a distância, como a função de kernel gaussiana (WHEELER, PÁEZ, 2010).

Nas funções kernel acima, há um parâmetro de largura de banda do kernel que deve ser selecionado ou estimado a partir dos dados, seja em termos de distância ótima ou do número ótimo de vizinhos. Para isso, as principais abordagens são a validação cruzada e o critério de informação de Akaike corrigido (AICc) (FOTHERINGHAM, 2009; WHEELER, PÁEZ, 2010).

A validação cruzada é um processo iterativo que procura a largura de banda do kernel que minimiza o erro de predição em todos os locais usando um subconjunto dos dados. Por sua vez, o processo do AICc baseia-se na minimização da estatística de mesmo nome visando melhorar o ajuste do modelo de regressão (WHEELER, PÁEZ, 2010).

A seleção de largura de banda ideal é uma relação compensatória entre enviesamento e variância. Uma largura de banda muito pequena leva a uma grande variação nas estimativas locais devido ao número pequeno de dados utilizados, enquanto uma largura muito grande provoca um viés significativo nas estimativas locais porque usam-se dados mais distantes do ponto onde se realiza a regressão (FOTHERINGHAM, 2009).

Um procedimento bastante aplicado a relações espaciais é a modelagem de regressão em duas camadas com base nos métodos OLS e GWR (OYANA; MARGAI, 2015). A primeira camada consiste em ajustar o melhor modelo global OLS. Assim, contribui-se para a identificação dos preditores mais importantes e capazes de explicar os processos espaciais na região de estudo. Em seguida, testa-se se os resíduos no modelo global são distribuídos aleatoriamente, isto é, se há independência espacial. Em caso negativo, há indícios de que o modelo pode gerar resultados incorretos.

A modelagem de segunda camada, posterior ao OLS, corresponde a aplicar o GWR para fornecer modelos locais da variável resposta. Logo, ajustam-se equações de regressão cujos coeficientes dos preditores respondem pela variabilidade espacial. Subsequentemente, os resíduos são avaliados quanto à autocorrelação espacial a fim de garantir que a questão espacial foi incorporada ao modelo e, então, não há prejuízo aos resultados estimados (OYANA; MARGAI, 2015).

A saída principal do GWR é um conjunto de estimativas de parâmetros específicos da unidade espacial, como os coeficientes dos preditores, os resíduos da regressão e estatísticas de ajuste do modelo (vide o  $R^2$ ). Estes podem ser mapeados e analisados a fim de fornecer informações sobre a não-estacionariedade espacial nos relacionamentos (DRUCK et al., 2004; FOTHERINGHAM, 2009).

Em suma, um modelo GWR é especialmente relevante quando ao menos uma das duas situações seguintes ocorrem. A primeira consiste na variável dependente apresentar dependência espacial significativa, então é necessário construir modelos locais para explicar as variações no espaço. A segunda se refere ao interesse de investigar a distribuição geográfica dos coeficientes de regressão locais visando compreender o efeito local das variáveis preditoras em diferentes unidades espaciais (OYANA; MARGAI, 2015).

## 2.3 Apoio a Decisão Multicritério

Esta seção apresenta os principais fundamentos relativos à modelagem multicritério empregada no presente estudo.

### 2.3.1 Conceitos básicos

As pessoas são naturalmente confrontadas com situações que requerem alguma forma de julgamento para obter um resultado final. Cada decisão que tomamos requer o equilíbrio de vários fatores de modo explícito ou inconsciente (BELTON; STEWART, 2002). Contudo, algumas decisões demandam maior reflexão devido, por exemplo, ao impacto dos resultados e à divergência de interesses. Neste sentido, têm evoluído o campo do Apoio a Tomada de Decisão Multicritério (*Multicriteria Decision Aiding* ou MCDA). Ele busca desenvolver metodologias e ferramentas de suporte à decisão para lidar com problemas decisórios complexos

envolvendo múltiplos objetivos conflitantes a serem julgados por um decisor (ROY, 1996; ZOPOUNIDIS; DOUMPOS, 2002; ZAVADSKAS; TURSKIS; KILDIENĖ, 2014).

O Apoio a Decisão busca indicar ou recomendar respostas a uma parte interessada que tornem o processo mais consistente e de acordo com o sistema de valores deste indivíduo (ROY, 1996). O ator envolvido na construção do modelo multicritério consegue compreender e explorar de forma racional suas próprias preferências, subjetividades e ponderações (de ALMEIDA et al., 2015). Um processo geral do MCDA consiste nas seguintes fases recursivas: identificação e estruturação do problema, construção e uso do modelo, e o desenvolvimento de planos de ação (BELTON; STEWART, 2002). Assim, almeja-se orientar o ator com informações propícias a decisões mais bem consideradas, justificáveis e transparentes (BELTON; STEWART, 2002; de ALMEIDA et al., 2015).

Na formulação de modelos multicritério, o decisor provê as preferências e, com base nas recomendações, opta por um curso de ação para o problema. Podem haver outros atores junto ao decisor, como: o analista, que fornece o suporte metodológico em MCDA para construir o modelo; o cliente, que serve de representante do decisor; e o especialista, que possui conhecimento excepcional acerca do objeto de estudo (ROY, 1996).

A construção de um modelo multicritério requer compreender a estrutura de preferências do decisor, avaliar o problema e extrair um conjunto de elementos, principalmente alternativas, critérios e uma matriz de decisão. As alternativas são os objetos para os quais o apoio a decisão é direcionado, são as ações em potencial a serem avaliadas (ROY, 2016). Por sua vez, entende-se critério como um padrão por meio do qual se avalia e compara alternativas conforme um certo ponto de vista acerca do problema (BELTON; STEWART, 2002; ROY, 2016). Os critérios devem ser não redundantes, exaustivos e consistentes. Os desempenhos das alternativas em cada critério podem ser avaliados em uma escala qualitativa ou quantitativa, os quais são apresentados numa matriz de decisão (de ALMEIDA et al., 2015).

Ao avaliar um problema de decisão, deve-se definir qual é a problemática mais adequada. Ela consiste numa maneira de classificar o tipo de problema conforme a maneira com que o decisor pretende comparar as alternativas (de ALMEIDA, 2013). Roy (1996) distingue quatro tipologias principais: escolha, que visa selecionar um subconjunto do espaço de alternativas; classificação, onde atribui-se cada alternativa à categoria mais apropriada entre uma família de categorias predefinidas;

ordenação, em que se colocam as alternativas em uma ordem de preferência (não necessariamente completa); e descrição, onde as ações e suas consequências são descritas de modo formalizado e sistemático.

Métodos multicritério são empregados para tratar as preferências do decisor e gerar uma recomendação final. Para que a escolha do método seja transparente e não-enviesada, deve-se considerar informações sobre o decisor (estrutura de preferências e racionalidade) e dos contextos organizacional e do problema (de ALMEIDA et al., 2015).

A literatura de MCDA propõe diversas formas de categorizar estes métodos. Uma delas fundamenta-se na racionalidade do decisor quanto à compensação ao agregar os critérios, classificando os métodos em compensatórios ou não compensatórios. O primeiro tipo verifica-se quando são considerados *tradeoffs* entre os critérios durante a avaliação das alternativas, de modo que o desempenho ruim em um critério pode ser remediado por um superior em outro. Por sua vez, os métodos não compensatórios não apresentam *tradeoffs* entre os critérios (ROY, 1996; de ALMEIDA, 2013; GRECO; FIGUEIRA; EHREGOTT, 2016).

Em grande parte dos métodos multicritério é necessário obter uma medida que pondere as preferências do decisor entre os critérios, sendo esta comumente denominada peso. Esse conceito está relacionado diretamente à racionalidade do decisor. Em métodos não compensatórios, o peso significa apenas a importância relativa dos critérios, enquanto para contextos compensatórios o termo apropriado é constante de escala, pois também incorpora informação acerca do range de valores dos critérios (de ALMEIDA et al., 2015).

Sob outra perspectiva, os métodos multicritério podem ser agrupados conforme as três principais famílias de abordagens operacionais: Métodos de critério único de síntese, Métodos de sobreclassificação e Métodos interativos (ROY, 1996).

Os métodos de critério único de síntese, ou aditivos, adotam um processo de combinação analítica de todos os critérios pelo qual se produz uma pontuação ou avaliação global para cada alternativa, reduzindo os critérios a um único. Eles apresentam uma racionalidade compensatória, abrangendo duas teorias de agregação dos critérios: Teoria do valor multiatributo (MAVT) e a Teoria da utilidade multiatributo (MAUT). A MAUT é usada em situações cujas consequências estão associadas a incertezas (evidenciando um contexto probabilístico), enquanto a MAVT associa um valor real exato a cada alternativa (abordagem determinística).

Em ambos os casos, a agregação ocorre mediante uma soma ponderada por taxas de substituição constantes, outrora denominadas constantes de escala (KEENEY; RAIFFA, 1976; BELTON; STEWART, 2002; BOUYSSOU et al., 2006).

Os métodos de sobreclassificação são não-compensatórios e baseiam-se na relação binária de mesmo nome, em que é avaliado se uma alternativa é pelo menos tão boa quanto a outra ao considerar todos os critérios – similar à ideia de dominância. Ao contrário do MAUT e MAVT, permitem-se situações de incomparabilidade entre consequências. Além disso, a agregação do desempenho nos critérios não necessariamente resume as avaliações das alternativas a uma única valoração. Destacam-se as famílias de métodos ELECTRE (*Elimination and Choice Expressing Reality*) e PROMETHEE (*Preference Ranking Organization Method for Enrichment of Evaluations*). Em geral, este tipo de método apresenta duas etapas: a construção das relações de sobreclassificação entre pares de alternativas e a exploração dessas relações para obter o resultado (ROY, 1996; BELTON; STEWART, 2002).

Por sua vez, os métodos interativos seguem uma sequência dinâmica e formal de perguntas feitas ao decisor sobre o desempenho das alternativas. Assim, o analista insere gradualmente as preferências do decisor no modelo, permitindo revisões e a alternância dos questionamentos com procedimentos de análise das respostas. Todavia, o maior benefício pode não ser obter uma solução ótima, mas sim os *insights* gerados durante a exploração do espaço de decisão. Abrangem-se problemas com um conjunto discreto ou contínuo de alternativas (LEE; OLSON, 1999; BELTON; STEWART, 2002; ROY, 2016; ALLMENDINGER et al., 2017).

### **2.3.2 Tomada de decisão espacial**

Esta seção apresenta os conceitos que norteiam o emprego de sistemas de informação geográfica em conjunto com a decisão multicritério neste estudo.

#### *2.3.2.1 Sistema de Informação Geográfica (GIS)*

O GIS define-se como um conjunto de ferramentas de software destinadas a criar, gerenciar, exibir e analisar dados espaciais com o intuito de contribuir para a modelagem e investigação do mundo real (SUGUMARAN; DEGROOTE, 2010).

Assim, o sistema enquanto tecnologia concede suporte à tomada de decisão espacial (MALCZEWSKI; RINNER, 2015).

O ambiente GIS processa simultaneamente dois tipos de dados: espaciais e de atributos (HEYWOOD; CORNELIUS; CARVER, 2002). O primeiro se refere à localização das entidades no espaço em termos de suas coordenadas geográficas. Por sua vez, os atributos descrevem as principais propriedades associadas às entidades espaciais, seja de natureza quantitativa ou qualitativa, como fatores socioeconômicos e custo do terreno.

A organização dos dados espaciais no GIS baseia-se em seus componentes estruturais, na forma de vetor ou de *raster*. As entidades em formato vetorial são representadas por cadeias de coordenadas. Cada coordenada corresponde a um ponto, cujas interligações resultam em objetos do tipo linha ou polígono. Já os dados na forma de *raster* são armazenados em uma matriz bidimensional de células de *grid* uniformes (pixels ou *rasters*) que compõem um *grid* de formato regular. Cada célula é supostamente homogênea, logo é o menor nível de informação provida pelo mapa e denota a sua resolução espacial (MALCZEWSKI, 2010).

### 2.3.2.2 GIS-MCDA

A abordagem multicritério (MCDA) pode ser aplicada em um contexto de tomada de decisão espacial. Um aspecto crítico é a necessidade de avaliar alternativas de decisão definidas espacialmente e as preferências do decisor, o que eleva o nível de complexidade (SUGUMARAN; DEGROOTE, 2010). Portanto, o resultado da análise depende não só de padrões geográficos como também dos julgamentos de valor ao longo do processo decisório. Como o GIS possui recursos muito limitados para modelar preferências, então foi desenvolvida a integração GIS-MCDA para expandir a capacidade de suporte à decisão (MALCZEWSKI, 2010, 2017; SUGUMARAN; DEGROOTE, 2010).

As duas abordagens têm potencialidades únicas que se complementam (MALCZEWSKI, 2006). Por um lado, o GIS fornece um conjunto de técnicas capaz de armazenar, gerenciar, analisar e visualizar dados geoespaciais, servindo de apoio a tomada de decisão. Por outro, o MCDA engloba um acervo de metodologias para estruturar problemas com objetivos conflitantes, permitindo esclarecer a situação e solucioná-la sistematicamente pela priorização de alternativas (MALCZEWSKI, 1999,

2017). O benefício advém do aumento na confiança do decisor e da simplificação das análises, sendo ambos decorrentes da exploração visual e da identificação de padrões espaciais no GIS (MALCZEWSKI, 2010).

Em síntese, GIS-MCDA é um processo que combina e transforma os dados geográficos (mapas de entrada) e as preferências do decisor em uma sugestão resultante (mapa de saída) de acordo com regras de decisão oriundas de um método pré-definido (MALCZEWSKI, 2010). Os métodos GIS-MCDA podem ser classificados em três grupos: convencional, espacialmente explícito e otimização espacial multiobjetivo (MALCZEWSKI; RINNER, 2015).

A respeito das abordagens convencionais, elas são adaptações de métodos MCDA para analisar problemas de decisão espacial, como o ELECTRE. Assume-se que as preferências do decisor são espacialmente homogêneas e geralmente se trata a variabilidade espacial de forma implícita (MALCZEWSKI, 2017). Logo, embora o fator espacial das alternativas de decisão não seja percebido explicitamente (isto é, as coordenadas geográficas não fazem parte dos cálculos), pode haver implicações espaciais associadas à implementação delas. Os critérios de avaliação, por sua vez, são baseados em relações espaciais, como proximidade, adjacência e contiguidade (VAN HERWIJNEN; RIETVELD, 1999; MALCZEWSKI; RINNER, 2015).

### 2.3.3 Weighted Linear Combination

O WLC (*Weighted Linear Combination*, ou Combinação Linear Ponderada em tradução livre) é o método GIS-MCDA mais utilizado, o qual pertence às abordagens convencionais (MALCZEWSKI, 2006). O método também é conhecido pelos termos: ponderação aditiva simples, soma ponderada, média linear ponderada e sobreposição ponderada.

Ele é um procedimento para agregar camadas de mapas por meio da execução de uma soma ponderada dos critérios de avaliação (ou atributos) associados a cada alternativa de decisão  $i$ . As alternativas são representadas por um conjunto de células ou pixels em uma base de dados GIS composta por *rasters*. Elas são descritas por meio de atributos locacionais na forma de dados de coordenadas e de dados de atributos, que consistem nos valores associados à localização. (MALCZEWSKI, 2000). O WLC é baseado na seguinte regra de decisão:

$$V(A_i) = \sum_{k=1}^n w_k v(a_{ik}) \quad (7)$$

onde  $V(A_i)$  é o valor global da  $i$ -ésima alternativa,  $w_k$  (tal que  $k = 1, 2, \dots, n$ ) é o peso do  $k$ -ésimo critério, e  $v(a_{ik})$  é a função-valor da  $i$ -ésima alternativa em relação ao  $k$ -ésimo critério. A alternativa que apresentar o maior valor de  $V(A_i)$  é a mais preferida (MALCZEWSKI, 2017).

O modelo WLC é baseado em duas premissas: linearidade e aditividade. A primeira se fundamenta no anseio por uma unidade adicional de um atributo ser constante para qualquer nível daquele atributo. Por sua vez, a última refere-se aos atributos serem mutuamente independentes em preferência um do outro (MALCZEWSKI; RINNER, 2015).

Neste contexto, os pesos representam constantes de escala, tal que a razão entre dois pesos quaisquer deve ser inversamente proporcional à taxa em que se está disposto a fazer um *tradeoff* do critério. Por fim, o cálculo dos pesos deve considerar o *range* dos valores dos critérios (MALCZEWSKI; RINNER, 2015). As premissas e o significado dos pesos no WLC são típicos do modelo aditivo tradicional (MAVT) (DE ALMEIDA, 2013).

Uma das principais vantagens do método é que ele pode ser facilmente implementado dentro de um ambiente GIS utilizando álgebra de operações algébricas de mapas e modelagem cartográfica. O método também é considerado simples de entender e intuitivo, o que o torna atraente aos atores envolvidos em um processo decisório (MALCZEWSKI, 2017).

### 2.3.4 ELECTRE-TRI-nC

A família de métodos de sobreclassificação ELECTRE é a mais utilizada para problemas de classificação multicritério (ALVAREZ; KISHIZAKA; MARTÍNEZ, 2021). Nela, o primeiro método dedicado a tratar a problemática de classificação foi o ELECTRE TRI (ROY; BOUYSSOU, 1993). Nesse método, o conjunto de alternativas é alocado a classes pré-definidas ordinalmente a partir de comparações par-a-par entre as alternativas do problema e os perfis que definem os limites superiores e

inferiores das classes. Numa variante do método denominada ELECTRE-TRI-C (ALMEIDA-DIAS; FIGUEIRA; ROY, 2010), cada classe é caracterizada a partir de apenas uma única alternativa de referência, um perfil central.

Em uma versão mais recente do ELECTRE-C, intitulada ELECTRE TRI-nC (ALMEIDA-DIAS; FIGUEIRA; ROY, 2012), o decisão tem maior liberdade para representar as classes do modelo. Ao invés de limitar a construção de uma única alternativa de referência central por categoria, cada classe pode ser caracterizada por  $n$  alternativas fictícias. Assim, o modelo multicritério tende a representar mais detalhadamente as preferências do decisão.

Formalmente, o ELECTRE TRI-nC é um método multicritério de classificação que atribui alternativas de um conjunto  $A = \{a_1, \dots, a_i, \dots, a_m\}$  a categorias de um conjunto de classes ordenadas predefinidas  $C = \{C_1, \dots, C_h, \dots, C_q\}$  com base em comparações par-a-par de alternativas  $a_i \in A$  com ações de referência  $b_h^r \in B_h = \{b_h^r, r = 1, \dots, m_h\}$  que são representativas de cada categoria  $C_h$  (ALMEIDA-DIAS; FIGUEIRA; ROY, 2012).

Dois subconjuntos adicionais são necessários para aplicar o método, contendo uma ação de referência cada:  $B_0 = \{b_0^1\}$  e  $B_{q+1} = \{b_{q+1}^1\}$ . Essas ações de referência são definidas como:  $g_j(b_0^1)$  é o pior desempenho possível e  $g_j(b_{q+1}^1)$  é o melhor possível no critério  $g_j$ ,  $\forall g_j \in F = \{g_1, \dots, g_j, \dots, g_n\}$ .

Além disso, os conjuntos de referência  $B_h$  devem satisfazer as condições de dominância a seguir:

- $B_{h+1}$  domina  $B_h$ :  $\forall h = 1, \dots, p-1; \forall j = 1, \dots, m; g_j(b_{h+1}^s) - g_j(b_h^r) \geq 0; s = 1, \dots, m_{h+1}; r = 1, \dots, m_h$
- $B_h$  não sobreclassifica  $B_{h+1}$ :  $\forall h = 1, \dots, p-1; \sigma(b_h^r, b_{h+1}^s) < \lambda; s = 1, \dots, m_{h+1}; r = 1, \dots, m_h$

Os critérios no ELECTRE-TRI-nC podem ser tratados como pseudo-critérios ao passo que consideram o caráter imperfeito dos dados. Isto ocorre ao permitir associar a cada critério  $g_j$  dois limiares: o de indiferença,  $q_j$  e o de preferência,  $p_j$ , de modo que  $p_j \geq q_j \geq 0$ . Consequentemente, na comparação de quaisquer pares de alternativas  $(a, a') \in A \times A$  obtém-se as seguintes relações binárias relativas a qualquer critério  $g_j$ :

- Preferência estrita:  $g_j(a) - g_j(a') > p_j(g_j(a')) \Leftrightarrow aP_ja'$

- Preferência fraca:  $q_j(g_j(a')) < g_j(a) - g_j(a') \leq p_j(g_j(a')) \Leftrightarrow aQ_ja'$
- Indiferença:  $-q_j(g_j(a)) \leq g_j(a) - g_j(a') \leq q_j(g_j(a')) \Leftrightarrow aI_ja'$

A cada critério é associado um peso  $w_j$  que representa a sua importância relativa. Assume-se que  $\sum_{j=1}^n w_j = 1$ . A concordância global com a afirmação “ $a$  sobreclassifica  $a'$ ” (ou  $a \succ a'$ ) é modelada por meio de um índice de concordância abrangente  $c(a, a')$  definido a seguir:

$$c(a, a') = \sum_{j \in C(aPa')} w_j + \sum_{j \in C(aQa')} w_j + \sum_{j \in C(aIa')} w_j + \sum_{j \in C(aIa')} w_j \varphi_j \quad (8)$$

onde

$$\varphi_j = \frac{g_j(a) - g_j(a') + p_j(g_j(a))}{p_j(g_j(a)) - q_j(g_j(a))} \in [0,1] \quad (9)$$

assim como  $C(aPa')$  é o subconjunto de critérios que dão suporte a  $aP_ja'$ ,  $C(aQa')$  é o subconjunto de critérios que dão suporte a  $aQ_ja'$ , e  $C(aIa')$  é o subconjunto de critérios que dão suporte a  $aI_ja'$ .

O ELECTRE-TRI-nC permite incluir um poder de veto a critérios  $g_j$  ao associar um limiar de veto,  $v_j$ , tal que  $v_j \geq p_j$  (ALMEIDA-DIAS; FIGUEIRA; ROY, 2012). Esta oposição à sobreclassificação em um critério é representada pelo índice de discordância parcial  $d_j(a, a')$ ,  $j = 1, \dots, n$ , o qual é definido como:

$$d_j = \begin{cases} 1 & \text{se } g_j(a) - g_j(a') < -v_j(g_j(a)), \\ \frac{g_j(a) - g_j(a') + p_j(g_j(a))}{p_j(g_j(a)) - v_j(g_j(a))} & \text{se } -v_j(g_j(a)) \leq g_j(a) - g_j(a') < -p_j(g_j(a)), \\ 0 & \text{se } g_j(a) - g_j(a') \geq -p_j(g_j(a)). \end{cases} \quad (10)$$

O índice de credibilidade  $\sigma(a, a')$  reflete o grau em que “ $a$  sobreclassifica  $a'$ ” (ou  $a \succ a'$ ), o qual é definido com base em todos os critérios conforme a seguir:

$$\sigma(a, a') = c(a, a') \prod_{j=1}^n T_j(a, a') \quad (11)$$

onde

$$T_j(a, a') = \begin{cases} \frac{1 - d_j(a, a')}{1 - c(a, a')} & \text{se } d_j(a, a') > c(a, a'), \\ 1 & \text{caso contrário.} \end{cases} \quad (12)$$

Cada alternativa deve ser comparada a conjuntos de alternativas de referência para ser atribuída a uma categoria, logo é necessário definir índices de credibilidade categórica. Na Equação (13) verifica-se o grau de sobreclassificação categórica de uma alternativa  $a$  sobre o conjunto de ações de referência  $B_h$ , enquanto na Equação (14) avalia-se o grau em que uma alternativa  $a$  é sobreclassificada pelo conjunto  $B_h$  (representativo da categoria  $C_h$ ).

$$\sigma(\{a\}, B_h) = \max_{r=1, \dots, m_h} \{\sigma(a, b_h^r)\} \quad (13)$$

$$\sigma(B_h, \{a\}) = \max_{s=1, \dots, m_h} \{\sigma(b_h^s, a)\} \quad (14)$$

Um nível mínimo de credibilidade, denotado por  $\lambda$ , é necessário para validar a afirmação “ $a$  sobreclassifica  $B_h$ ” quando todos os critérios são considerados. Este nível recebe um valor do intervalo  $[0,5, 1]$ , e é usado para definir quatro possíveis resultados quando uma alternativa é comparada com as ações de referências em uma categoria, definidas como  $\lambda$ -relações binárias:

- $\lambda$ -outranking:  $\{a\}S^\lambda B_h \Leftrightarrow \sigma(\{a\}, B_h) \geq \lambda$ ;
- $\lambda$ -preferência:  $\{a\}P^\lambda B_h \Leftrightarrow \sigma(\{a\}, B_h) \geq \lambda \wedge \sigma(B_h, \{a\}) < \lambda$ ;
- $\lambda$ -indiferença:  $\{a\}I^\lambda B_h \Leftrightarrow \sigma(\{a\}, B_h) \geq \lambda \wedge \sigma(B_h, \{a\}) \geq \lambda$ ;
- $\lambda$ -incomparabilidade:  $\{a\}R^\lambda B_h \Leftrightarrow \sigma(\{a\}, B_h) < \lambda \wedge \sigma(B_h, \{a\}) < \lambda$ ;

O procedimento de atribuir uma alternativa a uma categoria é composto de uma regra ascendente e uma regra descendente, que devem ser usadas conjuntamente (ALMEIDA-DIAS; FIGUEIRA; ROY, 2012). Uma função de seleção  $\rho$  é definida como:

$$\rho(\{a\}, B_h) = \min\{\sigma(\{a\}, B_h), \sigma(B_h, \{a\})\} \quad (15)$$

A regra descendente é definida como: diminua  $h$  de  $q + 1$  até o primeiro valor,  $t$ , tal que  $a S B_t$ , isto é,  $\sigma(\{a\}, B_t) \geq \lambda$ . Para  $t = q$ , selecione  $C_q$  como uma possível categoria para atribuir a alternativa  $a$ . Para  $0 < t < q$ , se  $\rho(\{a\}, B_t) > \rho(\{a\}, B_{t+1})$ , selecione  $C_t$  como uma possível categoria para atribuir a alternativa  $a$ ; caso contrário, selecione  $C_{t+1}$ . Para  $t = 0$ , selecione  $C_1$  como uma possível categoria para atribuir  $a$ .

A regra ascendente é definida como: aumente  $h$  de 0 até o primeiro valor,  $t$ , tal que  $B_t S a$ , isto é,  $\sigma(B_t, \{a\}) \geq \lambda$ . Para  $t = 1$ , selecione  $C_1$  como uma possível categoria para atribuir a alternativa  $a$ . Para  $1 < t < (q + 1)$ , se  $\rho(\{a\}, B_t) > \rho(\{a\}, B_{t-1})$ , selecione  $C_t$  como uma possível categoria para atribuir a alternativa  $a$ ; caso contrário, selecione  $C_{t-1}$ . Para  $t = (q + 1)$ , selecione  $C_q$  como uma possível categoria para atribuir  $a$ .

Essas duas regras são aplicadas conjuntamente e indicam as possíveis categorias mais altas e mais baixas às quais uma alternativa deve ser atribuída. Essas categorias podem ser iguais ou, se houver ambiguidade, a atribuição pode ser mal determinada e indicar uma gama de categorias possíveis. Em síntese, uma alternativa  $a$  pode ser atribuída a:

- Uma categoria, quando ambas as regras selecionam a mesma categoria;
- Duas categorias, quando as duas regras selecionam categorias consecutivas;
- Um intervalo de mais de duas categorias consecutivas, delimitado pelas categorias selecionadas pelas duas regras.

### 3 REVISÃO DE LITERATURA

O presente capítulo discute publicações recentes acerca dos principais temas discutidos neste trabalho (COVID-19 e crimes), tendo enfoque na aplicação de estruturas metodológicas próximas às que serão aqui exploradas: métodos estatísticos, espaciais e multicritério. A revisão de literatura foi dividida em três tópicos: análise estatística-espacial da propagação da COVID-19, modelagem matemática da ocorrência de crimes e considerações finais do capítulo. As bases de periódicos Scopus e Web of Science consistiram nas fontes de pesquisa.

#### 3.1 Estudos estatísticos-espaciais sobre COVID-19

A pandemia de COVID-19 tem ocasionado uma série de desafios sanitários, políticos e socioeconômicos à sociedade. Deste modo, entender o comportamento dinâmico da propagação espaço-temporal da doença auxilia no gerenciamento da crise. Dentre as abordagens mais empregadas destaca-se a análise espacial, particularmente a exploração de estatísticas de clusterização, interpolação e varredura espaço-temporal em função do número de casos confirmados e óbitos por COVID-19 (FATIMA et al., 2021).

Em estudos conduzidos na China ao nível de cidades (MA et al., 2021; WANG, Q. et al., 2021) e condados (XIONG et al., 2020), revelou-se que os *hotspots* de casos apresentam uma localização estável, mas com tendência de redução no tamanho ao longo do tempo. Um padrão semelhante ocorreu nos Estados Unidos até julho de 2020, embora os *clusters* espaciais estivessem mais espalhados pelo país (HOHL et al., 2020). Na Europa, notou-se uma forte heterogeneidade espacial até outubro de 2020: algumas regiões foram fortemente atingidas por mortalidade muito acima da média, enquanto outras a leste e ao sul tiveram taxas significativamente baixas (AMDAOUD; ARCURI; LEVRATTO, 2021). Investigações similares envolvendo *clusters* de casos e/ou óbitos por COVID-19 ocorreram na Turquia ao nível de províncias (ARAL; BAKHIR, 2022), na capital do Irã ao nível de bairros (LAK et al., 2021) e no estado de Nova York ao nível de condados (ZHENG; WANG; LI, 2021).

O centróide para casos da doença na América do Sul até janeiro de 2021, por sua vez, se deslocou do oeste para o leste dentro do território brasileiro (HUANG,

2021). No Brasil, os centróides de casos e óbitos iniciaram no estado de São Paulo (região Sudeste), então se moveram progressivamente para o norte até o início de maio de 2020, quando, enfim, retornaram ao Sudeste (CASTRO et al., 2021). O Nordeste brasileiro vivenciou um crescimento acelerado das taxas de COVID-19 de fevereiro a maio de 2020, com destaque para as áreas metropolitanas (principalmente no litoral) sendo *clusters* de casos (GOMES et al., 2020).

As iniciativas de mitigação ao espalhamento da doença devem ser sustentadas pelo conhecimento das características locais que possam influenciar na dinâmica da pandemia. Neste sentido, estudos têm aplicado técnicas de análise multivariada a fim de analisar a relação destas características com as taxas de incidência, mortalidade e letalidade por COVID-19 (de SOUZA; MACHADO; do CARMO, 2020; ALI; MORTULA; SADIQ, 2021; MANDA et al., 2021; SUN; HU; XIE, 2021).

O Quadro 1 apresenta uma breve categorização dos fatores recorrentemente explorados em modelos estatísticos na literatura e que se mostraram significativos na predição da COVID-19. Na amostra selecionada, as questões demográficas e socioeconômicas são mais exploradas. Uma porção considerável dos trabalhos levantados utiliza regressão múltipla, principalmente métodos que incorporam os efeitos espaciais na predição como o *Spatial Autoregressive Model* (MANDA et al., 2021; AMDAOUD; ARCURI; LEVRATTO, 2021; CUTRINI; SALVATI, 2021) e as variações do GWR (IYANDA et al., 2020; MOLLALO; VAHEDI; RIVERA, 2020; MAITI et al., 2021; LIU; LIU; GUAN, 2021; OLUYOMI et al., 2021). Percebe-se também que alguns destes estudos removeram variáveis explanatórias redundantes ou pouco significativas mediante procedimentos de seleção, levando a um conjunto reduzido de preditores (MOLLALO; VAHEDI; RIVERA, 2020; ALSHOGREN et al., 2021; JABŁONSKA; ABALLÉA; TOUMI, 2021; KWOK et al., 2021; LIU et al., 2021; LIU; GUAN, 2021; MAITI et al., 2021; PANA et al., 2021; SUN; HU; XIE, 2021).

Vale ressaltar que a significância dos preditores varia conforme a escala espacial, a área de estudo e a fase do surto (FATIMA et al., 2021). Em escala global, o início da difusão de COVID-19 foi afetado pela densidade populacional, por populações mais velhas e pelo tamanho da família, enquanto os impactos da globalização interpessoal e comercial têm aumentado com o tempo (SIGLER et al., 2021). Ademais, os países com maior população economicamente ativa (15 a 64 anos de idade) e despesas diretas com saúde privada per capita tendem a sofrer mais casos de COVID-19 nas fases iniciais da pandemia (IYANDA et al., 2020).

Quadro 1 - Tipos de preditores explorados na modelagem estatística da COVID-19

Tipos	Preditores
Demográfico	Minorias étnicas (ALI; MORTULA; SADIQ, 2021; MAITI et al., 2021; SUN; HU; XIE, 2021), população idosa (ALI; MORTULA; SADIQ, 2021; ALSHOGREN et al., 2021; AMDAOUD; ARCURI; LEVRATTO, 2021; ANDERSEN et al., 2021; MANDA et al., 2021; OLUYOMI et al., 2021), densidade populacional (LIU et al., 2021), tamanho da população (JABŁOŃSKA; ABALLÉA; TOUMI, 2021), população urbana (JABŁOŃSKA; ABALLÉA; TOUMI, 2021)
Socioeconômico	Nível de escolaridade (de SOUZA; MACHADO; do CARMO, 2020; MAITI et al., 2021; KWOK et al., 2021; LIU et al., 2021), taxa de desemprego (AMDAOUD; ARCURI; LEVRATTO, 2021; SUN; HU; XIE, 2021), PIB per capita (AMDAOUD; ARCURI; LEVRATTO, 2021), taxa de pobreza (LIU et al., 2021), índice de privação da área (OLUYOMI et al., 2021), renda domiciliar média (de SOUZA; MACHADO; do CARMO, 2020; MAITI et al., 2021; KWOK et al., 2021; MOLLALO; VAHEDI; RIVERA, 2020), desigualdade de renda (MOLLALO; VAHEDI; RIVERA, 2020; RAYMUNDO et al., 2021)
Epidemiológico	Comorbidades (ALI; MORTULA; SADIQ, 2021), disponibilidade de leitos e serviços de saúde (AMDAOUD; ARCURI; LEVRATTO, 2021; MANSOUR et al., 2021; WEINSTEIN et al., 2021; JABŁOŃSKA; ABALLÉA; TOUMI, 2021), número de médicos (AMDAOUD; ARCURI; LEVRATTO, 2021), número de enfermeiros (MOLLALO; VAHEDI; RIVERA, 2020), cobertura da vacina Polio-3 entre crianças (ALSHOGREN et al., 2021), cobertura da vacina BCG (PANA et al., 2021)
Ambiente construído	Mobilidade devido à geometria urbana (KWOK et al., 2021; WEINSTEIN et al., 2021), densidade de ambiente construído (LIU; LIU; GUAN, 2021), densidade de instalações comerciais e estradas (WANG, J. et al., 2021), aglomeração urbana, presença de distritos industriais e de grandes empresas (CUTRINI; SALVATI, 2021)
Político	Transparência governamental (MANDA et al., 2021), fechamento das fronteiras (JABŁOŃSKA; ABALLÉA; TOUMI, 2021), número de pouso internacionais (PANA et al., 2021)
Meio ambiente	Poluição, umidade relativa e temperatura do ar (BILAL et al., 2021; SUN; HU; XIE, 2021)

Fonte: O autor (2022)

O Brasil é complexamente grande e desigual em termos de saúde pública e questões socioeconômicas, portanto não há uma explicação única para os padrões espaciais de transmissão do vírus (CASTRO et al., 2021). Ao nível de municípios, adultos jovens e mulheres estão mais suscetíveis à COVID-19, enquanto homens mais velhos têm maior risco de morte pela doença (LIMA et al., 2021). Além disso, pretos e pardos estão mais expostos à doença (devido à sua atividade laboral) e

possuem maior risco de óbito (HUGHES et al., 2021). Municípios brasileiros com maior desigualdade de renda (MARTINES et al., 2021; RAYMUNDO et al., 2021) e população socialmente vulnerável apresentam alto risco de incidência da COVID-19 (RAYMUNDO et al., 2021). Dentre os fatores de vulnerabilidade a nível nacional estão o trabalho infantil, a evasão escolar de crianças e o número de adultos empregados com baixa escolaridade (de SOUZA; MACHADO; do CARMO, 2020).

Na região da Mata Atlântica (onde reside 57% da população brasileira), houve uma associação direta entre os casos e mortes por COVID-19 com o tamanho da população, a densidade demográfica e a área construída (VIEZZER; BIONDI, 2021). Nesta localidade estão as principais metrópoles do país, São Paulo e Rio de Janeiro. Na cidade de São Paulo, a COVID-19 afetou fortemente áreas com favelas, média salarial baixa e baixo percentual de idosos (FERREIRA, 2020). Já na cidade do Rio de Janeiro, os casos da doença partiram das áreas com maior PIB per capita e nível de escolaridade para aquelas menos favorecidas, onde inclusive há maior taxa de mortalidade – principalmente entre a população preta (SILVA; RIBEIRO-ALVES, 2021). Além dos pretos, no estado de São Paulo os pardos e com baixa renda domiciliar estão mais propensos ao óbito por COVID-19 (LI, S. et al., 2021).

A pandemia tem afetado gravemente as regiões mais pobres e desiguais no Brasil, com destaque para os estados da região Nordeste (KERR et al., 2020). Esses locais sofrem com um grande número de infecções e um alto risco de mortalidade por COVID-19 devido ao status socioeconômico desfavorecido e às condições de saúde insatisfatórias (LIMA et al., 2021). Em uma abordagem GIS-MCDA aplicada ao estado de Pernambuco em diferentes datas (até novembro de 2020), notou-se que as cidades com maior população e densidade populacional são altamente vulneráveis à doença – incluindo a capital do estado, Recife (FIGUEIREDO et al., 2022). Estudo semelhante conduzido em Recife, combinando técnicas estatísticas e multicritério, ressaltou 24 dentre os 94 bairros por terem alta suscetibilidade à propagação da COVID-19 (SOUZA et al., 2020b). Os demais trabalhos na capital pernambucana, até o momento (fevereiro de 2022), restringiram-se à associação dos casos de COVID-19 com o número de usuários de transporte público (da SILVA et al., 2020) e com fatores socioeconômicos (QUININO et al., 2021).

Neste sentido, esta etapa do presente estudo investiga a difusão espaço-temporal da doença na cidade do Recife em termos de casos confirmados e letalidade. Ademais, explora a influência sobre os índices epidemiológicos não só de

questões demográficas e socioeconômicas locais, como também do funcionamento de serviços essenciais potencialmente geradores de aglomeração (mesmo durante períodos de quarentena rígida). Além disso, percebeu-se que as principais metrópoles do país têm apresentado padrões socioeconômicos de propagação da doença semelhantes à tendência de nível nacional. Buscou-se, então, examinar se a pandemia na capital de Pernambuco evoluiu da mesma forma. Por fim, averiguou-se a possível compatibilidade de características entre as áreas mais suscetíveis à propagação da doença com àquelas de maior incidência e vulnerabilidade a roubos.

### 3.2 Modelos matemáticos sobre a ocorrência de crimes

As teorias criminais possuem em comum a noção de que crimes não ocorrem aleatoriamente, mas em um contexto de oportunismo do criminoso quanto à adequação dos alvos e do contexto local (ANDRESEN, 2014). Além disso, os eventos criminais tendem a se concentrar em um pequeno percentual de microunidades geográficas de determinada região (WEISBURD, 2015). Assim, verifica-se uma diversidade no foco das publicações buscando revelar os locais cuja periculosidade é exacerbada. Autores exploram padrões espaço-temporais dos crimes (ANDRESEN; LINNING; MALLESON, 2017), assim como evidenciam características da região de estudo que atraem a atenção de delinquentes, incluindo questões sociodemográficas (PRATT; CULLEN, 2005; ENGELEN; LANDER; VAN ESSEN, 2016) e a presença de instalações comerciais (KINNEY et al., 2008).

Sob o ponto de vista de modelagem matemática, as questões de pesquisa envolvendo criminalidade têm sido recorrentemente investigadas mediante técnicas estatísticas e/ou espaciais, com enfoque preditivo. Também são encontrados estudos cujo enfoque é a análise multicritério, nos quais, em alguns casos, implementa-se a combinação GIS-MCDA para enriquecer o modelo decisório.

#### 3.2.1 Modelagem estatística e espacial no contexto criminal

De acordo com Lee et al. (2017), os crimes se concentram em uma proporção relativamente pequena de locais, independentemente de como o crime é medido, a escala espacial ou o tipo de crime. Ademais, os autores descobriram que quando todos os lugares são considerados (incluindo aqueles sem registros de crimes), os

crimes contra o patrimônio aparecem mais concentrados do que os crimes contra a pessoa. Neste sentido, estudos têm se dedicado a identificar estes locais no espaço (e como eles variam ao longo do tempo) e explorar os principais fatores que propiciam a atividade criminal.

A análise de dados georreferenciados criminais requer considerar o nível de precisão dos testes matemáticos, o que se reflete nas dimensões da unidade espacial. Segundo Rummens e Hardys (2021), há um tradeoff entre a previsão em altas resoluções espaço-temporais e os custos de desempenho de previsão, devendo-se encontrar um ponto satisfatório entre ambos que seja consoante ao problema. Malleson, Steenbeek e Andresen (2019) notaram que, em estudos criminais, não há uma escala única mais apropriada, pois ela varia conforme o tipo de crime, o número de eventos disponível e o grau de clusterização espacial.

Fixado esse parâmetro, pode ter início a exploração espacial dos eventos criminais. Em alguns casos, os estudos também usufruem de ferramentas estatísticas mais convencionais. Por meio da estatística espacial Getis-Ord Gi\*, Malleson e Andresen (2016) indicaram a localização de *clusters* das taxas de furtos pela população ambiental e pela residencial. Encontrou-se áreas significativas para ambas as taxas (áreas predominantemente residenciais, mas com uma gama de amenidades) e apenas para a ambiental (áreas residenciais com locais que estimulam crimes, mas que não atraem grande volume de pessoas).

Pereira e Mota (2017b) analisaram a significância da redução de homicídios em Recife entre os anos de 2009 e 2013, com base no Teste de padrão de pontos espaciais. Os homicídios diminuíram quase no mesmo grau que a concentração deles ao nível de segmentos de rua aumentou, com a densidade de homicídios permanecendo a mesma. Aliás, cerca de 40% dos segmentos de rua que tiveram homicídios em 2009 não os tiveram mais em 2013. Segundo Pereira, Andresen e Mota (2016), no Recife, a diferença nos índices de homicídios é significativa apenas entre dias da semana e períodos do dia. Também se notou, mediante o Teste de padrão espacial, uma similaridade nos padrões espaciais de homicídios entre os meses e entre alguns dias da semana.

Em estudo semelhante a Pereira e Mota (2017b), Andresen, Linning e Malleson (2017) examinaram os crimes contra o patrimônio em Vancouver, Canadá. Observou-se que estes eventos estão altamente concentrados em cerca de 5% dos segmentos de ruas e cruzamentos (em 2013), variando com o tipo de crime.

Ademais, houve estabilidade espacial desse padrão entre os anos de 2003 e 2013 (inclusive nos segmentos e cruzamentos sem registros criminais). Análise similar ocorreu na cidade de Florianópolis referente a padrões espaço-temporais de homicídios e roubos em vias públicas (VALENTE, 2019). Ambos os tipos de crime apresentaram alta concentração, ocorrendo entre apenas 0,4% a 1,3% dos segmentos de rua; é um padrão estável no tempo em quantidade, mas não quanto aos locais de ocorrência.

Além da evolução espaço-temporal dos crimes, publicações se preocupam com as características da região de estudo que favorecem a ocorrência destes eventos. Cada modalidade de crime representa padrões próprios no mosaico urbano, sendo que a diversidade e a concentração de instalações provocam diferentes padrões de rotina e de movimentação de pessoas (KINNEY et al., 2008). Numa meta-análise de múltiplas teorias criminológicas, Pratt e Cullen (2005) ressaltaram como preditores fortes e estáveis o desemprego, a privação econômica, a ruptura familiar e a heterogeneidade racial. Pesquisas recentes corroboram com esse resultado, indicando a fortemente associação dos crimes patrimoniais com a heterogeneidade racial, a pobreza e a renda média (ENGELEN; LANDER; VAN ESSEN, 2016).

Hanaoka (2018) reparou que, no Japão, a população ambiental (pessoas que frequentam o local) afeta fortemente os crimes de “furtar e correr”, com efeitos distintos entre o dia e a noite. Por sua vez, Hipp e Kim (2019) analisaram a relação dos roubos com fatores ambientais, ao nível de segmentos de rua e áreas vizinhas, no sul da Califórnia. O risco de roubo é elevado, aos finais de semana, em um segmento com forte presença do varejo durante o dia, e em segmentos com muitos restaurantes no início da noite. Além disso, a presença de comércio e restaurantes nas áreas vizinhas trouxe um elevado risco à tarde e à noite.

Usando um modelo bayesiano espaço-temporal, Quick, Law e Li (2019) constataram que em Waterloo, Canadá, os parques estão mais positivamente associados aos crimes patrimoniais durante a primavera e o verão, e os estabelecimentos de alimentação e bebidas estão mais positivamente associados durante o outono e o inverno. Observou-se também que o ambiente construído tem um impacto mais espacial do que espaço-temporal sobre os padrões criminais.

A temperatura é fator recorrente em modelos preditivos criminais. Na cidade da Filadélfia, EUA, os crimes violentos e condutas desordeiras atingem índices maiores quando a temperatura está em níveis confortáveis, especialmente durante os meses

frios (SCHINASI; HAMRA, 2017). Identificou-se que a temperatura ambiente diária é linearmente relacionada com a taxa de homicídio doloso em algumas cidades dos Estados Unidos (XU et al., 2020) e na África do Sul (GATES et al., 2019).

Tendo em vista o escopo do presente estudo, construiu-se o Quadro 2 para evidenciar preditores de crimes contra o patrimônio em modelos estatísticos recentemente publicados. Os fatores preditivos foram extraídos após a parcimônia ser atingida, pois alguns trabalhos lidam inicialmente com um número elevado de variáveis (30 ou mais, por exemplo) que nem sempre possuem relação significativa com os crimes. A perspectiva espacial do problema foi bastante incorporada aos modelos, com o predomínio de métodos de regressão que abordam a heterogeneidade espacial dos preditores (como o GWR). Apesar do nível espacial das análises ter variado conforme os dados disponíveis, houve leve destaque para a investigação por bairros.

Quanto aos tipos de atributo dispostos no Quadro 2, é evidente que os artigos conseguem tanto trabalhá-los exclusivamente quanto em sinergia no modelo preditivo, o que reflete a ausência de impedimentos para a análise conjunta. Em relação à questão demográfica e socioeconômica, destacam-se variáveis derivadas da renda domiciliar, nível de educação, faixas etárias, tamanho da população residente e diversidade racial. A respeito do ambiente construído, há uma ampla variedade de instalações e elementos espaciais cujo papel é representar a dinâmica comercial e de movimentação de pessoas na região de estudo.

Alguns dos artigos do Quadro 2 investigaram a ocorrência de roubos em modelos exclusivos (PERSAD, 2020; FENG et al., 2019; CONNEALY; PIZA, 2019; HABERMAN; KELSAY, 2021; CECCATO; MOREIRA, 2021; EJIOGU, 2020; ADEYEMI et al., 2021; SILVA; LI, 2020). É válido ressaltar as associações desses crimes com as características da região que atraem os criminosos, pois isto contribui para o desenvolvimento de políticas públicas condizentes com o contexto local.

Persad (2020) constatou que os bairros com maior média de roubos em Toronto, Canadá, estão associados a um maior volume de negócios, e a menores níveis de escolaridade e renda familiar. Na Nigéria, os roubos possuem relação negativa com a taxa de desemprego, e positiva com a renda nacional bruta e o percentual de população masculina (ADEYEMI et al., 2021).

A mobilidade geográfica, as barbearias, as instalações de pagamento de cheques, casas de penhores (durante o dia) e as lojas de bebidas em locais

adjacentes propiciam o aumento nos roubos em Downtown Houston, EUA (EJIOGU, 2020). Nas áreas vizinhas ao metrô da cidade de São Paulo, tende-se a haver mais roubos quando a renda domiciliar é baixa e há uma quantidade maior de paradas de ônibus e áreas comerciais (CECCATO; MOREIRA, 2021).

Os roubos na cidade de Cincinnati, EUA, tendem a diminuir com o aumento na inclinação dos quarteirões e a aumentar com a presença de algumas instalações (hotéis, lojas cotidianas, centros de recreação, pontos de ônibus e espaços de gangues) (HABERMAN, KELSAY, 2021). Na cidade de Nova York, EUA, a presença de bares, mercearias, restaurantes e varejo de bebidas favorecem a chance de haver roubos de rua (FENG et al., 2019).

Dentre alguns tipos de roubos (a negócios, automóveis, residenciais e na rua) na cidade de Denver, Colorado, EUA, destacou-se a elevação do risco de roubos conforme a existência de farmácias, restaurantes, supermercados, lojas de conveniência e imóveis hipotecados (CONNEALY; PIZA, 2019). Na cidade de Praia, Cabo Verde, houve associação negativa dos roubos com o percentual de espaços públicos abertos, o tamanho médio das bordas das ruas, a complexidade da malha viária e a taxa de desemprego (SILVA; LI, 2020).

### **3.2.2 Estudos criminais durante a pandemia**

A pandemia de COVID-19 propiciou o surgimento de padrões criminais diferenciados. Além da situação social única vivenciada, as medidas restritivas alteraram as atividades de rotina e a circulação das pessoas nas ruas (NIVETTE et al., 2021). Os estudos nesta linha são majoritariamente de ordem estatística, cuja preocupação principal é a variação na quantidade de crimes ao longo dos diferentes estágios da pandemia em comparação a períodos passados.

Em um estudo em cidades de 23 países, Nivette et al. (2021) perceberam uma redução de cerca de 50% em roubos e furtos com a desaceleração da atividade urbana, enquanto os homicídios diminuíram apenas 14%. Segundo os autores, este fato decorre do menor número de vítimas em potencial para crimes de oportunidade em espaços públicos adequados, como áreas de elevada concentração de lojas e locais de entretenimento. Ainda segundo Nivette et al. (2021), limitações mais rigorosas para permanecer em casa estavam associadas a quedas mais fortes nos níveis de criminalidade.

Quadro 2 - Modelos preditivos para crimes contra o patrimônio

Autores	Escala espacial	Método	Preditores	
			Demográficos e socioeconômicos	Ambiente construído
Carter et al. (2020)	Bloco censitário	GWR	Renda domiciliar média, propriedade do domicílio	Propriedades comerciais
Persad (2020)	Bairro	Poisson-based spatial regression	% de população com credenciais educacionais elevadas, renda domiciliar média	Densidade de negócios por km <sup>2</sup>
Chen et al. (2020)	Área de gestão da delegacia	Geographically Weighted Negative Binomial (or Poisson) Regression	% de residências com área igual ou superior a 120 m <sup>2</sup> , % de residentes em imóvel alugado, % pessoas acima de 60 anos, fluxo de pessoas de outra província	Densidade de paradas de ônibus
Cowen, Louderback e Roy (2019)	Bloco censitário	OLS, GWR	-	Distância do transporte público e de ciclovias, densidade de interseções de ruas, acesso a amenidades, uso do território diverso, % área construída não- residencial, % casa unifamiliar
Feng et al. (2019)	Metade de um bloco censitário	Risk Terrain Modeling	-	Locais que vendem bebida alcoólica: varejo, farmácia, mercearia, bar, clube, restaurante, hotel, entre outros
Connealy e Piza (2019)	Grids de 250 x 250 pés	Risk Terrain Modeling	-	Varejo de maconha, escola, mercearia, farmácia, restaurante, loja de conveniência, motel, imóvel hipotecado, hotel, boate, bar, arte pública
Gulma et al. (2019)	Bairro	OLS	Jovens, pais solteiros, minoria étnica, população economicamente inativa entre 16 e 64 anos, pessoas sem qualificação acima dos 16 anos de idade, residentes há menos de 2 anos	-

Haberman e Kelsay (2021)	Quarteirão	Negative Binomial regression	Mobilidade residencial, heterogeneidade racial, população, % residentes vivendo na pobreza	Inclinação do quarteirão, <i>betweenness</i> , locais para alimentação, para bebidas e para entretenimento, hotel, varejo, mercearia, parque, parada de ônibus, escola de ensino médio e de ensino superior, espaço de gangues
Ceccato e Moreira (2021)	Estação de metrô e áreas vizinhas no raio de 150m	Negative Binomial regression	Renda média per capita, homens jovens, passageiros por ano por estação	Câmeras de segurança na estação, tipo de estação (final, transitória, central), área verde, estacionamento, parada de ônibus, área comercial, escola
Ejiogu (2020)	Bairro	Generalized linear simultaneous negative binomial regression	População total, privação concentrada da população, heterogeneidade racial	Lojas comerciais em geral, casa de penhores, loja de bebidas, barbearias, lojas de conversão de cheque em dinheiro, mobilidade geográfica
Adeyemi et al. (2021)	Estado	Besag-York-Mollier Poisson model using conditional autoregressive priors	Taxa de desemprego, densidade populacional, índice educacional, renda nacional bruta per capita, % população masculina, população de 18 a 35 anos, estrutura de policiamento	-
Tavares e Costa (2021)	Município	Global Poisson model, Geographically Weighted Poisson Regression, semi-parametric Geographically Weighted Poisson Regression	População jovem, taxas de retenção e abandono na educação básica, % população com idade correspondente ao nível de ensino, residências convencionais, beneficiários de programa de proteção social, poder de compra per capita, taxa de desemprego e população de estrangeiros	-
Andresen e Hodgkinson (2018)	Área de disseminação	Risk Terrain Modeling	Número de residências, % imigrantes recentes, % minorias visíveis,	-

			taxa de desemprego, valor médio das residências, residências bifamiliares, penhores, % locais necessitando grandes reparos, residências de segunda mão	
Silva e Li (2020)	Bairro	Spearman correlation, OLS	Taxa de desemprego, % famílias com posse e uso de certos bens e serviços, % famílias com baixa renda	Indicador ambiental urbano (densidade de nós de rodovias, densidade da superfície de estradas, % de espaços abertos, complexidade da rede de rodovias, tamanho médio das bordas da rua), % de divisas sem barreiras naturais

Fonte: O autor (2022)

Nos primeiros meses da pandemia (março a julho de 2020) na cidade de Nova York, os índices de homicídios e de arrombamentos não variaram significativamente. Houve, contudo, um aumento no roubo de automóveis e na violência armada em paralelo à queda nos furtos, estupros, agressões graves e crimes de trânsito (ESPOSITO; KING, 2021). Entre março e maio de 2020, na Suécia, houve queda nos furtos e agressões (além da redução nos arrombamentos), enquanto os índices de roubos e crimes de narcóticos ficaram inalterados (GERELL; KARDELL; KINDGREN, 2020). Na cidade de Detroit, em março de 2020, o *lockdown* fez crescer os arrombamentos em áreas de uso territorial misto, mas não naquelas de uso residencial (FELSON; JIANG; XU, 2020). Numa região com 1,5 milhão de habitantes no Reino Unido, o período pós-*lockdown* de março de 2020 levou à queda significativa de todos os tipos de crime, especialmente furtos a lojas e roubos (HALFORD et al., 2020).

A maioria das categorias de crimes reduziu significativamente na Cidade do México após o decreto da pandemia ou um *lockdown* ter sido instituído, com exceção de crimes violentos, até maio de 2020 (ESTÉVEZ-SOTO, 2021). Essa estabilidade em crimes violentos (como homicídios) também ocorreu em 25 grandes cidades dos EUA (ABRAMS, 2021) e nas cidades de Chicago, Baltimore e Baton Rouge (SCOTT; GROSS, 2021), sendo que em todas aconteceu uma queda acentuada dos crimes patrimoniais. Nas cidades de Los Angeles e Indianápolis, entre janeiro e abril de 2020 (contendo um *lockdown* de 15 dias), houve declínio nos

roubos residenciais junto à um aumento em roubos de automóveis e nas chamadas delatando violência doméstica (MOHLER et al., 2020). Lopez e Rosenfeld (2021) revelaram que, em grandes cidades dos EUA até dezembro de 2020, houve diminuições significativas nas taxas de agressão grave, roubo e furto, o que está associado à mobilidade residencial reduzida durante a pandemia.

No México, ao nível de municípios até outubro de 2020, os crimes convencionais (agressão física, crime patrimonial e fraude) diminuíram com o *lockdown*, mas tenderam aos níveis pré-pandêmicos quando ele terminou (BALMORI DE LA MIYAR; HOEHN-VELASCO; SILVERIO-MURILLO, 2021). Os crimes tiveram maior redução em municípios mais populosos, enquanto a taxa de desemprego não mostrou influência nisso. Os autores notaram que os homicídios e crimes relacionados a drogas não tiveram mudança substancial.

Na cidade de Buenos Aires, Argentina, o *lockdown* provocou uma queda substancial nos crimes patrimoniais, mas não afetou a taxa de homicídios. A diminuição da atividade criminosa (roubos, furtos e arrombamentos) foi maior nas áreas de negócios e de transporte, mas ainda significativa nas áreas comerciais e residenciais. Após a queda abrupta e imediata, os índices criminais se recuperaram gradualmente conforme o relaxamento das restrições de mobilidade, mas até o final de 2020 os patamares pré-pandêmicos ainda não haviam sido atingidos (PEREZ-VINCENT; SCHARGRODSKY; MEJÍA, 2021).

Padrão similar ocorreu no estado de Queensland, Austrália, visto que até julho de 2020 houve uma diminuição significativa na maioria dos tipos de crimes (exceto relacionados a drogas), seguida por incrementos após o relaxamento das restrições de circulação (ANDRESEN; HODGKINSON, 2020). Segundo os autores, isto reforça o que foi previsto pelas teorias criminais de oportunidade (como a Teoria de Atividade de Rotina), mas não dá suporte à Teoria da Desorganização Social. Langton, Dixon e Farrell (2021) encontraram resultados condizentes na Inglaterra e País de Gales, onde houve uma queda drástica nos roubos e furtos em lojas nas áreas repletas de estabelecimentos comerciais, pontos de transporte público e atrações noturnas. Isto foi seguido por um ressurgimento gradual dos índices à medida que as regras de bloqueio foram relaxadas, porém ainda abaixo do verificado antes da pandemia.

A aplicação de estatística espacial em estudos criminais durante a pandemia teve foco na identificação de padrões. Segundo o estudo de pontos e *clusters*

espaciais de Yang et al. (2021), na cidade de Chicago houve uma mudança significativa na distribuição espaço-temporal dos crimes em 2020 em relação aos anos de 2016 a 2019 – especialmente furtos, espacamentos, arrombamentos e fraudes. Em análise de *clusters* espaciais realizada na cidade de São Paulo ao nível de bairros, examinou-se as 12 semanas anteriores e as 12 posteriores ao *lockdown* de 2020 (CECCATO et al., 2021). De modo geral, reduziram os arrombamentos residenciais e aumentaram nos não-residenciais, mas os homicídios permaneceram estáveis. A extensão dos *coldspots* de roubos de veículos aumentou e a dos *hotspots* diminuiu, devido à presença de ambientes que tiveram redução drástica de visitantes. Apesar da leve diminuição dos *hotspots* nas áreas mais carentes, as que eram grandes geradoras de crimes pré-pandemia não mudaram.

Algumas pesquisas se dedicaram ao estudo de variáveis explanatórias da ocorrência de crimes conforme o avanço da pandemia. Campedelli et al. (2021) encontraram, após medidas de distanciamento social e mediante modelos de regressão logística, uma associação positiva do tamanho da população e do estado de saúde geral dos residentes (no mínimo, bom) com a redução de roubos em Chicago. Por outro lado, áreas com menores percentual da população acima de 65 anos e diversidade de renda tendem a deter maior redução dos índices de roubos.

Hodgkinson et al. (2022) revelaram que, nas áreas socialmente desorganizadas da cidade de Saskatoon, Canadá, a maioria dos tipos de crimes aumentou com a vigência das medidas restritivas. Nas áreas onde os furtos aumentaram, os preditores significativos na regressão logística multinomial foram os percentuais de população de baixa renda e de imigrantes recentes. Onde os furtos reduziram, os percentuais de solteiros e de pais solteiros e a densidade populacional contribuíram positivamente para a predição (HODGKINSON et al., 2022).

Em uma análise comparativa dos artigos sobre crimes durante a pandemia, percebe-se a predominância em abordar a oscilação nas quantidades de diversos tipos de crimes conforme medidas governamentais restritivas foram implantadas. Os autores que tratam da questão espacial da criminalidade enfatizam apenas as mudanças na localização e na extensão dos *clusters*. Até então poucos estudos distinguiram detalhadamente as características locais que impactaram a ocorrência dos diferentes tipos de crime, assim como investigaram variações nestas relações ao longo dos diversos estágios da pandemia. Neste sentido, um estudo conduzido em uma realidade heterogênea brasileira apresenta valor substancial.

### 3.2.3 Abordagem MCDA e GIS-MCDA no contexto criminal

Outra abordagem matemática aplicada à segurança pública é a análise multicritério, a qual tem apoiado a tomada de decisão. Como aplicação mais recorrente tem-se a avaliação do desempenho da atividade policial. Dentre as problemáticas tratadas, a de ordenação se destaca. Ela foi usada para gerar rankings: de estratégias policiais no combate ao crime (BASILIO; PEREIRA; COSTA, 2019), de estados quanto ao desempenho policial (AGARWAL et al., 2019), de cidades em termos da eficiência e da efetividade da atuação dos departamentos de polícia (NEPOMUCENO; DARAIO; COSTA, 2021), de bairros quanto ao nível de segurança residencial (OLIVEIRA et al., 2018), e de áreas de segurança pública baseando-se no alcance de objetivos (BASILIO; PEREIRA, 2020). Vale salientar que os trabalhos mencionados acima, com exceção de Oliveira et al. (2018), adotam algum método de sobreclassificação.

A questão espacial é um fator fortemente presente e intrínseco aos estudos de segurança pública, porém a integração GIS-MCDA nesta área ainda é escassa. Os principais estudos são desenvolvidos no estado do Pernambuco, referindo-se à vulnerabilidade de áreas a ocorrências criminais com base em um conjunto de características locais de caráter demográfico, socioeconômico ou ambiental (FIGUEIREDO; MOTA, 2016; FIGUEIREDO; MOTA, 2019; ROSA et al., 2019; SOUZA et al., 2020a; MOTA; FIGUEIREDO; PEREIRA, 2021).

Figueiredo e Mota (2016) classificaram a cidade do Recife ao nível de unidades de desenvolvimento humano quanto à propensão à ocorrência de roubos, fazendo uso de fatores socioeconômicos no método holístico DRSA (*Dominance-based Rough Set Approach*). Os autores desenvolveram uma versão do DRSA para decisão em grupo a fim de classificar áreas quanto a vulnerabilidade a crimes violentos letais intencionais (FIGUEIREDO; MOTA, 2019). A técnica foi aplicada ao nível de grids em um bairro de Pernambuco, considerando renda, educação e população como critérios. Ambos os estudos usam o ambiente GIS a fim de que a visualização dos dados em mapas auxilie na elicitação de preferências do decisor.

Ferramentas estatísticas e espaciais têm sido inseridas ao GIS-MCDA na segurança pública com o propósito de auxiliar na construção do modelo e na exploração de padrões nos resultados (ROSA et al., 2019; SOUZA et al., 2020a; MOTA; FIGUEIREDO; PEREIRA, 2021). Em uma região do Recife, Rosa et al.

(2019) combinaram a seleção de critérios socioeconômicos e ambientais mediante técnicas de regressão espacial com a aplicação do método DRSA para analisar a suscetibilidade de setores censitários a roubos em vias públicas.

Mota, Figueiredo e Pereira (2021) identificaram áreas vulneráveis a homicídios em um bairro do Recife pelo método DRSA, seguido pela análise de *clusters* espaciais e *hotspots* a fim de identificar padrões no mapa de vulnerabilidade. Por fim, Souza et al. (2020a) desenvolveram um modelo decisório baseado no método de sobreclassificação FlowSort a fim de classificar setores censitários quanto à suscetibilidade a roubos e furtos. Neste processo foram integradas técnicas de regressão múltipla e densidade Kernel para explorar e selecionar os critérios.

O presente estudo utiliza a abordagem GIS-MCDA para classificar setores censitários quanto a vulnerabilidade a roubos, com o suporte de técnicas estatísticas e espaciais. Contudo, diferencia-se pela estruturação do modelo. Em uma fase inicial, os dados criminais são explorados mediante *clusters* espaciais e as características das áreas mais afetadas são compreendidas pela análise de quintis. Então investigam-se os potenciais critérios de vulnerabilidade durante o período pandêmico mediante técnicas de densidade espacial, correlação e regressão múltipla (sendo as duas últimas tanto na versão da estatística clássica quanto da espacial). Por fim, um modelo multicritério é construído com base na estruturação de critérios via literatura criminal, análise fatorial e combinação ponderada de mapas. Os resultados obtidos durante o processo colaboraram com a elucidação das preferências do decisor.

### 3.3 Considerações do capítulo

O presente capítulo evidencia as principais abordagens utilizadas na investigação da propagação espaço-temporal da COVID-19 e da propensão de áreas a ocorrências de crimes. Modelos de ordem estatística, espacial e/ou multicritério relativos a estes temas foram elencados visando distinguir semelhanças e lacunas metodológicas.

Os estudos acerca da COVID-19 trouxeram diferentes perspectivas quanto aos fatores que influenciam a disseminação da doença e aos locais onde as taxas de casos e óbitos se concentram. Conforme o esperado, os padrões e a associação entre os preditores e a evolução da doença variaram conforme a região de estudo, a

escala espacial e a fase da pandemia. No Brasil, entende-se que a parcela da população mais socialmente vulnerável está mais exposta ao vírus. Propõe-se, então, explorar como a COVID-19 progrediu na cidade do Recife, considerando os serviços que permaneceram abertos mesmo durante a quarentena mais rígida.

A respeito dos estudos criminais, obteve-se os principais preditores e técnicas encontrados em modelos preditivos. Constatou-se que a análise multivariada é vastamente aplicada, com destaque para a regressão múltipla e os ajustes nela para incorporar a questão espacial. Fatores explicativos de diferentes origens (georreferenciadas, censitárias, entre outras) podem ser tratados em conjunto nos modelos, trazendo benefícios por sinergia. Por fim, não há um consenso quanto à relação entre grande parte dos fatores encontrados e a ocorrência dos crimes, tendo em vista que isso presumivelmente varia conforme o contexto local.

O estudo do impacto da pandemia sobre os crimes se concentrou na significância da evolução dos índices criminais conforme a vigência de medidas restritivas. Houve praticamente um consenso de que os crimes contra a pessoa se mantiveram estáveis, enquanto os contra o patrimônio foram bastante sensíveis às restrições de circulação de pessoas. Contudo, poucos trabalhos exploraram fatores descritivos locais associados a essas variações, especialmente em um contexto de ambientes heterogêneos como se verifica nos países em desenvolvimento.

A abordagem GIS-MCDA mostrou-se adequada para gerar recomendações ao decisior considerando as preferências dele relativa a múltiplos critérios e alternativas, em um contexto com elementos espaciais. Dentre os estudos criminais, o problema da avaliação de vulnerabilidade de áreas à ocorrência de crimes é um segmento de pesquisa consolidado. Uma contribuição recente aos modelos é a inserção de ferramentas estatísticas e espaciais durante o processo decisório para construir parâmetros e fornecer informações complementares sobre o alvo do estudo ao decisior. Neste sentido, há possibilidades de pesquisa sobre essas combinações metodológicas, especialmente em um contexto de pandemia.

#### 4 METODOLOGIA

O presente estudo emprega o método científico dedutivo (GIL, 2008), pois se pretende investigar como a vulnerabilidade a roubos se apresenta em uma região do Recife com base nas teorias criminais. A pesquisa possui finalidade aplicada (GIL, 2008) por empregar técnicas matemáticas consolidadas sem desenvolver teorias de valor universal. Tem-se um objetivo explicativo (GIL, 2002), pois explora a relação entre características locais e a vulnerabilidade a crimes. A natureza quantitativa (MARTINS, 2012) do trabalho deve-se ao uso predominante de ferramentas analíticas estruturadas, como métodos estatísticos, espaciais e multicritério.

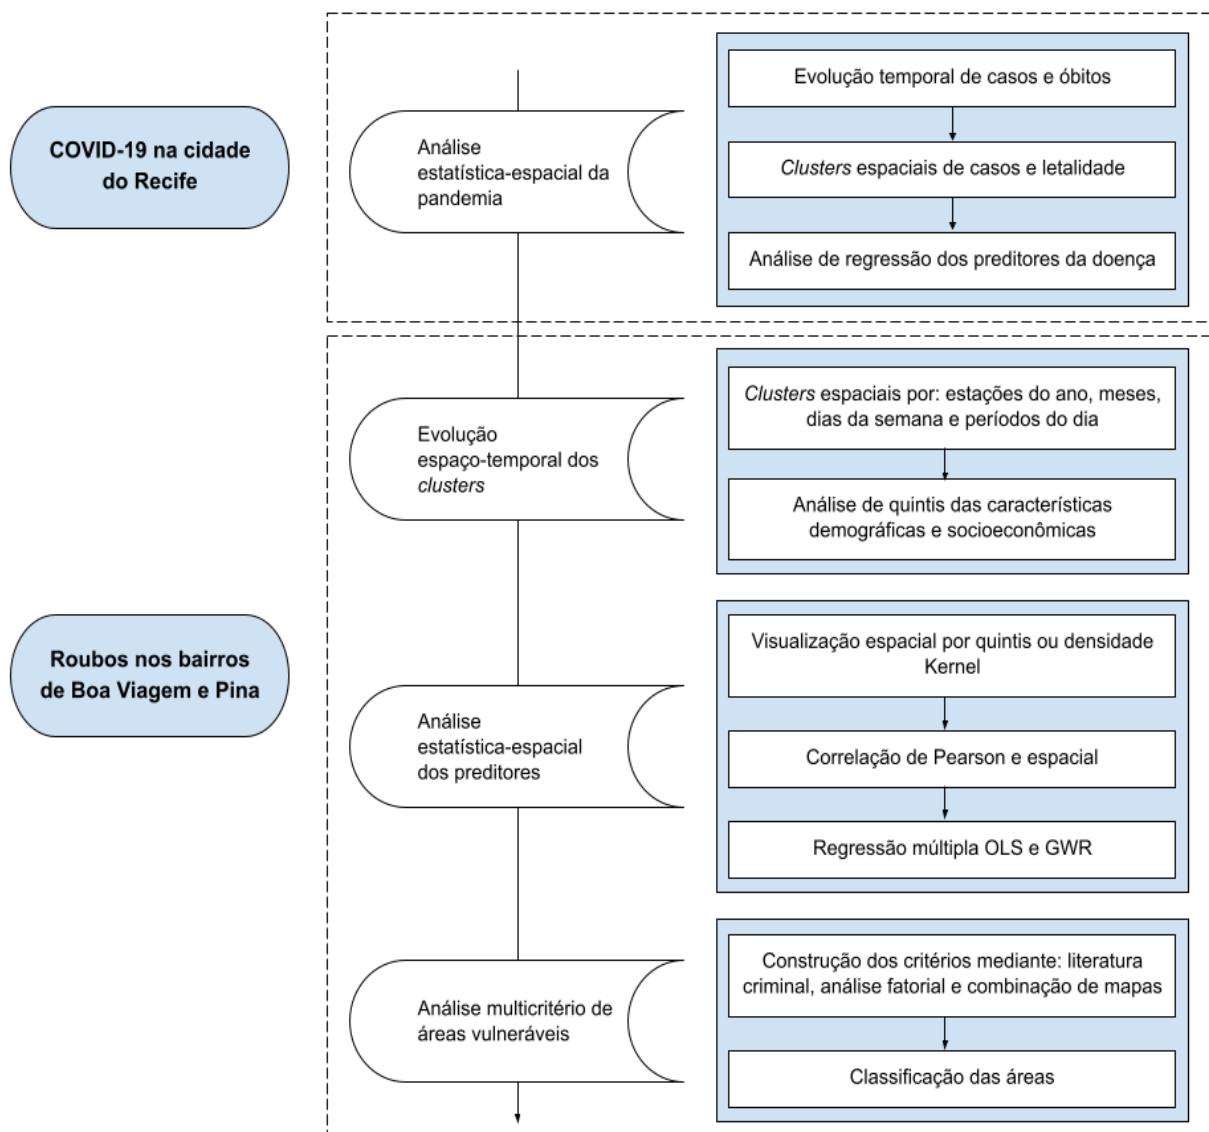
A exploração dos dados ocorre por meio de modelagem (MORABITO NETO; PUREZA, 2012) ao extrair de um problema real um modelo conceitual matemático. Adotou-se a documentação indireta por meio de fontes primárias e secundárias como técnica de pesquisa (GIL, 2002, 2008), visto que se exploram tanto dados georreferenciados e características da região de estudo quanto a literatura criminal para construção dos modelos.

A pesquisa busca identificar o patamar de vulnerabilidade a roubos de áreas localizadas em dois bairros do Recife, tendo em vista o contexto pandêmico. Esses locais apresentam um ambiente bastante favorável a este tipo de crime, devido à heterogeneidade socioeconômica (presença singular de locais desenvolvidos circundados por outros em situação diametralmente oposta) e à extensa quantidade e variedade de comércio local (geradores de oportunidades de roubos). Ademais, são locais que sofreram forte incidência de casos de COVID-19, especialmente nos primeiros meses da pandemia, o que afetou a rotina das pessoas e, consequentemente, a ocorrência de roubos. Assim, como apoio, os padrões distintivos da propagação espacial da COVID-19 na cidade do Recife foram examinados durante os estágios iniciais da pandemia.

Conforme disposto na Figura 2, a metodologia de pesquisa é dividida em duas macroetapas. A princípio explorou-se os casos confirmados e a taxa de letalidade por COVID-19 quanto à difusão espaço-temporal da doença e aos possíveis determinantes em Recife – ao nível de bairros. Então se buscou traçar um panorama comparativo da ocorrência de roubos nos bairros de Boa Viagem e Pina antes e após o início da pandemia. Um conjunto diversificado de fatores preditivos dos roubos, de ordem socioeconômica e ambiental, foram explorados por meio de

técnicas estatísticas e espaciais. Deste modo, almejou-se identificar aquelas que conseguem explicar melhor a ocorrência destes crimes, ao nível de setor censitário, em diferentes fases da pandemia. Por fim, modelos multicritério foram construídos a fim de investigar a vulnerabilidade das áreas dos dois bairros a roubos.

Figura 2 - Fluxo lógico da metodologia



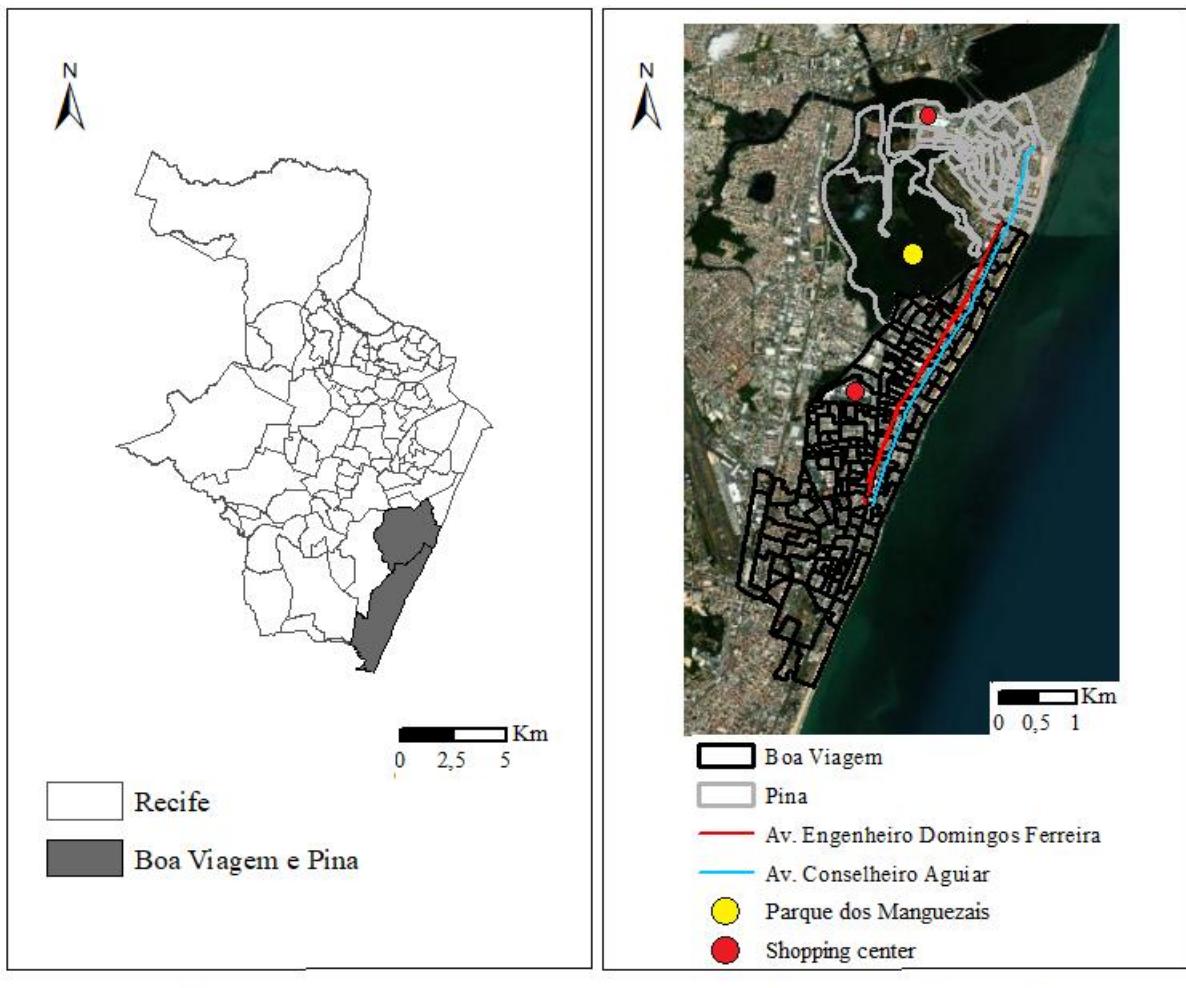
Fonte: O autor (2022)

A análise espacial foi executada nos softwares ArcGIS 10.5 e GeoDa 1.18. Por sua vez, os procedimentos estatísticos foram performados na plataforma R 3.6.1, enquanto o modelo multicritério fez uso do software MCDA-ULaval versão 0.6.

#### 4.1 Área de estudo

A cidade do Recife apresenta um papel de destaque no cenário nacional, sendo a escolhida para a exploração da disseminação espacial da COVID-19. Ela consiste na capital de Pernambuco, sendo este, em relação à região Nordeste, o terceiro estado mais populoso e com o maior PIB per capita. Com uma população estimada em 1,55 milhão de pessoas numa área de 218 km<sup>2</sup>, Recife é a segunda cidade pernambucana mais densamente povoada (IBGE, 2020). Em 2010, o município alcançou o maior Índice de Desenvolvimento Municipal (IDHM) dentre as capitais do Nordeste brasileiro (0,772) (SMS, 2014), abrangendo questões como longevidade, educação e renda. Por fim, em setembro de 2021, Recife deteve o metro quadrado mais caro (R\$ 6.412/m<sup>2</sup>) entre as capitais nordestinas (FIPERZAP, 2021). A Figura 3(a) apresenta a divisão da cidade em bairros.

Figura 3 - Área de estudo



Fonte: O autor (2022)

Por outro lado, Recife apresenta um padrão socioeconômico heterogêneo e desigual. Isto é comprovado pelo seu elevado índice de Gini, sendo o maior entre as capitais brasileiras no ano de 2019 (0,612) (SIS, 2020). A cidade possui duas localidades com desenvolvimento humano muito elevado, uma na zona norte e a outra na zona sul (a qual é predominada pelo bairro de Boa Viagem) (PEREIRA; MOTA, 2016). Em contrapartida, dois terços dos distritos do Recife possuem desenvolvimento humano médio ou baixo (PEREIRA; MOTA, 2016). Contudo, as discrepâncias em renda e provisão de serviços públicos não podem ser resumidas simplesmente à divisão da cidade por regiões. Existem diversos casos em que um bairro é circundado por outros com condições socioeconômicas opostas, embora estejam na mesma região (PEREIRA; MOTA, 2016). Além disso, alguns bairros considerados mais ricos também possuem áreas expressivas de moradia pouco privilegiada, como é o caso de Boa Viagem (FIGUEIREDO; MOTA, 2016).

Para os estudos relativos a roubos, a análise foi restringida aos bairros de Boa Viagem e Pina. O contexto local firma uma conexão entre os dois bairros não só pelos limites geográficos, como também pelo aspecto comercial e socioeconômico. Localizados na zona sul da cidade, eles se destacam pelo tamanho da população (cerca de 10% da cidade), pela elevada renda média domiciliar (R\$ 4.158) e pela diversidade de empreendimentos de alto padrão (IBGE, 2020). Em setembro de 2021, Boa Viagem apresentou o maior preço médio de venda de imóveis residenciais (R\$ 7.098/m<sup>2</sup>) e o terceiro em locação residencial (R\$ 39,1/m<sup>2</sup>), enquanto no ranking de locação o Pina teve o maior preço médio da cidade (R\$ 49,2/m<sup>2</sup>) (FIPEZAP, 2021). A Figura 3(b) apresenta o mapa da região e a sua divisão em 206 setores censitários, com uma imagem de satélite retirada da plataforma aberta OpenStreetMap.

A variância entre os fatores socioeconômicos locais (IBGE, 2016) evidencia o marcante contraste no interior desses bairros. Assim, nota-se como os residentes possuem condições financeiras e acesso a serviços públicos com larga diferença, embora estejam espacialmente próximos. Este tipo de padrão heterogêneo dá suporte ao que preconiza a Teoria da Desorganização Social (SHAW; MCKAY, 1942), logo é uma região mais propensa à ocorrência de crimes.

Além disso, a presença de uma população elevada e uma concentração de estabelecimentos comerciais diversificados tende a elevar o potencial de ocorrência de roubos nesses bairros. Isto se deve, de acordo com a Teoria da Escolha Racional

(COHEN; FELSON, 1979), à existência de mais oportunidades de alvo qualificado – o que aumenta o benefício do ato de roubar sob a perspectiva dos criminosos. Entretanto, recentemente o fluxo de pessoas nas ruas foi reduzido em alguns períodos devido a restrições sanitárias consequentes da pandemia de COVID-19. Ainda assim Boa Viagem e Pina estiveram entre as localidades com maior número de roubos neste período, tendo como base os dados georreferenciados providos pela Secretaria de Defesa Social de Pernambuco.

#### 4.2 Análise estatística-espacial da COVID-19

Esta macroetapa do estudo é parte integrante do trabalho desenvolvido por Souza et al. (2022). Conduz-se uma investigação espacial com o intuito de compreender o comportamento da pandemia de COVID-19 nos bairros da cidade do Recife. Para isto, combinou-se abordagens estatísticas (análises de correlação, quartis e regressão) com métodos espaciais (análise de *clusters* espaciais e regressão espacial) a fim de explorar características locais que refletem a suscetibilidade de áreas à propagação espacial da doença.

Os dados acerca do número de casos confirmados e mortes foram fornecidos pela Secretaria de Planejamento e Gestão do estado de Pernambuco (SEPLAG, 2022). Há registros diários em Recife ao nível de cidade, porém os dados que estão georreferenciados se referem apenas ao nível de bairros, na forma cumulativa, e entre 16 de abril e 3 de julho de 2020 (em intervalos de cerca de uma semana).

Os bairros foram caracterizados com base em 15 preditores demográficos e socioeconômicos obtidos do Censo 2010 (IBGE, 2016). Eles estão descritos no Quadro 3 e, ao longo do texto, são tratados como “indicadores censitários”. O conjunto de preditores foi expandido pela inclusão de seis serviços essenciais classificados pela Secretaria de Planejamento e Gestão do estado de Pernambuco (PHS, 2020), isto é, instalações que permaneceram abertas durante toda a pandemia. Estes serviços foram extraídos em modo georreferenciado do Google Maps mediante o software Google Map Extractor. A descrição espacial deles em forma de densidade Kernel (SILVERMAN, 1986) encontra-se no Quadro 4.

A evolução da COVID-19 na cidade de Recife como um todo foi inicialmente investigada. Considerou-se o período desde a confirmação do primeiro caso em março de 2020 até maio de 2021, para o qual histogramas foram elaborados com os

dados diários e o acumulado mensal de casos e mortes decorrentes da doença. Uma média móvel de 7 dias também foi inserida nos gráficos de evolução diária a fim de reduzir vieses inerentes aos dados devido à falta de testes e a atrasos no registro de casos e mortes (BUCKINGHAM-JEFFERY et al., 2017). Uma breve descrição das medidas restritivas promovidas pelos governos estadual e municipal neste período também foram apresentadas. Buscou-se, então, enriquecer as discussões acerca da rigidez delas e do avanço da doença.

Quadro 3 - Estatística descritiva dos indicadores censitários nos bairros do Recife

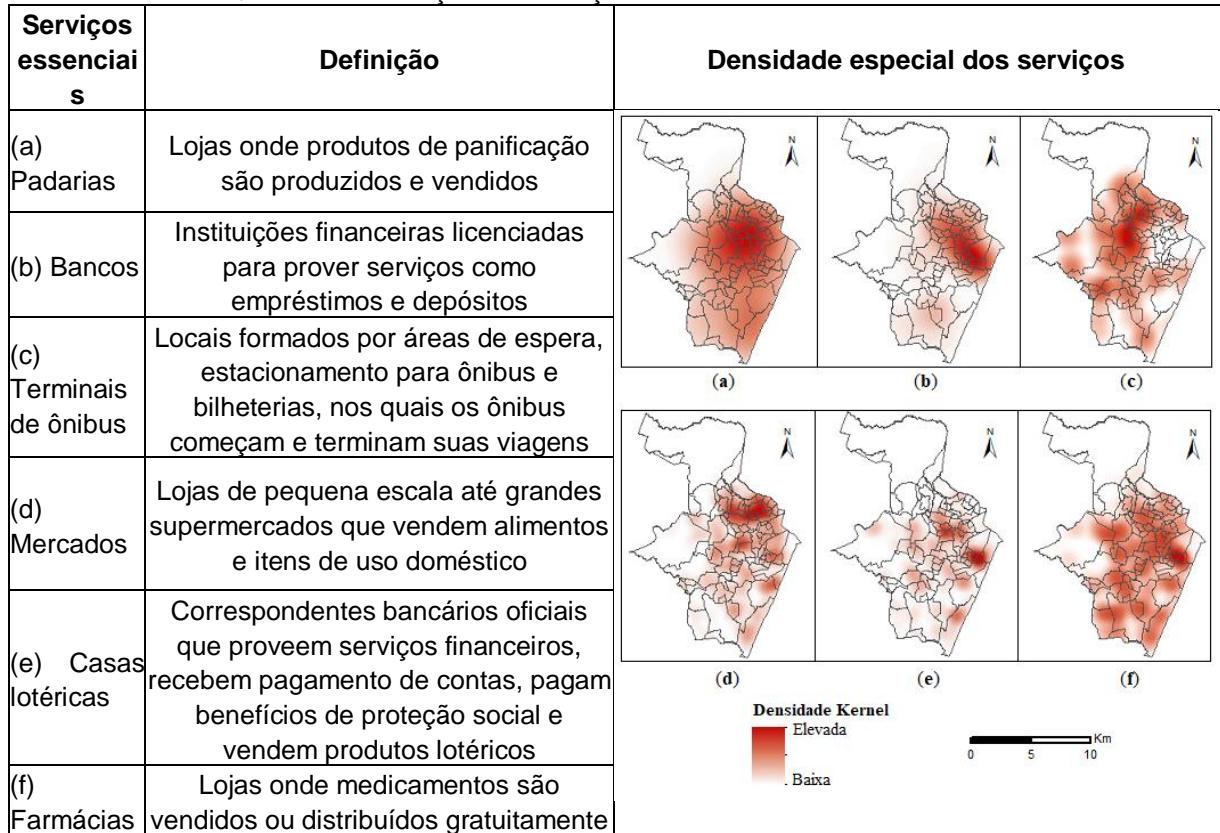
Indicador	Máximo	Mínimo	Média	Desvio-padrão	Definição
Renda (R\$)	10000,00	510,00	2054,50	2131,17	Renda média domiciliar dos residentes
População	122922	72	16358,55	18274,11	Total de residentes
RPD	4,5	1,73	3,25	0,30	Residentes por domicílio
Alfabetização (%)	0,9789	0,7159	0,8627	0,0533	Residentes alfabetizados acima de 6 anos de idade
Água encanada (%)	0,9954	0,1250	0,8367	0,1709	Domicílios com fornecimento de água encanada
Sistema de esgoto (%)	1,0000	0,0484	0,5628	0,2930	Domicílios com acesso à rede de esgotamento sanitário
Eletricidade (%)	1,0000	0,9226	0,9979	0,0080	Domicílios com fornecimento de energia elétrica
Coleta de lixo (%)	1,0000	0,7346	0,9755	0,0438	Domicílios atendidos por serviço de coleta de lixo
Domicílio próprio (%)	0,8687	0,4577	0,7268	0,0695	Domicílios adquiridos por seus residentes
Domicílio alugado (%)	0,5141	0,1111	0,2231	0,0648	Domicílios alugados por seus residentes
0 a 9 anos de idade	12149	6	2147,05	2306,98	Residentes divididos por faixa etária
10 a 19 anos de idade	15129	0	2613,43	2791,56	
20 a 39 anos de idade	41556	30	5649,29	6325,24	
40 a 59 anos de idade	33813	15	4015,44	4653,87	
Idade superior a 60 anos	20275	9	1933,23	2479,59	

Fonte: O autor (2022)

O recorte temporal de abril a julho de 2020 foi mais intensamente explorado nas etapas estatísticas posteriores devido ao interesse de investigar o impacto da quarentena mais rígida na disseminação da doença. Logo, foi apresentado um gráfico mais detalhado dos casos confirmados incluindo as intervenções do Governo

do Estado de Pernambuco e da Prefeitura Municipal do Recife instituídas até julho de 2020. Assim, pôde ser avaliado o impacto da severidade das medidas de restrição vigentes neste período, tais como: fechamento de atividades comerciais não-essenciais; uso obrigatório de máscaras; quarentena rígida; reabertura de armazéns de construção, salões de beleza, shopping centers, varejistas no subúrbio e locais de adoração (PHS, 2020).

Quadro 4 - Descrição dos serviços essenciais na cidade do Recife



Fonte: O autor (2022)

A propagação espacial da COVID-19 também foi apreciada em uma escala menor, especificamente bairros. Conduziu-se uma análise de *clusters* dos casos confirmados cumulativos e da taxa de letalidade (total de mortes dividido pelo total de casos) por meio da estatística Local Moran's I. Foram empregues dados georreferenciados ao nível de bairros no intervalo entre 16 de abril e 3 de julho de 2020. Deste período, considerou-se dez datas espaçadas em cerca de uma semana a fim de representar as fases de crescimento, pico e declínio das infecções.

Os *clusters* e *outliers* espaciais foram investigados visando compreender características locais que possam diferenciá-los. Deste modo, uma análise de quartis

foi aplicada aos indicadores censitários, assim como o teste de correlação de Spearman entre eles e a taxa de letalidade (visto que os casos serão explorados na análise de regressão). O conjunto complementar de preditores, os serviços essenciais, teve a sua relação com os casos e a letalidade explorada em gráficos de dispersão e pela correlação de Pearson (devido ao comportamento dos dados).

O caráter explanatório do estudo foi estendido mediante uma análise de regressão, tendo os casos acumulados de COVID-19 obtidos em 3 de julho de 2020 como variável resposta. A regressão OLS foi aplicada para destacar a força do relacionamento dos casos com as variáveis explicativas. De início, examinou-se os dois grupos de preditores (indicadores socioeconômicos e serviços essenciais) separadamente, com o propósito de não descartar relações relevantes devido à multicolinearidade. Assim, aplicou-se a OLS duas vezes, retirando as variáveis cujo VIF (fator de inflação de variância) fosse superior a 7,5, conforme adotado em outros estudos sobre COVID-19 (AL KINDI et al., 2021; HUANG et al., 2021). Dois modelos parcimoniosos (contendo um número reduzido de preditores) foram identificados por meio do método *stepwise* baseado na estatística AIC (*Akaike Information Criterion*).

A fim de considerar a sinergia entre eles os dois grupos de preditores, modelos que os combinam foram definidos por meio da regressão OLS. Desta vez, porém, foram novamente explorados os dados georreferenciados ao nível de bairros obtidos nas dez datas consideradas na análise de *clusters* espaciais. Assim, examinou-se a evolução do conjunto significativo de preditores ao passo que a pandemia evoluía no Recife e que as medidas governamentais entravam em vigor.

Adotou-se também a regressão espacial GWR visando explorar a natureza geoespacial dos casos de COVID-19 e de relaxar as suposições da OLS quanto à homogeneidade e à independência das observações dos termos de erro em toda a região de estudo (FISCHER; WANG, 2011). Os casos cumulativos em 3 de julho de 2020 foram tomados como variável dependente, enquanto o conjunto de preditores foi o mesmo usado no modelo parcimonioso da OLS nesta data. A função kernel escolhida pode variar conforme a densidade de infecções, enquanto a extensão do kernel foi definida automaticamente com base no critério AIC. O desempenho da OLS e da GWR foram comparados mediante as estatísticas AIC e  $R^2$  ajustado. Em seguida, analisou-se os  $R^2$  locais fornecidos pelo GWR para cada bairro, especialmente nos destacados como *clusters* High-High. Por fim, a estatística Global

Moran's I foi aplicada para checar a aleatoriedade da distribuição dos resíduos do modelo GWR no espaço (em caso afirmativo, o modelo espacial é adequado).

#### 4.3 Análise estatística-espacial-multicritério dos roubos

Esta macroetapa investiga a vulnerabilidade a roubos de áreas pertencentes a uma região da cidade do Recife, levando em consideração o contexto excepcional da pandemia de COVID-19. Para tanto, promoveu-se a combinação sinérgica de diferentes abordagens matemáticas: estatística, espacial e multicritério.

##### 4.3.1 Evolução espaço-temporal dos *clusters* de roubos

Os roubos foram impactados pela pandemia de COVID-19. Obteve-se, então, uma base de dados georreferenciados de crimes contra o patrimônio (neste caso, tratados como roubos) fornecidos pela Secretaria de Defesa Social de Pernambuco, abrangendo o período de 1º de janeiro de 2019 a 31 de maio de 2021. Averiguou-se como os *clusters* de roubos se comportaram nos bairros de Boa Viagem e Pina à medida que a pandemia evoluiu, comparando com o período anterior a ela.

Inicialmente usou-se um gráfico de barras para comparar os acumulados mensais em Boa Viagem e Pina, antes e durante a pandemia, buscando identificar mudanças significativas. Então foram apresentadas as quantidades de crimes por classificação. Como há um predomínio considerável de crimes contra os transeuntes em comparação aos demais, julgou-se não ser significativo avaliar *clusters* para cada tipo. Além disso, cerca de 10% das ocorrências não tinham classificação exata.

As ocorrências criminais georreferenciadas foram estruturadas nas seguintes divisões temporais: meses do ano, dias da semana, períodos do dia (madrugada, manhã, tarde e noite) e estações do ano. Os dados foram contabilizados por setor censitário. Assim, conduziu-se uma análise de *clusters* espaciais baseada na estatística Local Moran's I (ANSELIN, 1995). A comparação dos dados mensais deu-se entre janeiro de 2019 e maio de 2021. Já os *clusters* de dias da semana e de períodos do dia foram comparados entre dados de 2019 e dados agregados de parte do período pandêmico (11 de março de 2020 a 31 de maio de 2021). Por fim, os dados de estações de ano foram agregados por ano (2019, 2020 e 2021).

Buscou-se relacionar o impacto da fase da pandemia (com base na curva de casos de COVID-19) e as medidas restritivas vigentes com a flutuação dos *clusters* de roubos. Nas áreas com mudança significativa na posição dos *clusters*, explorou-se as características socioeconômicas locais por meio de análise de quintis no sentido de identificar padrões distintivos. Para isto, considerou-se um conjunto de 17 fatores demográficos e socioeconômicos obtidos do censo demográfico de 2010 ao nível de setor censitário (IBGE, 2016). A definição e a estatística descritiva destes estão no Quadro 5. Também denominados “indicadores censitários”, eles abrangem características da população residente sob o ponto de vista da renda domiciliar, educação, diversidade de cor ou raça, provisão de serviços públicos e faixa etária.

Quadro 5 - Estatística descritiva dos indicadores censitários nos bairros de Boa Viagem e Pina

Predictor	Máximo	Mínimo	Média	Desvio-padrão	Definição
denspop (hab/km <sup>2</sup> )	91984,60	231,74	24712,05	16146,22	Densidade populacional (total de residentes dividido pela área do setor censitário)
id_0_14	482	12	122,06	76,86	Residentes na faixa etária de 0 a 14 anos de idade
id_15_65	1476	57	539,45	221,88	Residentes na faixa etária de 15 a 65 anos de idade. População economicamente ativa
id_66_	234	5	74,37	42,31	Residentes na faixa etária igual ou superior a 66 anos de idade
branco	1314	46	448,21	213,80	Residentes autodeclarados brancos
pardo	1059	12	244,81	172,95	Residentes autodeclarados pardos
preto	218	2	34,20	39,99	Residentes autodeclarados pretos
alfab	1708	75	666,96	271,13	Residentes alfabetizados acima de 6 anos de idade
renda	8338,22	198,3	2375,11	1441,37	Renda média domiciliar dos residentes
var_renda	1,19x10 <sup>9</sup>	4,2x10 <sup>4</sup>	3,5x10 <sup>6</sup>	1,24x10 <sup>8</sup>	Variância da renda média domiciliar dos residentes
lixo	2038	78	724,62	306,83	Domicílios atendidos por serviço de coleta de lixo
agua	1758	13	613,84	304,94	Domicílios atendidos por serviço de água encanada
esgoto	1806	5	548,06	298,78	Domicílios sem esgoto a céu aberto
pavim	543	0	209,40	118,73	Domicílios atendidos por serviço de pavimentação
ilumpub	699	0	281,71	154,64	Domicílios atendidos por serviço de iluminação pública
dom_alug	615	2	179,74	88,10	Domicílios alugados
dom_prop	1736	3	521,70	245,36	Domicílios próprios

Fonte: O autor (2022)

Ademais, a região de estudo (Figura 3(b)) contém alguns elementos espaciais que precisam ser discutidos, visto que podem impactar no fluxo de pessoas para fins comerciais. Existem dois shopping centers de grande porte, os quais atraem um volume elevado de pessoas sob a expectativa de maior segurança e variedade de serviços, por exemplo. Porém, eles são vizinhos imediatos de localidades menos favorecidas. Boa Viagem e Pina são banhados pelo mar – o que é um forte atrativo para turistas –, bem como possuem uma extensa área coberta por mangues.

Destacam-se também duas avenidas (Conselheiro Aguiar e Domingos Ferreira) paralelas e com sentido de trânsito oposto entre si que estão localizadas próximas à praia. Elas são relevantes não só pela longa extensão, mas principalmente pelo elevado fluxo de trânsito e pela quantidade significativa de lojas. Por fim, parte da região de estudo faz fronteira com bairros com condições socioeconômicas precárias a sudoeste, especificamente Jordão e Ibura, os quais apresentam nível de desenvolvimento humano baixo (PEREIRA; MOTA, 2016). Logo, os setores censitários próximos a eles serão analisados.

#### **4.3.2 Análise estatística-espacial dos fatores preditivos de roubos**

Esta etapa do estudo serviu de preparação e embasamento sobre o problema dos roubos para a construção de um modelo multicritério. A ocorrência de roubos está associada com características da região de interesse que tornam estes ambientes mais atrativos à prática criminal. Deste modo, buscou-se examinar amplamente a relação entre as ocorrências de crimes ao longo da pandemia e um grupo diversificado de variáveis explanatórias por meio de técnicas estatísticas e espaciais envolvendo correlação, regressão linear múltipla e visualização espacial.

Neste sentido, agregou-se um conjunto de 37 fatores explicativos que caracterizam os bairros de Boa Viagem e Pina. Destes, 17 formam uma base de dados composta pelos indicadores censitários tratados no Quadro 5. Por sua vez, o segundo grupo é constituído pelos 20 fatores restantes, que representam estabelecimentos comerciais georreferenciados com finalidades diversas como lojas de produtos e instituições de ensino. A presença deles contribui para a circulação de pessoas portando bens com valor agregado (sob o ponto de vista dos criminosos), logo há incremento de alvos em potencial para roubos. Estas variáveis foram obtidas na plataforma Google Earth em agosto de 2021 e estão expostas no Quadro 6.

Quadro 6 - Descrição das instalações comerciais nos bairros de Boa Viagem e Pina

Estabelecimento	Total	Definição
Academia	78	Locais para prática desportiva e ginástica, incluindo crossfit e artes marciais
Adoração	118	Locais sagrados para serviços religiosos, incluindo igrejas, templos, centros espíritas e sinagogas
Banco	44	Instituições financeiras licenciadas para prover serviços como empréstimos e depósitos; limita-se às agências bancárias
Bar	309	Locais que servem bebidas alcoólicas, petiscos e/ou refeições com opção de consumo no próprio ambiente; inclui restaurantes e <i>fast-foods</i>
Cafedoceso	107	Locais para encontro casual que servem petiscos e lanches, sem enfoque em bebidas alcoólicas; inclui cafeterias, docerias e sorveterias
Cuiddomest	119	Lojas de produtos para cuidados domésticos; inclui moveleiras, armazéns de construção e lojas de artigos domésticos
Cuidpessoas	234	Lojas de produtos para cuidados pessoais; inclui lojas de roupas, cosméticos, esportes, suplementos e produtos naturais
Escola	84	Estabelecimentos de ensino básico (da educação infantil ao ensino médio)
Fac.curso	120	Estabelecimentos de ensino superior ou complementar; inclui faculdades, escolas de idiomas, cursos técnicos e preparatórios
Farmacia	96	Lojas onde medicamentos são vendidos ou distribuídos gratuitamente
Hotel	98	Estabelecimentos que alugam acomodações para viajantes; inclui hotéis, pousadas, <i>hostels</i> e resorts
Informatic	101	Lojas que vendem artigos de informática e/ou prestam serviços de manutenção
Loterica24	25	Locais alternativos à agência bancária para saques e pagamentos de contas; inclui casas lotéricas e unidades de Banco 24 horas
Mercado	81	Lojas de pequena escala até grandes supermercados que vendem alimentos e itens de uso doméstico; inclui mercearias, mercadinhos, hortifrutis e supermercados
Oficina	82	Locais para manutenção de veículos automotores; inclui oficinas mecânica e elétrica, borracharias e martelinhos de ouro
Padaria	68	Lojas onde produtos de panificação são produzidos e vendidos
Petshop	58	Lojas que vendem produtos e prestam serviços voltados a animais domésticos
Postog	37	Postos de gasolina; locais que vendem combustíveis para veículos automotores
Salaob	390	Salões de beleza; locais para tratamento de beleza, incluindo salões de cabeleireiro e barbearias
Saude	442	Unidades para tratamentos de saúde; inclui clínicas, ambulatórios, laboratórios, consultórios, posto de saúde e hospitais

Fonte: O autor (2022)

A investigação estatística ocorreu de forma isolada entre os grupos de dados de condicionantes, de modo que se consiga explorar as conexões relevantes entre as variáveis sem eventuais descartes precoces. De início, os fatores foram

representados em mapas a fim de verificar visualmente a distribuição deles na região de estudo e levantar padrões ambientais prévios. Para os indicadores censitários adotou-se a categorização em quintis, enquanto as instalações georreferenciadas foram ilustradas por meio da densidade Kernel (SILVERMAN, 1986). Então prosseguiu-se com a análise entre pares de condicionantes pertencentes a uma mesma base de dados originária. Por meio do coeficiente de correlação de Pearson, foram identificadas a relevância estatística, a força e a direção do relacionamento linear entre eles. Visando a posterior análise multicritério, isto contribui para construir combinações e gerar critérios de avaliação.

O presente trabalho enfatiza fortemente a distribuição espacial dos roubos. No contexto pandêmico, faz-se necessário representar como os diferentes estágios da propagação da COVID-19 impactaram nesses eventos criminais. Definiu-se como alvo da análise, então, um conjunto de 5 meses no intervalo entre o decreto da pandemia (março de 2020) e o limite de disponibilidade de dados criminais (maio de 2021). A seleção foi baseada na evidente tendência de crescimento, pico ou vale nas curvas de casos e óbitos por COVID-19, seja em relação à média móvel de 7 dias ou ao acumulado mensal destes. Os acumulados de roubos em cada mês foram explorados quanto aos fatores preditivos por meio de técnicas de correlação espacial, regressão *Ordinary Least Squares* (OLS) e regressão espacial.

Considerando os 5 meses selecionados, investigou-se a correlação espacial pareada entre os 37 preditores e as ocorrências de roubos utilizando a quantidade mensal deles por setor censitário. Assim, com o uso da estatística Global Moran's I bivariada (LEE, 2001) foi mensurada a associação espacial linear de cada variável com a ocorrência de roubos ao longo de toda a região de estudo (Boa Viagem e Pina). A matriz de pesos foi construída como uma matriz contiguidade rainha, ou seja, o peso em uma área foi influenciado apenas pelos vizinhos imediatos (compartilhando uma aresta e/ou vértice). O pseudo valor-p do teste de hipóteses para cada estatística foi calculado com base em 99999 iterações.

Uma análise multivariada foi conduzida a fim de compreender o efeito conjunto das variáveis explicativas sobre os eventos criminais, levando em conta a interação entre elas. Para este fim, empregou-se a regressão múltipla OLS em cada banco de dados (oriundos do IBGE e do Google Earth), adotando como variável dependente a quantidade mensal de roubos por setor censitário nos 5 meses definidos anteriormente. No total, foram construídos 10 modelos.

Buscou-se atender ao princípio da parcimônia de Occam (NISBET, 2018) nos modelos de regressão por meio da retirada de preditores altamente correlacionados. Para isto, foi calculado o fator de inflação de variância (VIF) para cada preditor e aqueles de VIF superior a 7,5 - conforme empregado em outros estudos criminais (ZHANG; MCCORD, 2014; WANG; LEE; WILLIAM, 2019; SILVA et al., 2020) – foram excluídos do modelo, um a um. A cada possível retirada, era executado um teste de razão de verossimilhança entre o modelo inicial e o reduzido para evitar a eliminação de variáveis relevantes à predição. A análise era concluída com o método de seleção de variáveis *stepwise* baseado na estatística AIC, resultando em um modelo parcimonioso e com capacidade preditiva próxima à original.

Como estamos lidando com dados espaciais tanto em relação aos crimes quanto aos determinantes, incorporou-se um componente espacial ao modelo de regressão. Para tal fim, a regressão espacial GWR foi empregada nos dados dos 5 meses escolhidos. O método também permitiu que as relações entre as variáveis variassem no espaço e fossem determinadas para cada setor censitário. Assim, gerou-se mapas com os resultados relativos ao  $R^2$  local e os coeficientes da regressão ao longo da região de estudo. Por fim, a qualidade dos modelos finais foi avaliada mediante o critério de informação de Akaike corrigido (AICc) e o coeficiente de determinação ajustado ( $R^2$  ajustado).

#### **4.3.3 Análise multicritério de áreas vulneráveis a roubos**

A modelagem multicritério parte da definição de alguns parâmetros essenciais, os quais incluem: alternativas, critérios de avaliação, decisor e problemática (de ALMEIDA, 2013). Neste estudo, as alternativas correspondem aos 206 setores censitários que formam os bairros de Boa Viagem e Pina. A escolha desta escala espacial se deve à limitação do IBGE em ter os setores como as menores divisões espaciais para as quais fornece informações socioeconômicas (IBGE, 2016). Ademais, trata-se de um problema de classificação em termos da vulnerabilidade dos locais à ocorrência de roubos. O analista assumiu o papel do decisor na avaliação de preferências e definição de parâmetros para o modelo, tendo como suporte o conhecimento histórico acerca da região de estudo e a exploração estatística-espacial dos dados criminais.

O esforço principal no desenvolvimento do modelo deu-se na elaboração dos critérios. Buscou-se um conjunto de critérios não-redundantes, exaustivos e consistentes (ROY, 1996), tendo um embasamento também da literatura criminal. A análise estatística prévia revelou relações significativas entre os 37 fatores preditivos, bem como entre eles e as ocorrências de roubos na região de estudo. Os preditores com significância expressiva na correlação espacial e nos modelos parcimoniosos foram realçados.

Vale salientar que aspectos considerados redundantes do ponto de vista estatístico não necessariamente o serão sob a perspectiva multicritério (de ALMEIDA, 2013). De acordo com o autor, a significância estatística não implica em relevância nas preferências do decisor – as quais são subjetivas e variam conforme o contexto de decisão. Isto reforça o caráter exploratório – porém não impositivo – da modelagem estatística, servindo apenas como suporte à aprendizagem de preferências e ao estabelecimento de critérios.

A definição dos critérios ocorreu segundo a origem das variáveis a fim de abranger vastamente o panorama criminológico local. Deste modo, os 17 fatores representativos da questão demográfica e socioeconômica (extraídos do IBGE) foram filtrados com base nos resultados estatísticos e no alicerce da literatura. Logo foram inseridos no modelo multicritério na forma de atributos naturais.

Por outro lado, os 20 preditores indicativos do fluxo de pessoas e comércio local foram mantidos na análise multicritério dada a contribuição diferenciada deles à atratividade local a roubos. Contudo, como existe correlação significativa entre os elementos ao ponto de serem discernidos vieses similares de explicação da ocorrência de crimes, empregou-se uma Análise fatorial exploratória (HAIR et al., 2009) para dividi-los em fatores não-correlacionados entre si.

Usou-se o teste de Kayser-Meyer-Olkin para avaliar a adequação dos dados amostrais para a Análise fatorial, isto é, a medida deve exceder 0,50. O teste de esfericidade de Bartlett também foi aplicado para verificar se existem correlações suficientes entre as variáveis explicativas, cujo valor-p deve ser inferior a 0,05.

A fim de auxiliar na definição do número de fatores, aplicou-se o teste scree para indicar quais fatores possuem quantias substanciais de variância comum, assim como avaliou-se os fatores que possuem raízes latentes – isto é, aqueles cujos autovalores fossem maiores do que 1,0. A Análise fatorial ocorreu segundo a rotação ortogonal varimax e comparando os resultados oriundos de quatro métodos de

fatoração: minres, ols, principal axes e max likelihood. Por fim, é determinada a alocação das variáveis aos fatores.

Estes fatores representam os critérios relativos aos estabelecimentos comerciais. Os valores intracritério foram encontrados pela aplicação do método aditivo WLC a cada fator, tendo em vista a natureza espacial dos dados. Assim, realizou-se uma soma ponderada dos mapas de densidade Kernel referentes a cada estabelecimento. Os pesos seguem a lógica de *tradeoff*, na qual se considera o *range* de valores dos atributos e o grau de importância deles – que foi identificado na etapa de exploração estatística-espacial.

Com o conjunto de critérios determinado, prosseguiu-se com a execução do modelo multicritério para a classificação das 206 alternativas em cinco categorias de vulnerabilidade a roubos por meio do método de sobreclassificação ELECTRE-TRInC. Os parâmetros necessários foram construídos pelo analista, particularmente: os pesos, os limiares de preferência e de indiferença, os perfis centrais das categorias, e o nível de credibilidade.

O cálculo dos pesos dos critérios ocorreu mediante o procedimento de Simos Revisado (FIGUEIRA; ROY, 2002). Este procedimento utiliza um baralho de cartas, o qual contém uma carta por critério mais um número suficiente de cartas em branco. O especialista é solicitado a ordenar os critérios, do mais importante ao menos importante. A diferença de importância entre os *ranks* (posições) é expressa pela introdução de cartas em branco entre as cartas de critérios. O especialista é questionado quantas vezes o critério (ou critérios) na primeira posição é mais importante do que o critério (ou critérios) na última posição, o que é denotado pelo fator Z. Calcula-se, por fim, os pesos não-normalizados e normalizados.

Finalmente, o modelo multicritério foi executado com o suporte do software MCDA-ULaval versão 0.6. Apresentou-se o resultado do modelo na forma de mapa (gerado no ArcGIS 10.5) visando facilitar a identificação de padrões espaciais e a análise comparativa com os locais destacados na análise de *clusters* espaciais.

## 5 ANÁLISE DA PANDEMIA DE COVID-19 EM RECIFE

O presente capítulo realiza um estudo amplo acerca do panorama epidemiológico e espacial da propagação da COVID-19 na cidade do Recife. Neste sentido, investiga-se os índices epidemiológicos em relação às medidas restritivas governamentais. Ademais, avalia-se a concentração espacial da doença (em termos de casos e taxa de letalidade) ao nível de bairros e discute-se as características locais que propiciam o avanço das infecções.

### 5.1 Estudo epidemiológico

A tendência de propagação da COVID-19 na cidade do Recife foi analisada no período de março de 2020 a maio de 2021. Considerou-se os dados de casos confirmados e óbitos decorrentes da COVID-19, tanto na forma de registros diários como de acumulado mensal, sendo estes cedidos pela Secretaria de Planejamento e Gestão do estado de Pernambuco (SEPLAG, 2022). Recortes do contexto local foram mencionados como forma de compreender possíveis influências sobre as diferentes fases da pandemia na região de estudo.

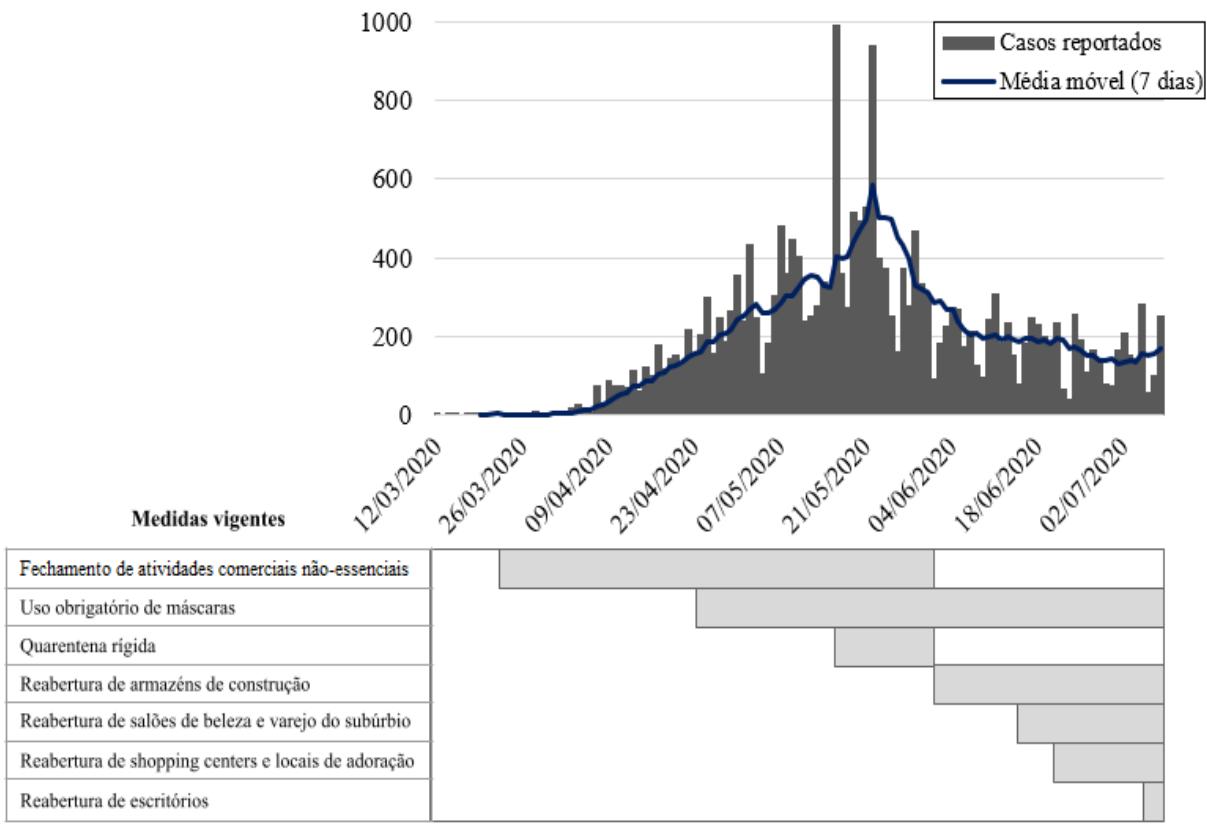
A Figura 4 amplia o gráfico de casos no intervalo entre o início da pandemia e o início de julho de 2020 na cidade do Recife, tendo em vista a colaborar com a exploração estatística conduzida posteriormente. Nela estão destacadas as medidas de restrição ou flexibilização impostas pelo Governo do Estado de Pernambuco e pela Prefeitura Municipal do Recife, bem como os respectivos períodos de vigência.

Logo após os primeiros casos confirmados de COVID-19 em Pernambuco, o governo estadual decretou o fechamento do comércio, dos serviços não-essenciais e das obras de construção civil a partir de 22 de março de 2020 (PHS, 2020). Foi autorizado o funcionamento apenas de supermercados, padarias, mercadinhos, farmácias, postos de gasolina, casas de ração animal e depósitos de água e gás.

O número de casos confirmados diários continuou em tendência de crescimento durante o mês de abril de 2020. Logo, o governador do estado lançou o Decreto Nº 48.969, de 23 de abril de 2020, tornando obrigatório o uso de máscaras (ainda que artesanais) para trabalhadores de estabelecimentos comerciais que prestam serviços essenciais (PHS, 2020). Esta medida foi estendida à toda a população em 11 de maio de 2020, tanto em espaços abertos ao público quanto no

interior de estabelecimentos e veículos (públicos e privados). Todavia, como as multas eram impostas aos proprietários ao invés dos clientes, a adesão à medida dependeu mais da disposição do público em usar máscaras e da fiscalização na entrada dos estabelecimentos.

Figura 4 - Evolução da curva de casos de COVID-19 entre março e julho de 2020



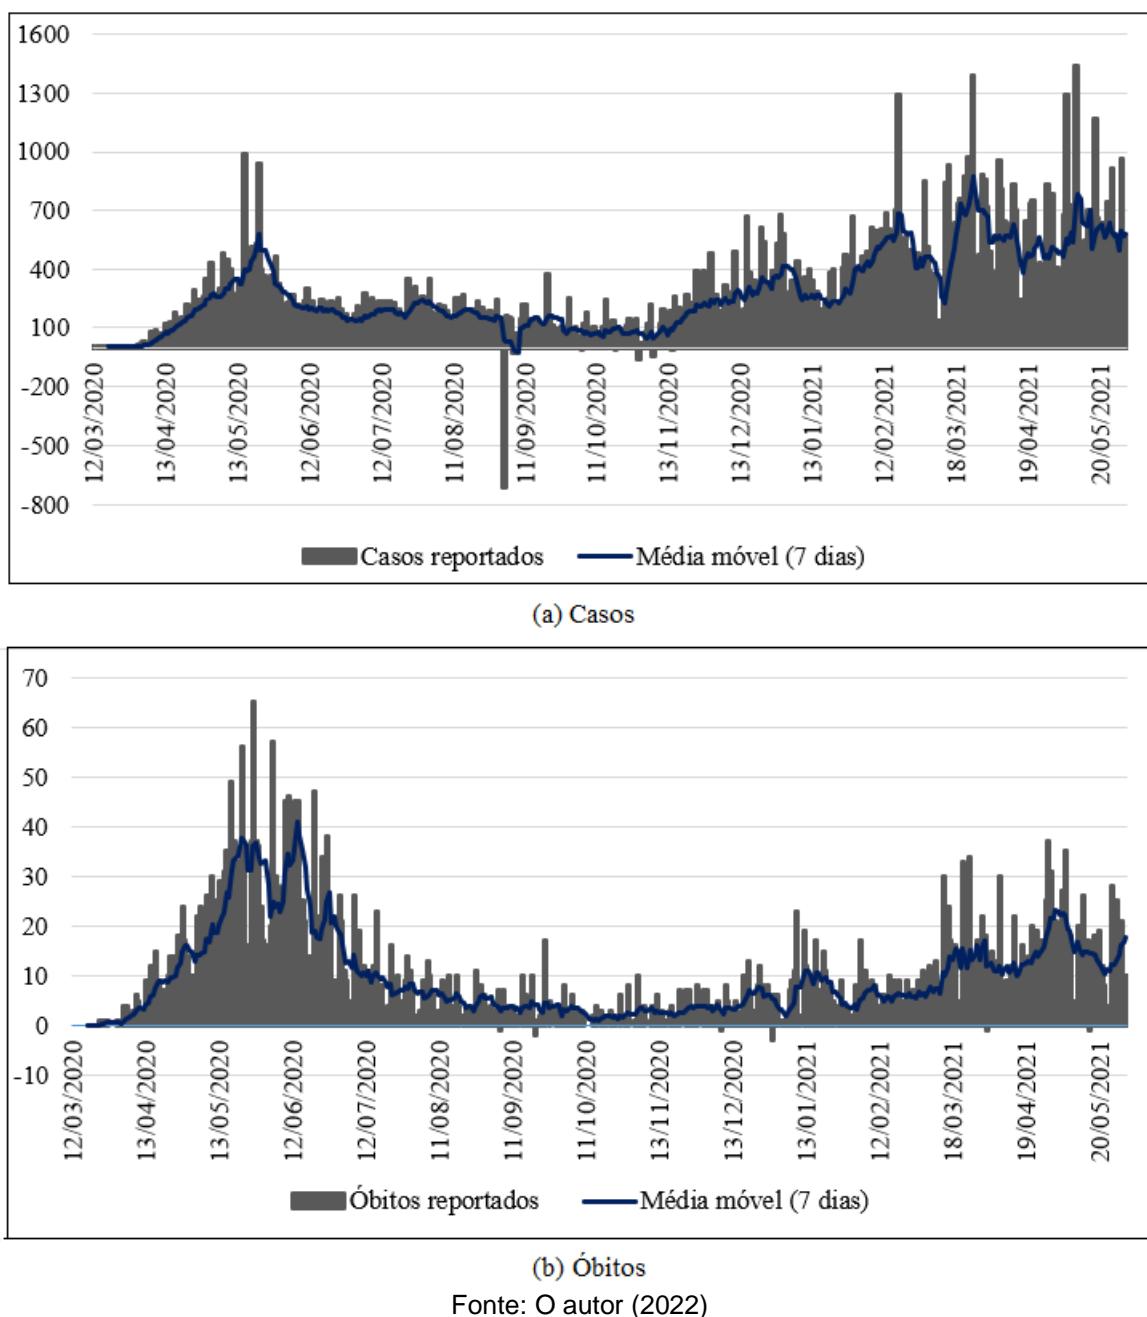
Fonte: O autor (2022)

Apesar do esforço das autoridades públicas, as medidas não foram suficientes para amenizar o aumento no número de casos reportados de COVID-19 – conforme se verifica na Figura 4. Assim, por meio do Decreto Nº 49.017, de 11 de maio de 2020, o governo estadual instituiu uma quarentena mais rígida em 5 municípios com elevada taxa de infecções naquele momento, incluindo o Recife (PHS, 2020).

Então, no período de 16 a 31 de maio de 2020 apenas os serviços essenciais puderam funcionar, com capacidade reduzida e distanciamento mínimo de 1 metro entre as pessoas. Só estava autorizado a sair de casa à procura dos serviços essenciais, sendo obrigatório portar um comprovante. Por sua vez, os veículos eram permitidos nas ruas conforme um sistema de rodízio baseado no número final da placa de identificação (PHS, 2020).

Essas restrições afetaram positivamente a curva de casos notificados, no sentido de que a média móvel das infecções atingiu o pico no final de maio de 2020 (durante a quarentena), e então apresentou uma tendência de estabilização até o início de julho de 2020 (Figura 4). Logo após o final da quarentena, mesmo com a flexibilização gradual das restrições levando à reabertura de locais propícios a aglomerações de pessoas (por exemplo, shopping centers e lojas de varejo), a curva de casos não cresceu de imediato. Um leve aumento dos casos foi reportado apenas no início de agosto de 2020 (Figura 5(a)).

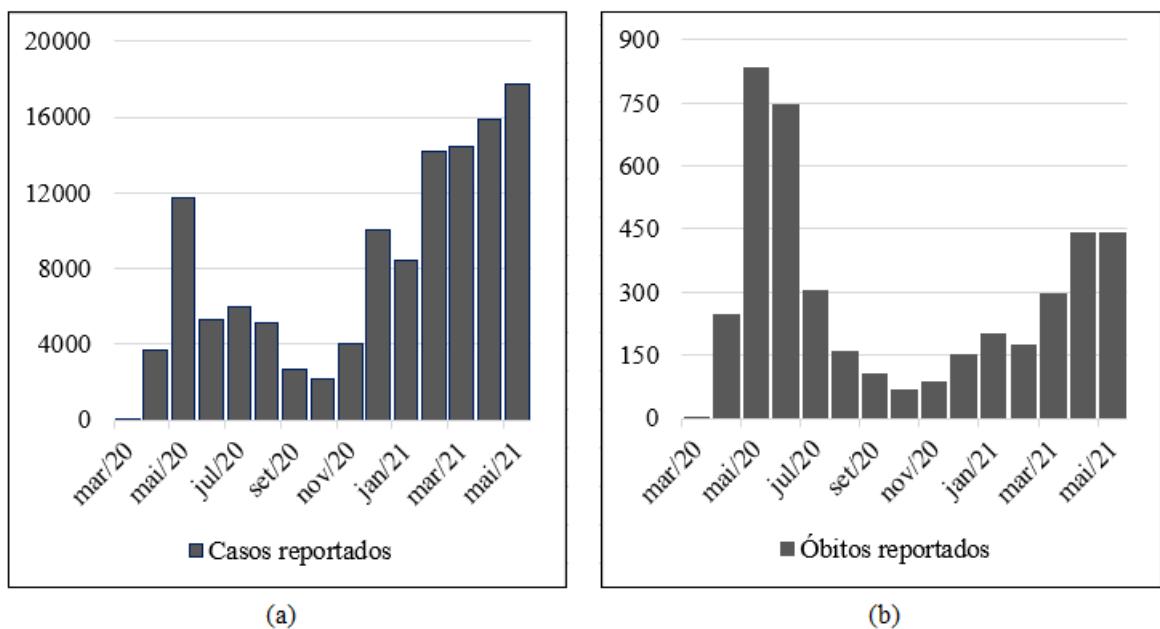
Figura 5 - Registro diário dos casos e óbitos por COVID-19 em Recife



A curva de casos acumulados por mês (Figura 6(a)) aponta que o mês de maio de 2020 configurou o pico da primeira onda de infecções em Recife. Os óbitos também atingiram o pico acumulado neste mês, mas se mantiveram igualmente elevados em junho de 2020 (Figura 6(b)). Ainda em junho, a média móvel de óbitos chegou ao ápice de todo o período investigado da pandemia (Figura 5(b)). Isto tende a estar relacionado com a elevada ocupação dos leitos de UTI na época; inclusive a fila de espera por leitos atingiu o seu pico em 11 de maio de 2020 (ROQUE, 2021).

Com a queda dos índices posterior à quarentena rígida (conforme mencionado acima), o governo estadual passou a liberar a abertura dos serviços não-essenciais paulatinamente, porém com restrições de horário e de capacidade de funcionamento (G1PE, 2020). O setor de eventos obteve a primeira autorização de retorno em 07 de setembro de 2020 (SANTOS, 2020), conseguindo ampliar a capacidade para até 300 pessoas em outubro (MORAES, 2020). Já as escolas foram as últimas a retomarem suas atividades com o ensino médio em 06 de outubro de 2020 (NASCIMENTO, 2020a), findando com o retorno da educação infantil em 24 de novembro de 2020 (ALVES, 2020).

Figura 6 - Acumulado mensal dos casos e óbitos por COVID-19 em Recife



Fonte: O autor (2022)

Nesse momento, a tendência de queda sustentada nos casos e óbitos vinha durando cerca de três meses, mas foi cessada na segunda quinzena de novembro de 2020 (Figura 5(a)). O acumulado mensal de ambos os índices também voltou a

crescer em novembro de 2020 (Figura 6), embora de forma tímida – provavelmente como um reflexo da flexibilização das medidas restritivas. Devido à proximidade das festividades de fim de ano e ao consequente impulso nas vendas, especialmente em um ano de crise sanitária e comercial, houve um esforço do governo para manter as lojas abertas e com horário estendido até o Natal (MOROSINI, 2020).

O impacto desse fluxo maior de pessoas nas ruas para fins comerciais na transmissão do vírus fez com que as infecções se acelerassem e os óbitos obtivessem um aumento acentuado entre a segunda quinzena de dezembro de 2020 e a primeira de janeiro de 2021 (Figura 5). Isto ocorreu mesmo com o eventual atraso nas notificações devido aos feriados de Natal e Ano Novo. No acumulado mensal até então, foi atingido um segundo pico de casos em dezembro de 2020, enquanto o de óbitos ocorreu em janeiro de 2021 (Figura 6). O governo estadual interviu por meio da proibição de festas e shows de dezembro de 2020 até o carnaval em fevereiro de 2021 (NASCIMENTO, 2020b).

O mês de janeiro de 2021 compreendeu uma série de situações que afetaram o andamento da pandemia em Recife. Em uma época de verão ensolarado, notou-se um crescente desrespeito às medidas sanitárias com a superlotação de bares e praias, onde houve aglomerações e resistência ao uso de máscaras (G1PE, 2021a, 2021b). Como resposta, o governo de Pernambuco suspendeu o uso de aparelhos de som em ambientes de lazer (G1PE, 2021c) e a realização de eventos sociais e corporativos a partir de 25 de janeiro (MOROSINI, 2021).

Ademais, a realização das provas do ENEM na segunda quinzena de janeiro promoveu reuniões em salas fechadas por todo o estado, apesar da alta taxa de abstenção (G1PE, 2021d). Por outro lado, no dia 18 de janeiro teve início em Pernambuco a campanha de vacinação (G1PE, 2021e). Isso trouxe esperança no combate à COVID-19 porque a vacina é a melhor forma de prevenir infecções, reduzir casos graves e, consequentemente, diminuir as taxas de mortalidade (BARTSCH et al., 2021). Os números de casos e óbitos se mantiveram em um patamar elevado, porém estável em valores acumulados (Figura 6). Além do que foi mencionado, estes índices epidemiológicos também foram influenciados pela maior circulação de pessoas no mês de dezembro anterior.

Em fevereiro de 2021, atingiu-se um novo pico na média móvel de casos em Recife (Figura 5(a)), porém os óbitos ficaram estáveis no acumulado mensal (Figura 6(b)). Neste mês confirmaram-se os primeiros casos da variante Gamma do SARS-

CoV2 em solo pernambucano, a qual é mais transmissível do que a linhagem original do vírus (SSPE, 2021). Durante a primeira quinzena de fevereiro de 2021 ocorreu o período carnavalesco, época tradicional de grandes festas e eventos públicos. Os governos estadual e municipal decretaram medidas para coibir comemorações, dentre as quais: o fechamento de bares, restaurantes e comércio de rua (G1PE, 2021f); e a suspensão do ponto facultativo no feriado (FOLHAPE, 2021). Contudo, houve registros de festas clandestinas (APRÍGIO, 2021; G1PE, 2021g).

Nos dois meses seguintes, março e abril de 2021, houve uma acentuação nas curvas de casos e óbitos conforme se verifica nos acumulados mensais (Figura 6). Inclusive, o maior pico da média móvel de casos desde o início da pandemia foi registrado neste período (Figura 5(a)). O estado enfrentou um ritmo de vacinação lento neste período, visto que até o final de abril apenas 15% da população havia recebido ao menos uma dose da vacina (majoritariamente grupos prioritários e população acima de 60 anos de idade) (G1PE, 2021h). Além disso, Pernambuco sofreu com o déficit de doses para completar o esquema vacinal da Coronavac, levando ao adiamento das aplicações em Recife (G1PE, 2021i).

Último mês analisado pelo presente estudo, maio de 2021 registrou o maior pico acumulado de casos desde o início da pandemia (Figura 6(a)). Ocorreu também o pico acumulado e na média móvel de mortes da segunda onda de disseminação da COVID-19 – contudo, era aproximadamente metade do pico da primeira onda (Figura 6(b) e Figura 5(b)). Inclusive, em 19 de maio formou-se a maior fila de espera por leitos de UTI da segunda onda (ROQUE, 2021). Este mês é marcado pelo Dia das Mães, uma das datas mais lucrativas para o varejo pernambucano, o que levou à ampliação do horário de funcionamento das lojas (DIARIOPE, 2021). Logo, espera-se uma maior movimentação de pessoas nas ruas. Isto somado à predominância da variante Gamma, que é mais transmissível, em Pernambuco (TÔRRES, 2021) e à desaceleração na média diária de doses aplicadas (G1PE, 2021j) impulsionou a disseminação da COVID-19.

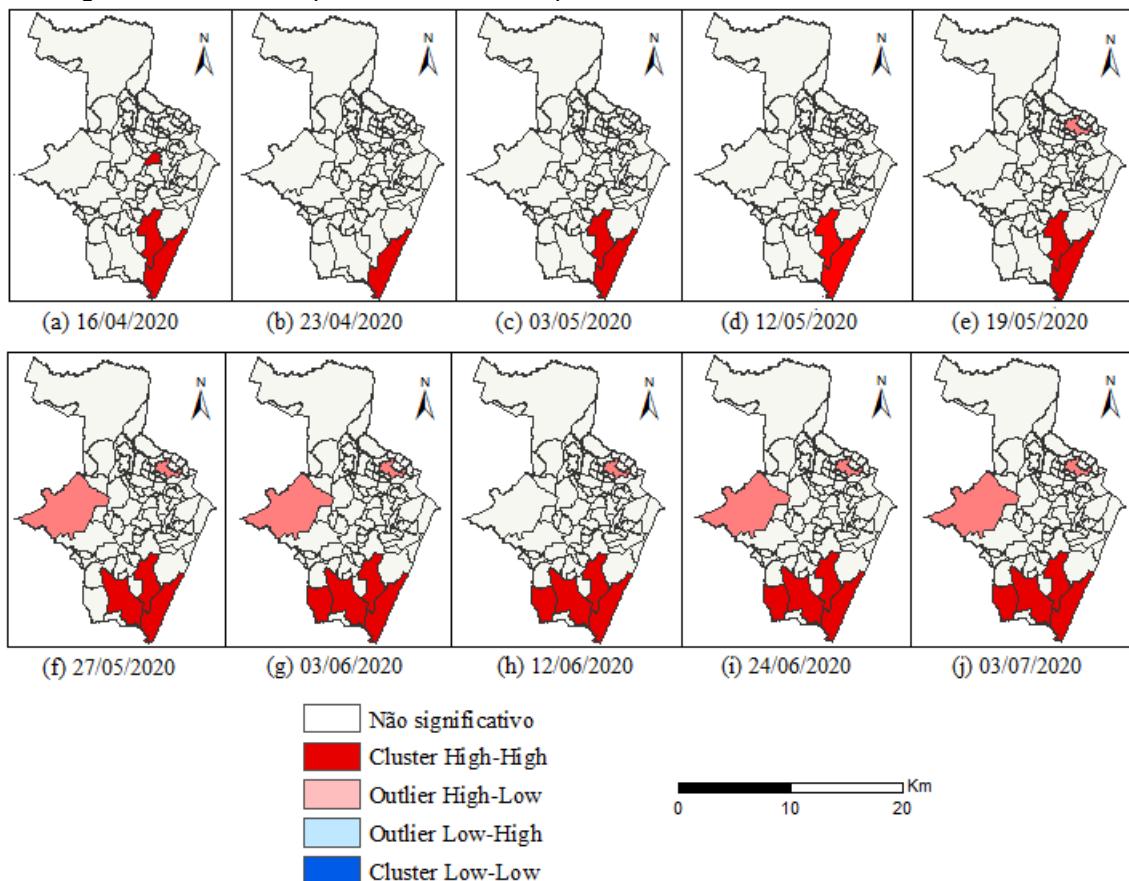
## 5.2 Análise de *clusters* espaciais

Os casos confirmados e a taxa de letalidade decorrente da COVID-19 foram investigados em termos da concentração espacial destes em *clusters* e *outliers* nos bairros de Recife. O estudo se restringiu ao intervalo de 16 de abril a 03 de julho de

2020, em dez datas espaçadas em aproximadamente uma semana. Para tanto, utilizou-se a estatística Local Moran's I. Os locais cuja clusterização fosse estatisticamente significativa foram explorados por meio de uma análise de quartis baseada nos 15 indicadores socioeconômicos descritos no Quadro 3. Dentre esses estão inclusos fatores representativos da: renda domiciliar, densidade populacional, propriedade do domicílio, provisão de serviços públicos e faixa etária.

Em relação aos casos de COVID-19, os *clusters* identificados se encontram na Figura 7. Eles se concentraram no início da pandemia nos bairros da zona sul da cidade, especialmente em Boa Viagem. Inclusive, o bairro foi o único *cluster* significativo em 23 de abril de 2020. À medida que a incidência de casos aumentou, outros *clusters* espaciais do tipo High-High e *outliers* High-Low surgiram não só na zona sul, como também nas zonas norte e oeste.

Figura 7 - Clusters espaciais dos casos reportados de COVID-19 nos bairros de Recife



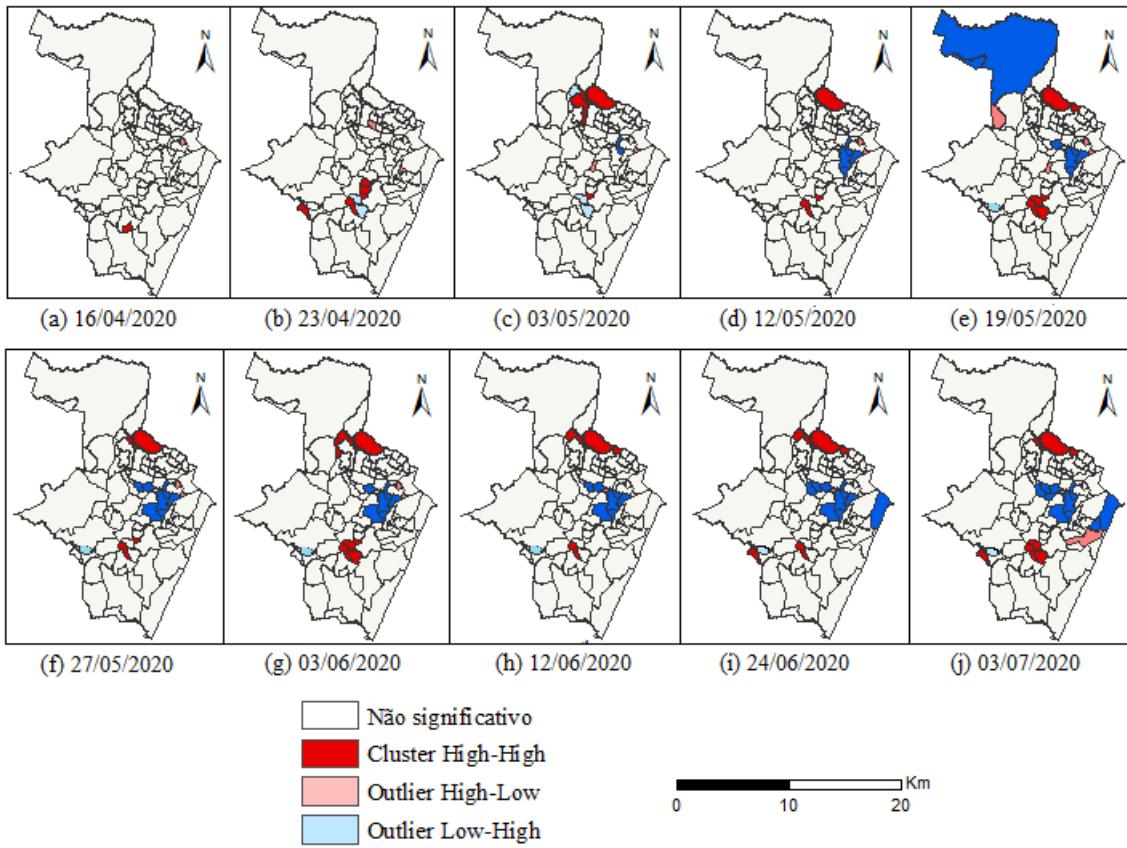
Fonte: O autor (2022)

A análise de quartis indicou uma forte discrepância social entre Boa Viagem e os demais *clusters* e *outliers*. Boa Viagem apresenta uma elevada densidade

populacional, assim como um acentuado nível de desenvolvimento em termos de acesso a esgotamento sanitário, coleta de lixo e níveis de renda e alfabetização (está acima do terceiro quartil destes). Enquanto isso, em relação a estes fatores, os outros locais destacados na Figura 7 atingem índices inferiores a 50% da totalidade de bairros em Recife.

A taxa de letalidade por COVID-19 também foi examinada em termos de *clusters* espaciais, conforme apresentado na Figura 8. Em comparação à Figura 7, nota-se padrões espaciais consideravelmente diferentes daqueles verificados para os casos confirmados. Os *clusters* e *outliers* de letalidade se mantiveram predominantemente estáveis ao longo do período analisado. Em geral, os *clusters* High-High se formaram nas zonas sul e sudoeste do Recife, enquanto os do tipo Low-Low foram percebidos nas zonas norte e centro-leste.

Figura 8 - *Clusters* espaciais da taxa de letalidade por COVID-19 nos bairros de Recife



Fonte: O autor (2022)

Embora Boa Viagem tenha sido um *cluster* significativo de casos notificados desde a primeira data analisada (16 de abril de 2020), esse padrão não se repetiu

para a taxa de letalidade. O registro do primeiro óbito em Boa Viagem ocorreu em 10 de abril de 2020, após a notificação de 63 casos - o que representava 15% dos casos de COVID-19 em Recife na época. Este bairro liderou o número de mortes na cidade de 27 de abril a 8 de julho de 2020, mas não se tornou *cluster* nem *outlier* significativo da letalidade em nenhuma das dez datas investigadas. Isto é, Boa Viagem teve o maior acumulado de casos em Recife durante o período considerado, mas a proporção de óbitos por casos se manteve baixa. Em 3 de julho de 2020 o bairro atingiu a sua taxa de letalidade máxima (18%), o que ainda denotou um patamar bastante inferior ao dos *clusters* High-High (entre 34% e 54%).

A análise de quartis mostra que os *clusters* High-High e *outliers* High-Low de letalidade costumam apresentar características socioeconômicas semelhantes às daqueles encontrados para os casos confirmados – exceto Boa Viagem. Por exemplo, a maioria dessas áreas apresenta uma população de baixa renda que sofre com uma prestação de serviços públicos precária. Atributos opostos foram verificados nos *clusters* Low-Low (tanto para casos quanto para taxa de letalidade), os quais se destacam por ter menos residentes por domicílio do que 75% de todos os outros bairros de Recife.

Em complemento à análise de *clusters* e quartis, aplicaram-se testes de correlação de Spearman entre a taxa de letalidade por COVID-19 (em 3 de julho de 2020) e os indicadores censitários. Adotando valor-*p* < 0,05, detectou-se que a letalidade está associada positivamente com o número de residentes por domicílio (*p* = 0,41); enquanto negativamente com a renda familiar (*p* = -0,51), a taxa de alfabetização (*p* = -0,44), o acesso a esgotamento sanitário (*p* = -0,47) e à coleta de lixo (*p* = -0,27), e ao número de pessoas acima de 60 anos (*p* = -0,32).

Em uma investigação conjunta dos resultados anteriores, percebe-se que alguns locais tendem a sofrer menos mortes por COVID-19 quando os residentes possuem um nível de renda e alfabetização consideravelmente acima da média da cidade. Essas áreas também possuem mais acesso aos serviços públicos e um número de residentes por domicílio menor do que em outros bairros de Recife. Ao contrário do que era esperado com base na análise de correlação, a população idosa é maior nos *clusters* Low-Low de letalidade. Assim, embora os idosos sejam mais propensos a contrair casos graves de COVID-19 (VERITY et al., 2020), a proporção de mortes foi menor em bairros com alta concentração de pessoas nesta faixa etária.

Por fim, examinou-se a relação entre a presença de serviços essenciais (Quadro 4) nos bairros destacados como *clusters* espaciais em termos de casos de COVID-19 e taxa de letalidade (em 3 de julho de 2020) por meio da correlação de Pearson. Em relação aos casos, nos *clusters* High-High as quantidades de farmácias e de padarias apresentavam as relações mais fortes com os casos, sendo ambas significativamente positivas (valor-p < 0,05). Cinco dentre os seis bairros ressaltados pertencem ao quarto quartil desses fatores, o que ratifica o resultado. Por sua vez, nos *clusters* Low-Low para a taxa de letalidade, o número de bancos foi o único fator significativamente associado a ela – neste caso, negativo. Seis dentre os dez bairros vistos como Low-Low foram colocados no quarto quartil deste determinante.

### 5.3 Análise de regressão

A exploração dos preditores locais da COVID-19 foi expandida por meio de uma análise de regressão espacial. Os casos da doença foram tratados como variável dependente, ao passo que dois conjuntos de fatores explanatórios foram formados. O primeiro foi composto por 15 indicadores socioeconômicos (Quadro 3) extraídos do Censo 2010, enquanto o outro incluiu 6 serviços essenciais que operaram durante todas as fases da pandemia em Recife (Quadro 4).

Os determinantes foram processados inicialmente de acordo com a sua origem, ou seja, foram conduzidos dois modelos de regressão. A variável resposta correspondeu aos casos cumulativamente notificados de COVID-19 no dia 3 de julho de 2020, a qual foi tratada mediante o método OLS em busca de modelos parcimoniosos (isto é, reduzir o número de determinantes a conjuntos não-redundantes). Ambos os modelos de regressão foram estatisticamente significativos (valor p < 0,001).

Em relação apenas aos determinantes socioeconômicos, cinco deles formaram o conjunto final significativo ( $R^2 = 0,9521$ ), sendo duas faixas etárias extremamente opostas ('pessoas entre 0 e 9 anos' e 'pessoas com mais de 60 anos'), dois atributos de infraestrutura (acesso a água encanada e à coleta de lixo) e o número de residentes por domicílio. Analisando os fatores individualmente, o total de residentes (fator 'população') é capaz de explicar por si só, com base no  $R^2$ , cerca de 90% da variabilidade nos casos de COVID-19.

Por sua vez, a investigação exclusiva dos serviços essenciais revelou o seguinte conjunto parcimonioso: número de padarias, mercados, bancos e farmácias – resultando em um  $R^2$  elevado (0,8659). A análise de cada fator destacou o número de padarias como o preditor que melhor consegue explicar a variabilidade nos casos, com um valor de cerca de 77% no  $R^2$ .

Posteriormente formou-se um conjunto único de 21 determinantes, independentemente da origem deles, a fim de compreender o possível efeito sinérgico entre eles ao longo da região de estudo. Modelos de regressão OLS foram construídos para dez datas diferentes entre abril e julho de 2020, tendo os casos cumulativos de COVID-19 como a variável dependente.

Buscou-se um conjunto parcimonioso de variáveis explicativas para cada dia analisado. Para isso, as variáveis altamente correlacionadas foram excluídas e aplicou-se o método de seleção de regressores *stepwise*. Os resultados estão resumidos na Quadro 7. Embora os determinantes tenham sido analisados em um bloco único, os conjuntos finais destes foram mostrados separadamente a fim de facilitar a percepção de padrões. A coluna MV, medidas vigentes, remete aos decretos de restrição ou flexibilização instituídos pelos governos do estado de Pernambuco e do município de Recife que estavam vigentes em cada data.

Os dez modelos de regressão foram considerados significativos (valor  $p < 0,001$ ) para a predição de casos de COVID-19. Todos os determinantes contribuíram positivamente para as predições, exceto o fator ‘terminais de ônibus’. O  $R^2$  ajustado apresentou um aumento considerável até o início de junho de 2020, sendo seguido por uma tendência de estabilização. Isto provavelmente decorreu do cenário de crescimento lento de casos em Recife, conforme percebido na Figura 4. Como o  $R^2$  ajustado mostrou-se elevado, cada modelo OLS foi validado com base em partições do banco de dados de casos de COVID-19. A comparação da raiz do erro quadrático médio dos modelos não demonstrou *overfitting* significativo.

Alguns preditores foram repetidos frequentemente nos conjuntos parcimoniosos do Quadro 7, como ‘padarias’, ‘mercados’, ‘renda’ e ‘crianças de 0 a 9 anos’. Assim, ratifica-se a importância destes para a predição de casos. Por outro lado, as variáveis explanatórias ‘pessoas com mais de 60 anos’ e ‘população’ obtiveram destaque durante a análise inicial, aquela baseada na origem do banco de dados dos preditores. Contudo, ambas foram descartadas após a redução dos conjuntos de determinantes aos seus núcleos não-redundantes.

Quadro 7 - Modelos de regressão OLS com determinantes combinados em grupo único

Data	MV*	Indicadores censitários	Serviços essenciais	R <sup>2</sup> ajustado
16/04/2020	1	Domicílio próprio, renda	Padarias, mercados, lotéricas, terminais de ônibus	0,8117
23/04/2020	1; 2	0 a 9 de idade, domicílio próprio, sistema de esgoto	Padarias, mercados, bancos	0,8159
03/05/2020	1; 2	0 a 9 anos de idade, renda	Padarias, mercados, lotéricas, terminais de ônibus	0,8331
12/05/2020	1; 2	0 a 9 anos de idade, domicílio próprio, renda, alfabetização	Padarias, mercados, lotéricas	0,8689
19/05/2020	1; 2; 3	0 a 9 anos de idade, renda	Padarias, mercados, lotéricas	0,8958
27/05/2020	1; 2; 3	0 a 9 anos de idade, renda	Padarias, mercados, lotéricas	0,9100
03/06/2020	2; 4	0 a 9 anos de idade, renda	Padarias, mercados, lotéricas	0,9162
12/06/2020	2; 4	0 a 9 anos de idade, domicílio próprio, alfabetização	Padarias, mercados, lotéricas	0,9215
24/06/2020	2; 4; 5; 6	0 a 9 anos de idade, domicílio próprio, alfabetização	Padarias, mercados, lotéricas	0,9255
03/07/2020	2; 4; 5; 6	0 a 9 anos de idade, renda	Padarias, mercados, farmácias	0,9260

\* Medidas vigentes:  
 1- Fechamento de atividades comerciais não-essenciais  
 2- Uso obrigatório de máscaras  
 3- Quarentena rígida

4- Reabertura de armazéns de construção  
 5- Reabertura de salões de beleza e varejo do subúrbio  
 6- Reabertura de shopping centers e locais de adoração

Fonte: O autor (2022)

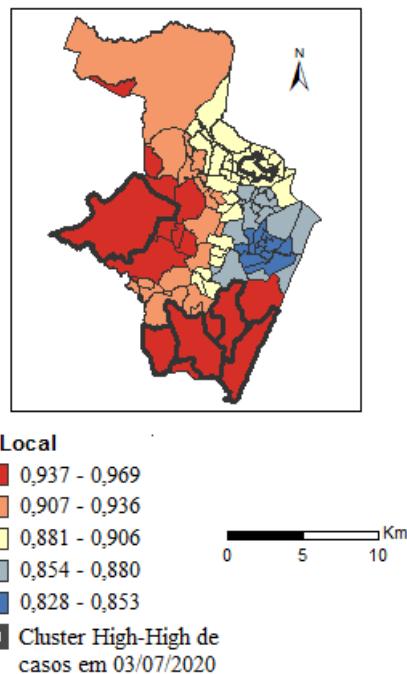
Enriqueceu-se a análise com a regressão espacial GWR. Para tanto, usou-se os dados georreferenciados de casos de COVID-19 referentes a 3 de julho de 2020, bem como o conjunto de preditores significativo nesta data (expresso no Quadro 7). Como resultado global do modelo baseado em 54 áreas vizinhas para cada bairro, obteve-se um R<sup>2</sup> de 0,960.

Ao aplicar a estatística Global Moran's I aos resíduos da GWR, resultou-se em um índice de -0,028 (valor-p = 0,63). Logo, os resíduos estão distribuídos aleatoriamente e o modelo está adequado. Nota-se uma ligeira melhora dos resultados da OLS (análise global) em relação aos da GWR (análise local), pois o R<sup>2</sup> ajustado aumentou de 0,926 para 0,944, assim como a estatística AIC reduziu de 935,99 para 916,19. Como a diferença no AIC foi maior que 2, então a qualidade do modelo espacial é significativamente melhor (CHATTERJEE; HADI, 2013).

A GWR possibilita realizar previsões locais, para cada divisão espacial, o que contribui na elucidação das variações do modelo ao longo da região de estudo

(BRUNSDON; FOTHERINGHAM; CHARLTON, 1996). Deste modo, obteve-se um  $R^2$  local para cada bairro do Recife cuja distribuição espacial está ilustrada na Figura 9. O intervalo de valores mostra-se notavelmente elevado, uma vez que o limite inferior é capaz de explicar 82,8% da variabilidade de casos notificados. Avaliando as áreas com maior desempenho do  $R^2$  (em vermelho), percebe-se que elas comportam justamente os *clusters* High-High identificados em 3 de julho de 2020 (Figura 7(j)). Isto é, o modelo de regressão consegue melhores resultados de predição nos bairros onde se concentram as infecções por COVID-19.

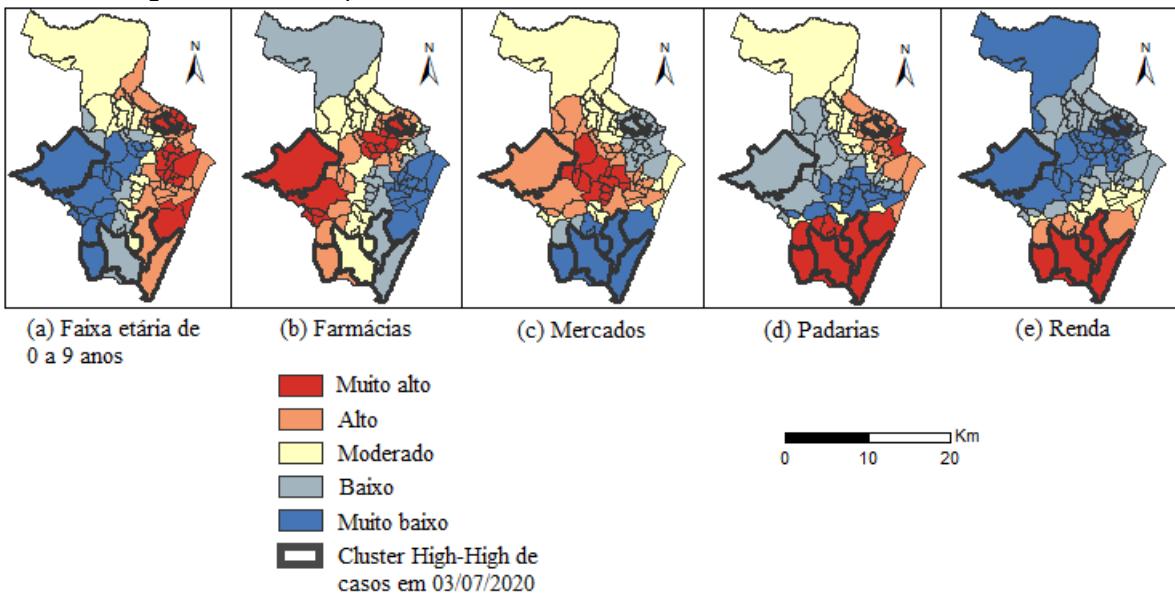
Figura 9 - Desempenho do  $R^2$  local nos bairros de Recife



Fonte: O autor (2022)

A contribuição de cada preditor para a modelagem de regressão espacial também foi explorada, de modo a identificar os diferentes impactos destes na predição do número de infecções por COVID-19. Assim, a Figura 10 apresenta uma classificação dos coeficientes das equações locais da regressão GWR em cinco categorias mediante o algoritmo *Jenks Natural Breaks* (JENKS; CASPALL, 1971).

Figura 10 - Desempenho dos coeficientes do modelo GWR nos bairros de Recife



Fonte: O autor (2022)

Ao novamente investigar os bairros denotados como *cluster* High-High (Figura 10), nota-se que a predição dos casos na região Sul foi mais impactada pela renda média de seus residentes e pela presença de padarias (em vermelho). Por sua vez, a variabilidade de casos no *cluster* ocidental é melhor descrita pela presença de farmácias e supermercados locais. A influência mais forte na incidência de COVID-19 no *cluster* ao norte da região é decorrente da presença de padarias e de farmácias, bem como do número de crianças de 0 a 9 anos de idade.

#### 5.4 Discussão

As medidas restritivas à circulação de pessoas em Recife começaram a ser implementadas imediatamente após a confirmação dos primeiros casos de COVID-19, em março de 2020, o que contribuiu para mitigar a transmissão do vírus. Após a primeira infecção registrada, os casos demoraram cerca de um mês a iniciar uma fase de aumento sustentado. A posterior iniciativa do governo estadual em estabelecer uma quarentena rígida em maio de 2020 surtiu efeitos positivos, porque o pico de infecções ocorreu neste período e foi seguido por uma tendência de queda e estabilização da curva de casos em níveis mais baixos. De fato, Kerr et al. (2020) reafirmaram os efeitos positivos da quarentena estrita em Pernambuco, pois ajudou a aumentar o distanciamento social e a reduzir a taxa de reprodução do vírus.

Os casos confirmados e óbitos por COVID-19 permaneceram estáveis ou em declínio por cerca de três meses, mesmo após o relaxamento de medidas restritivas a partir de junho de 2020. Isto denotou um possível controle da pandemia, mas que logo foi desmistificado. Com a aproximação de feriados e festividades de fim de ano, houve maior aglomeração das pessoas e um consequente aumento nos índices epidemiológicos. Assim, não só o Recife como outras cidades brasileiras enfrentaram uma segunda onda da doença a partir do final de 2020. Isso foi intensificado com o surgimento de novas variantes do SARS-CoV2 mais transmissíveis, incluindo a variante Gamma descoberta em Manaus, Brasil (MOORE; OFFIT, 2021).

Por pressão do setor produtivo e da crise econômica brasileira, os governos estadual e municipal mantiveram aberto grande parte do comércio do Recife, embora restrições de horário de funcionamento e capacidade de atendimento fossem impostas e revistas periodicamente. Todavia, não houve uma nova quarentena rígida na cidade. A severidade branda das medidas restritivas junto à propagação de variantes do coronavírus, ao ritmo lento da vacinação e ao relaxamento da população no respeito às medidas sanitárias fez surgir novos picos de infecção no início de 2021. Espera-se um maior apoio da sociedade bem como a ampliação da campanha de vacinação para que o ritmo de infecções seja reduzido significativamente.

De acordo com um estudo na cidade de São Paulo, Brasil, as pessoas que moram em áreas com uma grande variedade de instalações comerciais em um raio de 500 metros de suas residências são mais inclinadas a se movimentar fora de casa (FLORINDO et al., 2021). Em um contexto de pandemia de COVID-19, mesmo durante fases mais restritivas, os residentes ainda precisam comprar mantimentos e medicamentos primários, provavelmente perto de onde vivem. Isso é uma realidade em bairros de baixa renda de Recife, pois uma parte significativa de sua população não pode pagar pelo transporte público, o que restringe sua rotina a lugares onde podem chegar a pé (ou de bicicleta, no máximo) (de LIMA; MAIA; LUCAS, 2017).

Padarias, mercados e farmácias aparentam ter uma forte influência na propagação espacial da COVID-19 de acordo com os resultados das análises de correlação e regressão. Descobertas semelhantes foram obtidas em uma cidade na China, onde esses mesmos pontos de interesse influenciaram o aumento na extensão do *cluster* de COVID-19 nos bairros vizinhos (LI, B. et al., 2021). Contudo,

por si só o número dessas instalações comerciais não implica necessariamente em filas mais longas ou espaços lotados que ajudam a transmitir o SARS-CoV2. Essa consequência também depende do nível de demanda ao longo do dia e pode ser afetada pelo número de residentes do bairro. Portanto, análises adicionais devem ser realizadas.

Os *clusters* High-High de casos foram verificados pela primeira vez no bairro de Boa Viagem, o qual é reconhecido pela população elevada e com renda bastante acima da média municipal. Depois surgiram outros *clusters* do mesmo tipo em Recife, porém com uma situação precária quanto à provisão de serviços públicos e o rendimento domiciliar. Este padrão de disseminação de áreas com melhores condições socioeconômicas para menos favorecidas também ocorreu com os casos na cidade do Rio de Janeiro (SILVA; RIBEIRO-ALVES, 2021) e com os óbitos por COVID-19 na cidade de São Paulo (BERMUDI et al., 2021).

A forma com que a doença se propagou em Recife tende a ter ocorrido por uma parcela substancial da população de áreas nobres, especialmente Boa Viagem, possuir recursos para se deslocar com mais frequência às metrópoles brasileiras ou mesmo a outros países. Assim, essas pessoas foram as primeiras a se infectar em outros lugares e, ao retornarem ao Recife, espalharam a doença para os indivíduos ao seu redor.

A chegada da COVID-19 em locais menos privilegiados da cidade produziu um impacto mais forte, inclusive percebido na taxa de letalidade. A análise de correlação de Spearman reafirmou isto, visto que há mais propensão à letalidade em locais com mais residentes por domicílio, menor renda média familiar, menos alfabetizados e com dificuldades no acesso a esgotamento sanitário e coleta de lixo.

Deste modo, as pessoas que vivem neste tipo de ambiente possuem menos infraestrutura em seus bairros e as condições de suas casas dificultam seguir as recomendações sobre isolamento social e cuidados pessoais. Por exemplo, tende-se a não haver renda suficiente para comprar itens de proteção (álcool, máscara) nem acesso constante à água encanada, bem como raramente há a opção do trabalho em *home office*. Todos esses fatores são agravados pelos impactos sociais da COVID-19 (BAMBRA et al., 2020). Por outro ângulo, notou-se o acesso dificultado à testagem para populações menos favorecidas na cidade, o que pode ter reduzido os casos reportados e, consequentemente, aumentado a letalidade nessas áreas.

A análise de regressão aponta que locais onde há um maior número de crianças (entre 0 e 9 anos) e/ou idosos (acima de 60 anos) tendem a apresentar mais casos notificados. Em relação às crianças, nota-se um contrassenso em relação à literatura. Na China, as crianças têm uma incidência menor de COVID-19 e são menos propensas a infecções do que outros grupos (LYU et al., 2020). Ademais, estudos afirmam que elas formam a maioria dos casos assintomáticos de COVID-19 (KRONBICHLER et al., 2020) e, no Brasil, há uma grande chance de elas não serem testadas por falta de capacidade de testagem (KAMEDA et al., 2021). Por outro lado, de março a outubro de 2020, as escolas e creches estavam fechadas em Recife (PHS, 2020), o que estimulava os grupos mais jovens a ficarem em casa. Portanto, era provável que disseminassem o vírus para seus familiares. Conclui-se então que um estudo epidemiológico mais aprofundado deve ser conduzido para validar esse resultado estatístico para crianças na cidade.

Os idosos não devem ser negligenciados. O aumento da infecção por SARS-CoV2 em idosos apresenta uma correlação direta com o risco de infecções em outras faixas etárias (YU, 2020). Portanto, o endurecimento do distanciamento social e outras medidas para reduzir os riscos de contaminação deles, como a análise da acessibilidade a locais públicos e a recursos de saúde (KANG et al., 2020), podem impactar positivamente toda a sociedade.

Alguns fatores se mostraram relevantes estatisticamente para a maioria das datas examinadas em relação aos casos de COVID-19, mas não apareceram no conjunto mais recente de determinantes após a quarentena rígida. Esse foi o caso das lotéricas, do domicílio próprio e da taxa de alfabetização – todos positivamente associados à variabilidade dos casos notificados.

As casas lotéricas têm sido utilizadas em conjunto com as agências bancárias da Caixa Econômica Federal para efetuar o pagamento de um auxílio emergencial a pelo menos 25% da população brasileira desde abril de 2020 (GARCIA et al., 2021). Assim, a presença dessas instalações poderia ter promovido a formação de longas filas sem respeito ao distanciamento social e com aglomeração entre pessoas socialmente vulneráveis (JN, 2020).

Por sua vez, espera-se que pessoas alfabetizadas sejam mais informadas sobre a doença, mas não se pode presumir que deem a importância devida a esse assunto nem que elas detêm os recursos necessários para seguir as medidas sanitárias. A associação direta dos casos com a alfabetização diverge de outras

pesquisas (de SOUZA; MACHADO; do CARMO, 2020), logo os resultados do presente estudo aparentam evidenciar um padrão distintivo do Recife.

Finalmente, a propriedade de domicílio não é capaz de realçar uma diferença social clara entre os *clusters* High-High dos casos de COVID-19. Essa variável explanatória se mostrou estatisticamente significativa para a predição dos casos na primeira e na última data exploradas na análise de regressão (16 de abril e 3 de julho de 2020, respectivamente). Portanto, o fator tornou-se relevante em *clusters* de casos tanto na fase do surgimento destes em locais privilegiados quanto, em um momento posterior onde a doença avançou para áreas que são historicamente reconhecidas por condições de vida deficitárias (PEREIRA; MOTA, 2016).

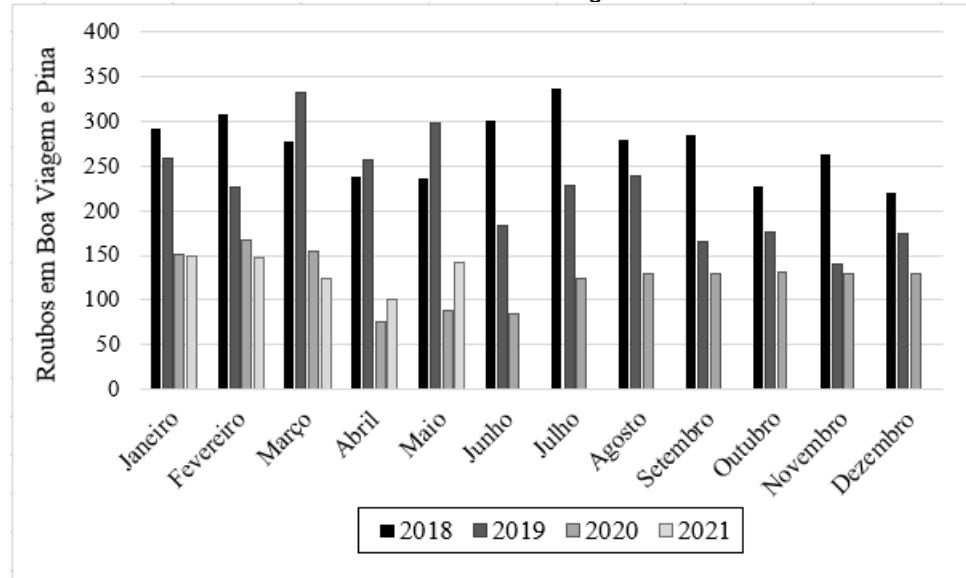
## 6 ROUBOS EM BOA VIAGEM E PINA: ANÁLISE DE CLUSTERS

O presente capítulo descreve os índices de roubos na região de estudo, traçando comparações com os anos anteriores à pandemia de COVID-19. Além disso, examina a concentração espacial de roubos considerando os índices das áreas vizinhas. Para este fim, o estudo foi conduzido ao nível de setores censitários e explorou diferentes recortes temporais.

### 6.1 Análise descritiva do acumulado de roubos

O volume de roubos nos bairros de Boa Viagem e Pina provavelmente foi afetado pelas medidas restritivas adotadas ao longo da pandemia de COVID-19. Ela teve início oficialmente em 11 de março de 2020 conforme decretado pela Organização Mundial de Saúde (OMS, 2020). Assim, a Figura 11 apresenta um comparativo do acumulado mensal das ocorrências de roubos nestes bairros, considerando os dados disponíveis para os anos de 2018, 2019, 2020 e 2021.

Figura 11 - Acumulado mensal de roubos em Boa Viagem e Pina nos anos de 2018 a 2021



Fonte: O autor (2022)

Houve declínio nas ocorrências em todos os meses de 2020 em comparação a 2019, mesmo naqueles que antecederam a pandemia (janeiro e fevereiro de 2020). Uma queda mais brusca ocorreu após março de 2020, tendo sido influenciada pelo decreto oficial da pandemia e o consequente fechamento dos serviços não-

essenciais na segunda quinzena do mês. Com menos pessoas circulando nas ruas, há uma redução tanto no número de alvos em potencial quanto no de possíveis vigilantes e criminosos, então espera-se haver menos roubos.

O padrão de queda nos roubos entre março e abril e de nova subida entre abril e maio de 2019 também ocorreu no ano de 2020, porém em um patamar bastante inferior e que se manteve até junho de 2020. Inclusive, em 2019 o mês de maio conteve o segundo maior pico mensal de roubos (superado apenas por março, mês das festividades de Carnaval). Em maio de 2020 estavam vigentes as restrições mais rígidas de toda a pandemia (neste estudo, até maio de 2021), dentre as quais a quarentena estrita. As pessoas só podiam se locomover em vias públicas com o comprovante do destino para serviços essenciais, assim como houve rodízio de veículos. Logo, as oportunidades de roubo foram bastante reduzidas.

Concomitantemente à reabertura gradual do comércio (com horário de funcionamento e capacidade de atendimento estendidos), os roubos atingiram um nível mais elevado (porém constante) de julho de 2020 a dezembro de 2020. Assim, mesmo com o esperado incremento das vendas devido aos feriados de Dia dos Pais, Dia das Crianças e Natal e ao consequente fluxo maior de clientes nas ruas, não houve um aumento significativo dos roubos nos respectivos meses (agosto, outubro e dezembro de 2020) como havia ocorrido no ano de 2019.

O início do ano de 2021 foi marcado por um trato mais naturalizado da pandemia apesar dos crescentes recordes de casos notificados e óbitos por COVID-19. Medidas majoritariamente brandas e pontuais foram impostas visando diminuir a chance de aglomerações, como a suspensão temporária dos eventos. Entre janeiro e março de 2021, os índices criminais foram levemente inferiores aos de 2020. Isto surpreende visto que nos dois meses iniciais de 2020 ainda não havia a influência da pandemia em Recife, logo espera-se que o fluxo de pessoas na época fosse consideravelmente maior do que em 2021.

Em abril e maio de 2021 houve um crescimento relevante nos roubos em comparação a 2020, embora em um patamar inferior ao momento pré-pandemia (2019). Esse aumento entre 2020 e 2021 reflete a não-vigência da quarentena estrita, logo houve mais liberdade para locomoção de pessoas e, então, mais alvos em potencial nas ruas. Além disso, esse acréscimo no movimento também foi impulsionado pelo Dia das Mães (comemorado em maio), tendo em vista que é uma

das datas mais lucrativas do varejo pernambucano (DIARIOPE, 2021) e propicia um maior número de transeuntes. Logo, há mais alvos em potencial para roubos.

Os roubos em Boa Viagem e Pina foram classificados conforme a Secretaria de Defesa Social de Pernambuco, no ano de 2019 e no período da pandemia explorado neste estudo (11 de março de 2020 a 31 de maio de 2021), conforme se verifica no Quadro 8. Houve uma queda no total de ocorrências, provavelmente pela menor circulação de pessoas durante a pandemia devido aos decretos restritivos e à queda no poder aquisitivo pela crise econômica no Brasil. Isto é perceptível na queda acima de 30% nos roubos a estabelecimentos e a transeuntes.

Quadro 8 - Tipos de roubos em Boa Viagem e Pina no ano de 2019 e durante a pandemia

Tipo de roubo	2019	Pandemia
Transeunte	2146	1403
Estabelecimentos comerciais	180	130
Transporte coletivo	35	30
Residência	26	33
Saída de banco	23	18
Instituição financeira	1	5
Outros	271	157
<b>Total</b>	<b>2682</b>	<b>1776</b>

Fonte: O autor (2022)

Apesar de apresentar um acumulado baixo em comparação com os demais tipos, houve um aumento no roubo a residências. Dentre os possíveis motivos está o fato das pessoas estarem passando mais tempo em casa em atividades de *home office*. Nota-se também um leve aumento nos roubos a instituições financeiras. Por outro lado, ocorreu uma leve queda nos roubos em saída de bancos e em transportes coletivos – cerca de 15 e 20%, respectivamente.

## 6.2 Estudo dos *clusters* espaciais por meses

A análise espacial dos roubos teve como foco a identificação de *clusters* espaciais significativos em Boa Viagem e Pina considerando diferentes escalas de tempo. Inicialmente foi tratada a divisão mensal para os anos de 2019, 2020 e 2021 (janeiro a maio).

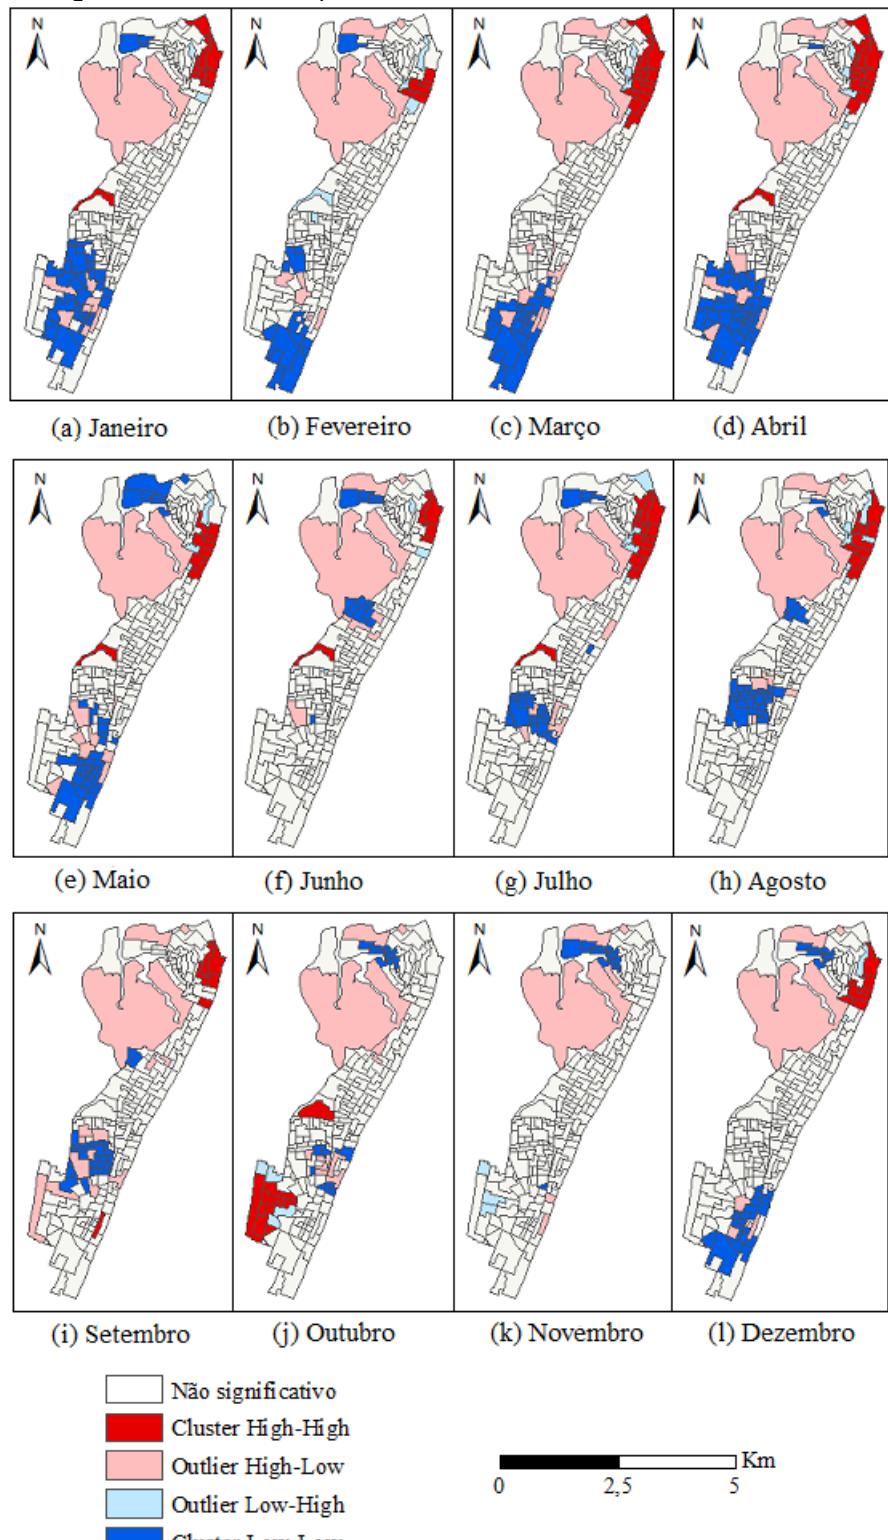
### 6.2.1 *Clusters* espaciais mensais em 2019

A Figura 12 comporta a localização destes *clusters* durante os meses do ano de 2019. Em janeiro (Figura 12(a)), foram percebidos *clusters* do tipo High-High (HH) no nordeste e no centro-oeste da região de estudo. O do nordeste é caracterizado por um perfil etário misto, visto que a população idosa se apresenta entre o primeiro (0-20%), o quarto (60-80%) e o quinto (80-100%) quintis. Há também uma mescla em termos de renda (setores em todos os quintis), cor da população (brancos, pretos e pardos no quarto ou quinto quintis, a depender do setor) e acesso à infraestrutura (maioria dos fatores no quarto e quinto quintis na orla; primeiro e segundo quintis nos demais locais). É uma área pouco povoada ('denspop' no primeiro quintil) e com domínio dos domicílios alugados (maioria no quinto quintil).

Por sua vez, o *cluster* HH do centro-oeste (ainda em janeiro) também apresenta densidade populacional baixa (primeiro quintil), mas a renda é moderada (terceiro quintil) e com alta variação (quarto quintil) – sendo ambos abaixo do padrão no nordeste. Há condições medianas de infraestrutura (terceiro quintil), sendo precárias em esgotamento sanitário (primeiro quintil). Apresentam maior destaque a população branca (terceiro quintil; enquanto pardos no segundo quintil e pretos no primeiro quintil), idosa e economicamente ativa (ambas no terceiro quintil, enquanto crianças no segundo quintil).

Em janeiro de 2019 (Figura 12(a)), havia dois *clusters* do tipo Low-Low (LL), um ao sul e outro a noroeste. O LL do sul é caracterizado por uma população mais idosa (quarto quintil), economicamente ativa (quinto quintil), branca (quinto quintil) e alfabetizada (maioria no quinto quintil) que a dos HH; porém são igualmente pouco povoados (primeiro quintil). Apesar de compreender áreas ricas (renda no quinto quintil), a maioria do LL tem renda baixa (segundo quintil). Há um ótimo acesso à infraestrutura (água, lixo, pavimentação e iluminação pública no quinto quintil – em maioria). No centro do LL, porém, há um grupo de setores menos favorecidos (primeiro e segundo quintis em infraestrutura) e mais adensados (quarto e quinto quintis). Por fim, o LL do sul é intercalado por setores High-Low (HL), que se distinguem só por ter uma população mais velha (quinto quintil, em maioria).

Figura 12 - Clusters espaciais de roubos durante os meses de 2019



Fonte: O autor (2022)

O cluster LL de janeiro a noroeste é composto por dois setores censitários de perfis bastante opostos. A respeito dos fatores etários, de infraestrutura, de densidade populacional e de alfabetização, um setor pertence ao primeiro e segundo

quintis, enquanto o outro ao quarto e quinto quintis. A semelhança deles está na renda e na variação da renda serem muito baixas (primeiro quintil). A população branca (primeiro e quarto quintis) é menos evidente do que os pretos e pardos (terceiro e quinto quintis, respectivamente), divergindo do LL do sul.

Alguns padrões se modificaram em fevereiro (Figura 12(b)). Os *clusters* HH ficaram apenas nas áreas menos favorecidas do HH de janeiro a nordeste em relação à infraestrutura (fatores do primeiro ao terceiro quintis), porém com renda maior (quarto e quinto quintis). Essas áreas apresentam uma população mais velha (maioria com 'id\_66\_' em quintis elevados), com cor mista (pretos e brancos entre os maiores quintis). Há apenas um setor censitário destoante mais ao interior, o qual detém renda baixa (primeiro quintil) e população predominantemente preta (quinto quintil). Ressalta-se que um setor migrou de HH para LH (Low-High) – isto é, os roubos diminuíram significativamente ao seu redor –, no qual se evidencia a população preta (quinto quintil) e a renda baixa (segundo quintil).

Os *clusters* LL em fevereiro se deslocaram mais em direção ao sul, enquanto parte do centro se tornou HL (isto é, houve aumento significativo de roubos). Ademais, o HH ao centro-oeste de janeiro se tornou LH (isto é, houve redução significativa em relação ao entorno), local este que é vizinho ao shopping Recife. Nas proximidades também há duas áreas LH com alta densidade populacional (quarto quintil) e população mais jovem ('id\_0\_14' no quinto quintil).

No noroeste, em fevereiro surgiu uma área HL na qual se situa o shopping center Rio Mar. Contudo, o shopping foi inaugurado em 2012, mas na época do Censo 2010 a área era composta por manguezais e comunidades ribeirinhas. Por este motivo, os índices de infraestrutura, renda e alfabetização são extremamente baixos (maioria no primeiro quintil).

Nos meses de março (Figura 12(c)) e abril (Figura 12(d)), o HH a nordeste se expandiu para a mesma área ocupada em janeiro e para setores em direção ao sul. Estes últimos são locais com renda elevada (quinto quintil), boa infraestrutura urbana (fatores do segundo ao quarto quintis) e com população branca (quintis superiores a pretos e pardos) e mais velha ('id\_66\_' acima das demais faixas). As áreas LH do nordeste e do centro-oeste voltaram a ser HH. No sul, o LL aumentou em comparação a fevereiro, incluindo áreas com mais pardos e pretos (quintis superiores a brancos) e boa infraestrutura urbana ('pavim', 'ilum\_pub' e 'lixo' no quinto quintil), porém com renda baixa e homogênea ('renda' e 'var\_renda' no

segundo quintil). Em maio (Figura 12(e)), o padrão espacial se manteve, exceto pela leve redução nas áreas HH e LL e pelo surgimento de uma LL a noroeste (inclusive convertendo um setor HL em LL).

Em junho (Figura 12(f)), o LL do sul deixou de ser significativo. Por sua vez, a área HH do nordeste reduziu e se deslocou rumo ao norte, porém manteve características similares às verificadas em maio. Surgiu um novo LL no centro-norte da região, composto por duas localidades com características diametralmente opostas. Os setores LL vizinhos ao Parque dos Manguezais possuem: renda muito baixa (primeiro e segundo quintis); infraestrutura precária (maioria dos fatores no primeiro e segundo quintis); e alfabetização deficitária (segundo e terceiro quintis); população mais preta e parda (terceiro e quinto quintis); e baixa densidade populacional (segundo quintil). Por outro lado, há setores LL com renda elevada (quarto e quinto quintis), boa infraestrutura (geralmente do terceiro ao quinto quintis) e alfabetização (quarto quintil), além de população mais branca (quarto e quinto quintis) e densidade populacional razoável (segundo ao quinto quintis). A semelhança entre essas duas áreas LL é apenas a população ser mais jovem ('id\_0\_14' no quarto e quinto quintis).

No mês de julho (Figura 12(g)), a área HH foi similar à de abril. O LL do centro-norte deixou de ser significativo, enquanto outro surgiu ao centro-sul. Este último contém uma população branca mais evidente (quinto quintil; pretos no primeiro quintil), renda moderada (terceiro quintil) e pior infraestrutura (segundo e terceiro quintis) que os LL do centro-norte de junho. Este LL é rodeado por setores HL constituídos por população mais branca (terceiro quintil), menos alfabetizada (segundo quintil), com renda similar ou um pouco superior ao LL (terceiro e quarto quintis) e infraestrutura um quintil abaixo do LL. Por fim, um setor censitário no centro-sul com área maior que a vizinhança passou de HL (desde abril) para LL (idem a janeiro e fevereiro). Ele é similar aos LL vizinhos, mas bem menos povoado (primeiro quintil).

Em agosto (Figura 12(h)) houve praticamente uma junção dos LL de junho e julho rodeada por HL, com uma leve redução no HH. Surgiram dois LL a noroeste, tal que um deles de renda baixa (primeiro quintil) e população mais preta e parda (quarto quintil), enquanto o outro mais abaixo tem renda elevada (quinto quintil) – sendo o único naquela localidade (a maioria dos vizinhos estão no primeiro quintil). Ambos têm baixa densidade populacional.

No mês de setembro (Figura 12(i)) as áreas HH e LL diminuíram. No lugar das LL surgiram HL nas proximidades, tanto no centro-sul quanto no sudoeste. Eles apresentam características similares, exceto pela renda menor (segundo quintil) daqueles do sudoeste. Um setor HH isolado também se tornou significativo no sudeste, no qual se verifica uma população mais branca (quinto quintil) e de renda elevada (quinto quintil), com baixa densidade populacional (segundo quintil) e servida com uma boa infraestrutura (terceiro e quarto quintis).

Outubro (Figura 12(j)) é marcado por padrões espaciais totalmente diferentes em relação aos meses anteriores. A área que tinha sido HL em setembro no sudoeste (e que era LL em abril) se tornou HH (e rodeada por LH). Nestes locais, evidencia-se a população preta (maioria no quinto quintil) e a renda baixa (maioria no segundo quintil), porém há elevada alfabetização (maioria no quinto quintil) e boa infraestrutura (exceto 'esgoto' no primeiro quintil). A área é pouco povoada (primeiro e segundo quintis) e com residentes consideravelmente jovens (quinto quintil de 'id\_0\_14' e 'id\_15\_65' predomina).

Ainda neste mês (Figura 12(j)), o HH do nordeste e o LL de setembro no centro-sudoeste deixaram de ser significativos. No centro-sudoeste, surgiram áreas HL (rodeadas por LL) na vizinhança mais próxima à orla (parte tinha sido LL, parte HL em julho). Elas são marcadas por: uma renda baixa (segundo e terceiro quintis); infraestrutura ruim (maioria no segundo quintil); população mais branca (terceiro quintil) e idosa (quarto e quinto quintis); e baixa alfabetização (segundo quintil).

Em outubro também ressurgiu o LL do noroeste, porém com extensão espacial maior do que em agosto. Vale ressaltar que esta é uma área: densamente povoada (terceiro e quinto quintis); de população mais nova ('id\_0\_14' no terceiro quintil; os demais em inferiores), preta e parda (ambos no quarto e quinto quintis); de renda baixa (primeiro quintil), exceto por um setor no quinto quintil; e de infraestrutura precária (primeiro quintil em todos os fatores).

Ainda em outubro (Figura 12(j)) surgiu um HH no centro-oeste onde se localiza o shopping center Recife (entre abril e julho, havia HH na vizinhança). No ambiente se verifica uma população mais parda (terceiro quintil); de renda elevada (quarto quintil); uma maioria de domicílios próprios (terceiro quintil); e acesso ruim à infraestrutura urbana (esgotamento sanitário, iluminação pública, água encanada e pavimentação no segundo quintil).

No mês de novembro (Figura 12(k)), todas as áreas HH deixaram de ser significativas, sendo que parte desses setores se converteram em LH. Por outro lado, o LL do noroeste se expandiu para um setor censitário que havia sido parte deste tipo de *cluster* em julho. Apareceu também um HL no sudeste em áreas de renda elevada (quinto quintil) próximas à orla.

Por fim, em dezembro (Figura 12(l)) ressurgiram *clusters* LL ao sul (vistos pela última vez em maio) e HH no nordeste (que haviam desaparecido desde setembro). O LL localizado no noroeste se manteve significativo. Assim, notou-se um retorno a um padrão espacial bastante próximo ao que se fez presente no início do ano no que concerne à localização dos *clusters*.

### 6.2.2 *Clusters* espaciais mensais em 2020

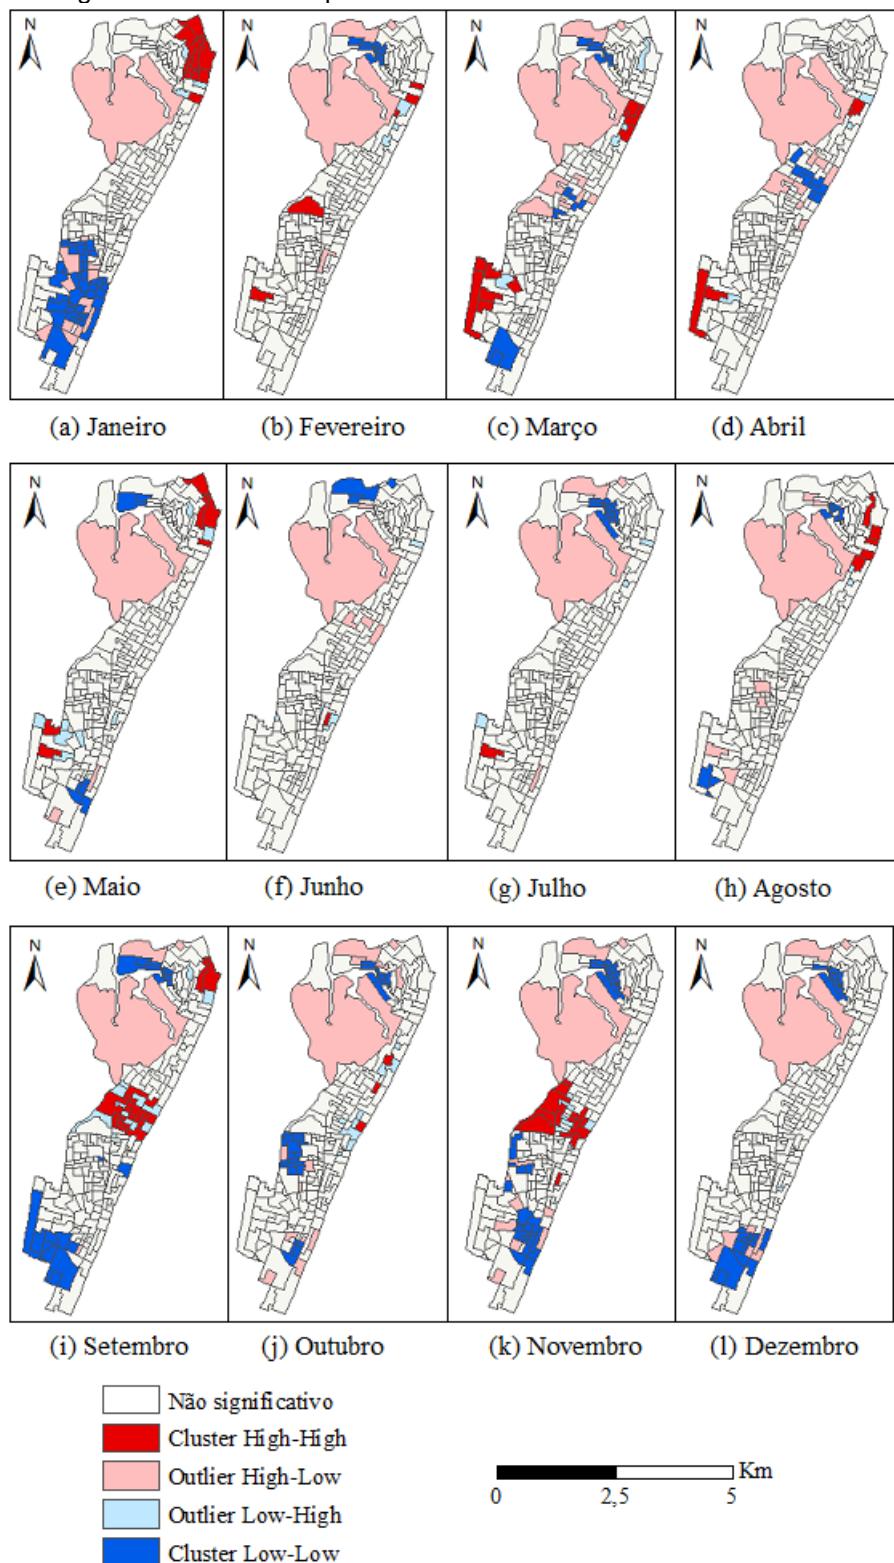
Os *clusters* de roubos em Boa Viagem e Pina referentes ao acumulado mensal durante o ano de 2020 estão dispostos na Figura 13. Em janeiro (Figura 13(a)), a localização de áreas HH e LL é similar ao percebido em janeiro de 2019, exceto pelo setor HH no centro-oeste que deixou de ser significativo. Por sua vez, em fevereiro (Figura 13(b)) houve uma redução drástica do HH do nordeste e o ressurgimento do LL do noroeste (que existiu até dezembro de 2019). Neste mês, retornou o HH do centro-oeste onde se localiza o shopping Recife, assim como um HH menos privilegiado no sudoeste (ambos vistos pela última vez em outubro de 2019).

Março (Figura 13(c)) se destaca pelo início da pandemia e pelas medidas restritivas a partir da segunda quinzena. Apesar disso, os *clusters* LL e HL do noroeste se mantiveram. Na região central, surgiram setores HL (com 'denspop' no primeiro quintil) e LL. Os últimos possuem: alta densidade populacional (quarto e quinto quintis); população mais idosa (quinto quintil), branca (quarto quintil) e bem alfabetizada (quinto quintil); renda moderada (terceiro quintil) e heterogênea ('var\_renda' no quinto quintil); provisão de infraestrutura razoável (todos os fatores no quarto e quinto quintis); e mais domicílios alugados (quinto quintil).

Ainda em março (Figura 13(c)), o *cluster* HH do nordeste se deslocou em direção ao sul, para áreas semelhantemente bem desenvolvidas: renda alta (quarto e quinto quintis); infraestrutura satisfatória (a maioria pelo menos no terceiro quintil); população mais velha ('id\_66\_' pelo menos no quarto quintil); baixa densidade populacional (primeiro quintil); e predominância de domicílios próprios (terceiro

quintil). Por fim, o HH que se tornou significativo no sudoeste tem localização similar ao existente em outubro de 2019.

Figura 13 - Clusters espaciais de roubos durante os meses de 2020



Fonte: O autor (2022)

No mês de abril (Figura 13(d)) ocorreu uma redução ou desaparecimento massivo dos *clusters* e *outliers*. Por se tratar de um período bastante restritivo da pandemia, então houve menor circulação de pessoas nas ruas e, consequentemente, menos alvos em potencial para os criminosos. Apenas o LL se expandiu ao centro-norte para áreas de renda elevada e boa infraestrutura (ambos predominantemente no quarto quintil). Por outro lado, os setores LL do noroeste e do sul deixaram de ser significativos. Já os *clusters* HH do nordeste e do sudoeste reduziram a sua extensão. De um modo geral, nota-se um padrão fortemente distinto de abril de 2019 (Figura 13(d)), no qual havia um grande LL no sul e um HH muito maior no nordeste.

Em maio (Figura 13(e)) as autoridades públicas decretaram a quarentena mais rígida na segunda quinzena do mês. A área LL da porção central desapareceu, enquanto o HH do nordeste visto pela última vez em janeiro retornou (área socioeconomicamente privilegiada). Por sua vez, os setores HH do sudoeste se deslocaram para áreas pouco privilegiadas, mas ainda próximas às de abril. Por fim, uma nova área LL adveio no sudeste, sendo ela caracterizada por: uma população mais jovem ('id\_0\_14' pelo menos no quarto quintil), bem alfabetizada e branca (ambos no quarto quintil, pelo menos); pouca densidade populacional (segundo quintil); boa infraestrutura (pelo menos no quarto quintil); e mais domicílios próprios (quinto quintil).

Nos meses de junho (Figura 13(f)) e julho (Figura 13(g)) iniciou a reabertura gradual dos serviços não-essenciais. Poucos *clusters* se mostraram significativos. Em junho, algumas áreas LL no centro-norte de abril se tornaram HL, enquanto as HH do nordeste sumiram. O LL do noroeste transitou para HL em julho, enquanto o LL em região próxima existente em fevereiro e março ressurgiu (a qual contém áreas menos privilegiadas e de população mais preta e parda).

Em agosto (Figura 13(h)), o *cluster* HH do nordeste reapareceu, porém em menor extensão, em uma localização similar a agosto de 2019. Ainda em comparação ao mesmo período de 2019, os LL do centro-norte e centro-sudoeste não se mantiveram, sendo alguns substituídos por HL. Já o *cluster* LL se deslocou rumo ao sudoeste, onde há: renda baixa (segundo quintil); infraestrutura razoável (água, lixo e iluminação pública no quarto quintil; esgoto e pavimentação no segundo quintil); e população predominantemente parda e preta (ambos no quarto quintil). Por fim, o LL do noroeste se manteve, porém com área reduzida.

No mês de setembro (Figura 13(i)) se manifesta um padrão espacial novo até então. A área onde havia alguns setores LL e HL entre março e abril no centro da região se tornou HH. Nela há uma ótima infraestrutura (maioria dos fatores acima do quarto quintil) e uma população branca, rica e alfabetizada (os três fatores pelo menos no quarto quintil). Além disso, o *cluster* LL verificado no sul em março retornou, mas agregando uma área tida como HH em março e abril no sudoeste. Em suma, percebe-se uma configuração bastante diferente da percebida em setembro de 2019, exceto pela existência do HH no nordeste da região de estudo.

Em outubro (Figura 13(j)) houve uma redução drástica nos *clusters* HH do centro. Ademais, o HH do nordeste sumiu, mas o LL e o HL do noroeste se mantiveram. Na região sul, os setores LL foram reduzidos e circundados por HL. Já o LL que surgiu no centro-sul abrangeu duas áreas vizinhas distintas: numa predomina a população branca de renda elevada (ambos no quinto quintil) e pouco adensada (primeiro quintil), enquanto na outra prevalecem pretos e pardos (ambos no quinto quintil) com baixa renda (primeiro quintil) e bem adensados (quarto quintil). Contudo, ambas as áreas detêm população mais jovem ('id\_0\_14' ao menos no terceiro quintil). Comparando a outubro de 2019, o padrão é similar ao norte, mas diverge ao sul.

O mês de novembro (Figura 13(k)) é distinguido pela retomada de padrões espaciais similares aos de setembro. Contudo, o HH do nordeste não ressurgiu e houve um deslocamento dos *clusters* LL para áreas mais ricas, com melhor infraestrutura e densamente povoadas (todos pelos menos no quarto quintil) próximas à orla. Assim como ocorreu em outubro, a configuração ao norte é similar ao que se viu em novembro de 2019, mas ao sul não.

Por fim, em dezembro (Figura 13(l)) nota-se uma formação de *clusters* similar à do mês anterior, principalmente quanto aos setores LL do noroeste e do sul que se mantiveram. Em contrapartida, as áreas HH no centro e LL no centro-sul deixaram de ser significativas. Em comparação a dezembro de 2019, apenas o HH do nordeste não apareceu desta vez, ao passo que o restante é similar.

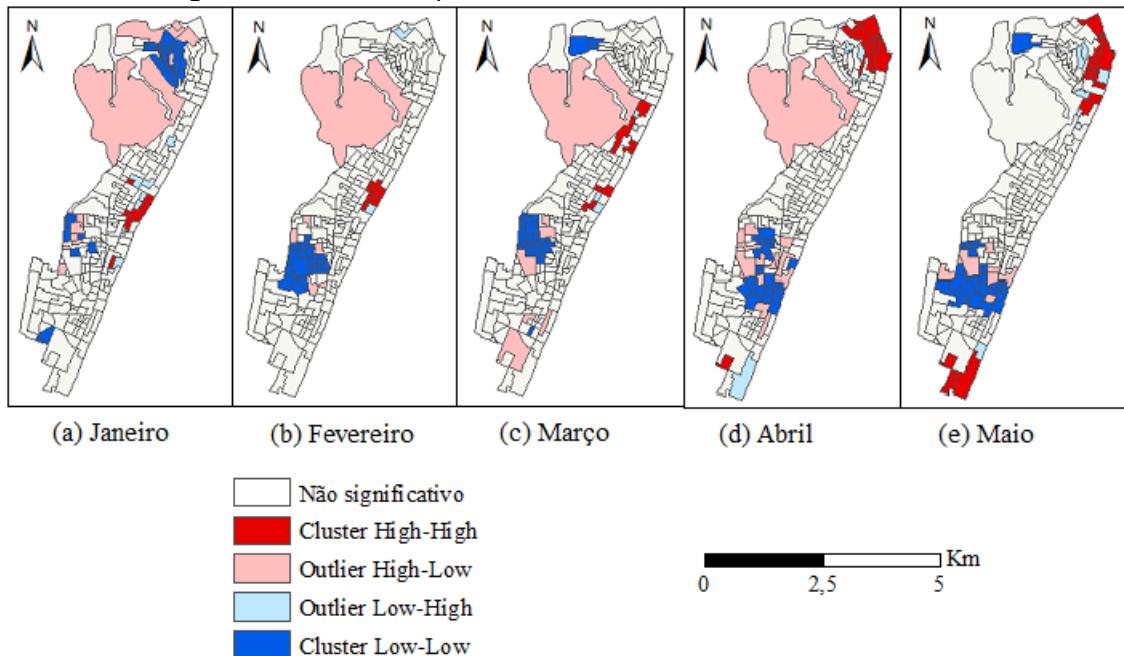
### 6.2.3 Clusters espaciais mensais em 2021

Os *clusters* de roubos referentes aos cinco meses iniciais do ano de 2021 para os quais há disponibilidade de dados georreferenciados estão expostos na Figura

14. Em janeiro (Figura 14(a)), a área HH do centro-leste (vista pela última vez em novembro de 2020) ressurgiu em extensão menor e mais próxima à orla, em áreas mais ricas, com melhor infraestrutura e população mais idosa (todos estes fatores pelo menos no quarto quintil, na maioria dos setores). O LL realçado em outubro de 2020 no centro-sul também reapareceu, mas mesclado com áreas HL. Por sua vez, o LL do noroeste se expandiu em relação ao de dezembro de 2020. Ao comparar com os dois anos anteriores, nota-se um padrão bastante distinto dos janeiros pré-pandemia. Em linhas gerais, surgiram novos *clusters* ao centro, não houve setores HH no nordeste e o LL do sul foi reduzido a dois setores apenas, além de que o LL do noroeste se manteve (porém expandido).

Em fevereiro (Figura 14(b)), os *clusters* LL no noroeste e no sul desapareceram, enquanto o LL do centro-sul se expandiu para áreas antes tidas como HL. São constatadas diferenças relevantes em relação aos dois fevereiros imediatamente pré-pandemia, visto que a área HH se moveu do nordeste para o centro-leste e o LL do sul foi deslocado em direção ao centro.

Figura 14 - *Clusters* espaciais de roubos durante os meses de 2021



Fonte: O autor (2022)

O mês de março (Figura 14(c)) retrata o início do retorno do *cluster* HH existente no nordeste, enquanto o HH do centro-leste e o LL do centro-sul foram levemente reduzidos. Por outro lado, alguns setores HL começam a surgir no centro-

sul em torno dos LL, contendo áreas de boa infraestrutura (a maioria dos fatores no quinto quintil), população mais velha ('id\_66\_' no quinto quintil) e renda elevada (maioria no quinto quintil). Em comparação a março de 2019, não havia HH no centro-leste e o HH do nordeste era maior e localizado mais ao norte, enquanto em março de 2021 algumas áreas LL do sul se tornaram HL. Em relação a março de 2020, repara-se que parte das áreas LL e HL do centro-leste se tornaram HH, o HH do centro-sul deixou de ser significativo e o LL do sul se transformou em HL.

Abril (Figura 14(d)) representa o retorno do *cluster* HH do nordeste típico do período pré-pandêmico. Como destaque tem-se a expansão da área LL do centro-sul em direção às áreas mais privilegiadas da orla. Surgiu também o primeiro setor HH no extremo sul desde o início das análises. No local há infraestrutura bem estabelecida (quarto ou quinto quintis, na maioria dos setores), população mais jovem ('id\_0\_14' no quinto quintil) e renda baixa (segundo quintil). Em abril de 2019 (Figura 12(d)), em geral, o padrão espacial era bastante parecido, divergindo pela extensão das áreas LL mais próximas do sul e pela ausência do HH no extremo sul. Por sua vez, em abril de 2020 (Figura 13(d)) havia *clusters* LL no centro-norte, poucos setores HH no nordeste (porém mais deslocados ao sul) e a região sudeste continha setores HH.

Enfim, em maio de 2021 (Figura 14(e)), constata-se que a distribuição espacial de abril se manteve, porém com uma distensão do HH do nordeste em direção ao sul, e o LL do centro-sul em direção ao oeste. Além disso, o *cluster* HH no extremo sul se expandiu. Ele se distingue por conter apenas um setor com renda elevada (quarto quintil) – o qual é próximo à orla e similar ao HH do sul de abril de 2020 nos outros fatores –, enquanto os demais setores estão no segundo quintil da renda. Ademais, o setor localizado por trás do que se situa junto à orla apresenta uma população mais jovem ('id\_0\_14' no terceiro quintil), mas detém infraestrutura precária (segundo quintil). Em maio de 2019 (Figura 12(e)), as características espaciais eram bastante parecidas, porém o LL do noroeste era maior e não havia o HH no extremo sul (mas sim no centro-oeste). Por fim, maio de 2020 (Figura 13(e)) apresenta um padrão mais distinto devido ao auge das medidas restritivas. Neste mês o padrão ao norte era semelhante, mas existia um HH no sudeste ao invés do extremo sul, assim como o LL do sul era menor.

### 6.3 Estudo dos *clusters* espaciais por estações do ano

Em um novo recorte temporal, revelou-se *clusters* espaciais referentes ao acumulado de roubos em Boa Viagem e Pina por estações do ano. Os resultados estão na Figura 15. Vale ressaltar que o período do verão levou em consideração os últimos dias de dezembro do ano anterior, pois, em análise separada, estes poucos dias não eram suficientes para formar *clusters* e não alteraram o resultado final quando agregados. Além disso, no outono de 2021 só se investigou dados de 20 de março a 31 de maio de 2021 devido à limitação da fonte, isto é, faltaram os roubos ocorridos nos dias seguintes até 21 de junho do mesmo ano.

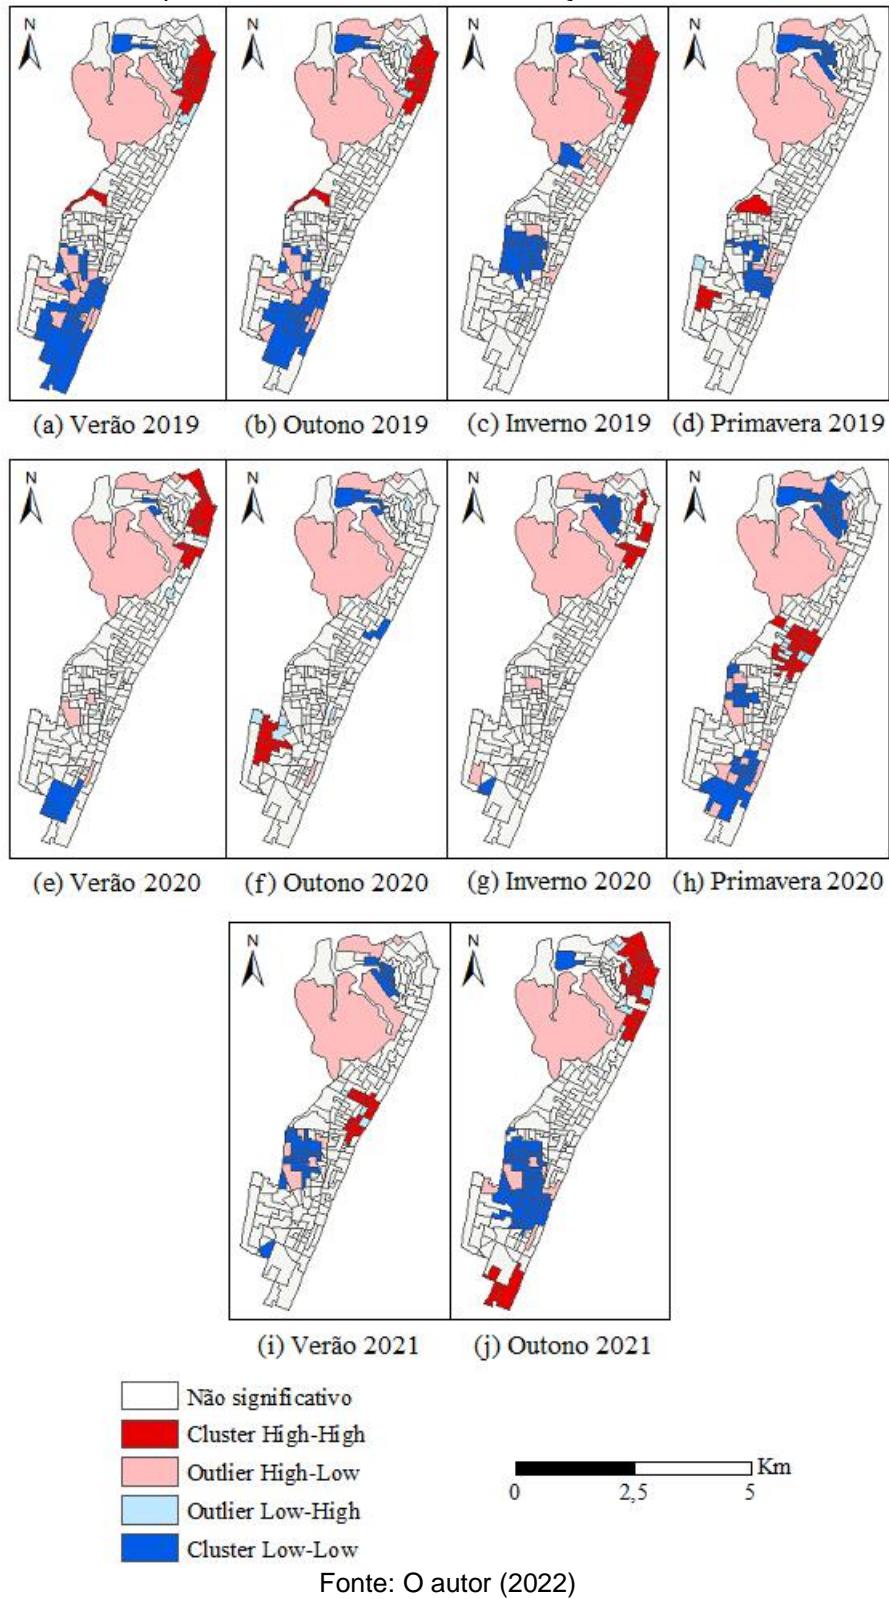
O padrão espacial no verão de 2020 pouco foi afetado pela pandemia, visto que ela foi decretada em 11 de março e o verão findou em 20 de março de 2020 (mais os últimos dias de dezembro de 2020). Assim, o verão de 2020 (Figura 15(e)) demonstrou *clusters* HH e LL em locais similares ao verão de 2019 (Figura 15(a)). A diferença entre eles está na redução dos LL no sul em áreas consideradas majoritariamente menos privilegiadas (exceto as próximas à orla) e na extinção do HH no centro-oeste. Ambos os locais já foram discutidos nos estudos por mês.

No verão de 2021 (Figura 15(i)) – já inserido na pandemia, mas em um contexto de flexibilização de restrições – ocorreu um posicionamento totalmente diferente dos HH: ao invés do nordeste, eles surgiram no centro-leste, próximos à orla. Em relação à 2019 (Figura 15(a)), os LL do centro-sul foram expandidos em direção à vizinhança do shopping Recife, enquanto restou apenas um setor deste tipo no sul.

Entre o outono de 2019 (Figura 15(b)) e o de 2020 (Figura 15(f)), nota-se um deslocamento do HH das áreas mais desenvolvidas no nordeste para o sudoeste, o qual apresenta condições menos privilegiadas em renda e infraestrutura. O LL do sul deixou de ser significativo, surgindo um menor em extensão no centro-leste, numa área bem desenvolvida. Enfim, o LL do noroeste em local com condições de vida precárias se manteve.

O padrão verificado em outono de 2021 se tornou mais semelhante ao do outono de 2019 (pré-pandemia) na porção norte da região. Já na porção sul, o LL se deslocou em direção ao centro, perpassando por uma mescla de áreas ricas (próximas à orla) e outras mais pobres. Também surgiu um HH no extremo sul, o qual foi previamente abordado na análise de maio de 2021 (Figura 14(e)).

Figura 15 - Clusters espaciais de roubos durante as estações dos anos de 2019, 2020 e 2021



No que tange ao inverno de 2020 (Figura 15(g)), o LL do noroeste se expandiu para áreas com privação socioeconômica em comparação a 2019 (Figura 15(c)). Por sua vez, o HH continuou sendo significativo nos locais predominantemente

privilegiados a nordeste, mas teve as suas dimensões reduzidas. Os setores LL situados no centro-norte e centro-sudoeste deixaram de ser relevantes estatisticamente, ao passo que surgiu um novo setor LL ao sul.

Durante a primavera de 2020 (Figura 15(h)), os HH se deslocaram de áreas menos privilegiadas no sudoeste e centro-oeste (a qual contém o shopping Recife) realçadas em 2019 (Figura 15(d)) para áreas mais ricas e desenvolvidas no centro-leste. O *cluster* LL cresceu rumo ao sul, onde se encontra melhor infraestrutura, taxa de alfabetização (quinto quintil é maioria) e a população é mais jovem ('id\_0\_14' no quinto quintil).

É importante ressaltar o *outlier* HL localizado no extremo noroeste, no qual se situa o shopping Rio Mar. Com exceção do verão de 2019 e do outono de 2021, ele se mostrou significativo ao longo de todo o período analisado. Como característica local tem-se o contraste entre o grande fluxo comercial devido ao empreendimento e a sua vizinhança repleta de setores com baixa renda e infraestrutura deficitária (e que frequentemente se tornaram LL).

#### 6.4 Estudo dos *clusters* espaciais por dias da semana

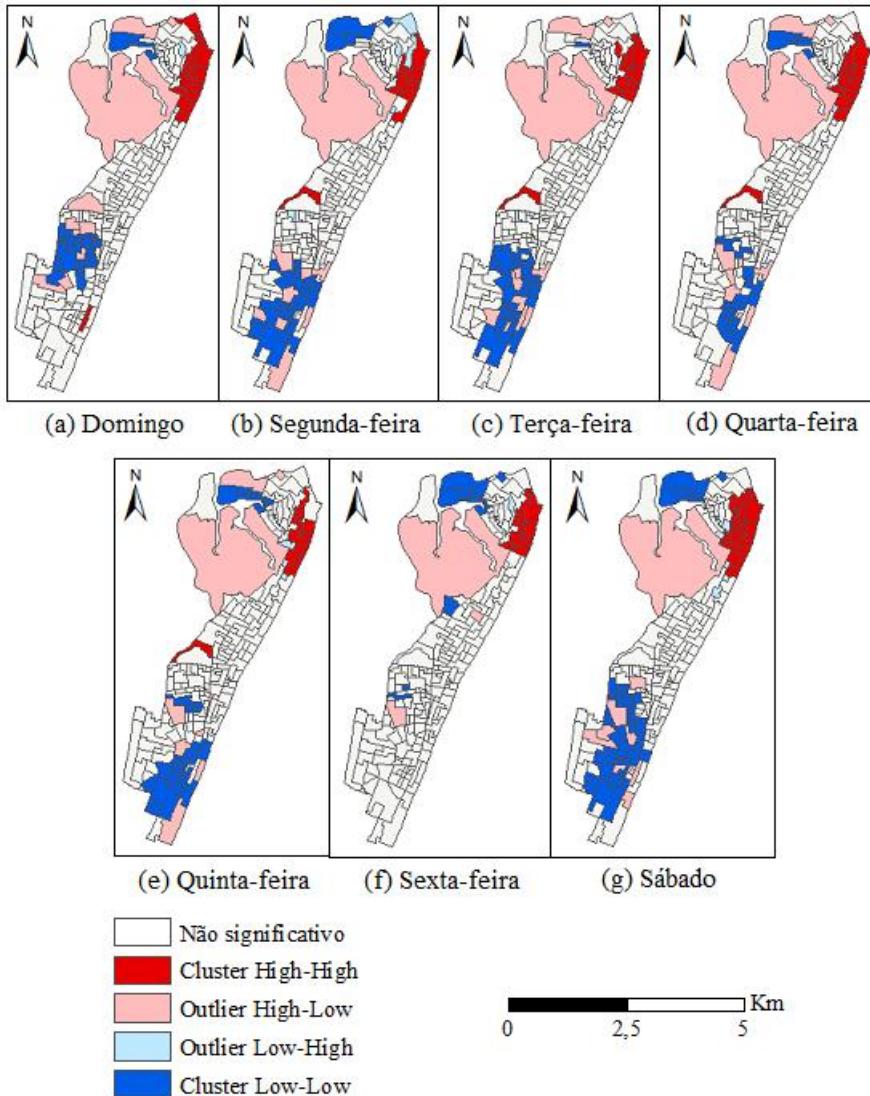
A concentração espacial dos roubos também foi explorada de acordo com os dias da semana. Foram examinados dois recortes temporais: o ano pré-pandêmico de 2019 (Figura 16) e o período da pandemia (Figura 17) para o qual se tem dados de roubos (11 de março de 2020 a 31 de maio de 2021).

A respeito de 2019 (Figura 16), os padrões espaciais encontrados na segunda, terça, quarta, quinta-feira e sábado são bastante similares entre si. A exceção se dá por leves variações na extensão do HH no nordeste e do LL no noroeste, porém ambos passaram a compreender setores com características similares.

No domingo (Figura 16(a)) e na sexta-feira (Figura 16(f)), a porção norte da região apresentou localizações semelhantes para os *clusters* HH e LL. Porém, no domingo o LL se concentrou no centro-sudoeste da região (em áreas com densidade populacional e população branca no quinto quintil), rodeado por setores HL (áreas de baixa renda – segundo quintil – e população preta no quinto quintil). No domingo também existiu um setor HH isolado no sudeste, marcado por: uma população mais branca (quinto quintil) e com renda elevada (quinto quintil), boa infraestrutura urbana (terceiro e quarto quintis) e baixa densidade populacional.

No que se refere à sexta-feira (Figura 16(f)), surgiu um LL no centro-norte com setores cujas características eram opostas em termos de renda (segundo e quinto quintil) e cor da população (brancos no quinto quintil em um; pardos no quinto quintil no outro), porém ambos possuem população jovem ('id\_0\_14' no quarto e quinto quintis). Além disso, houve uma diminuição considerável no tamanho do LL existente no centro-sul.

Figura 16 - Clusters espaciais de roubos durante os dias da semana no ano de 2019



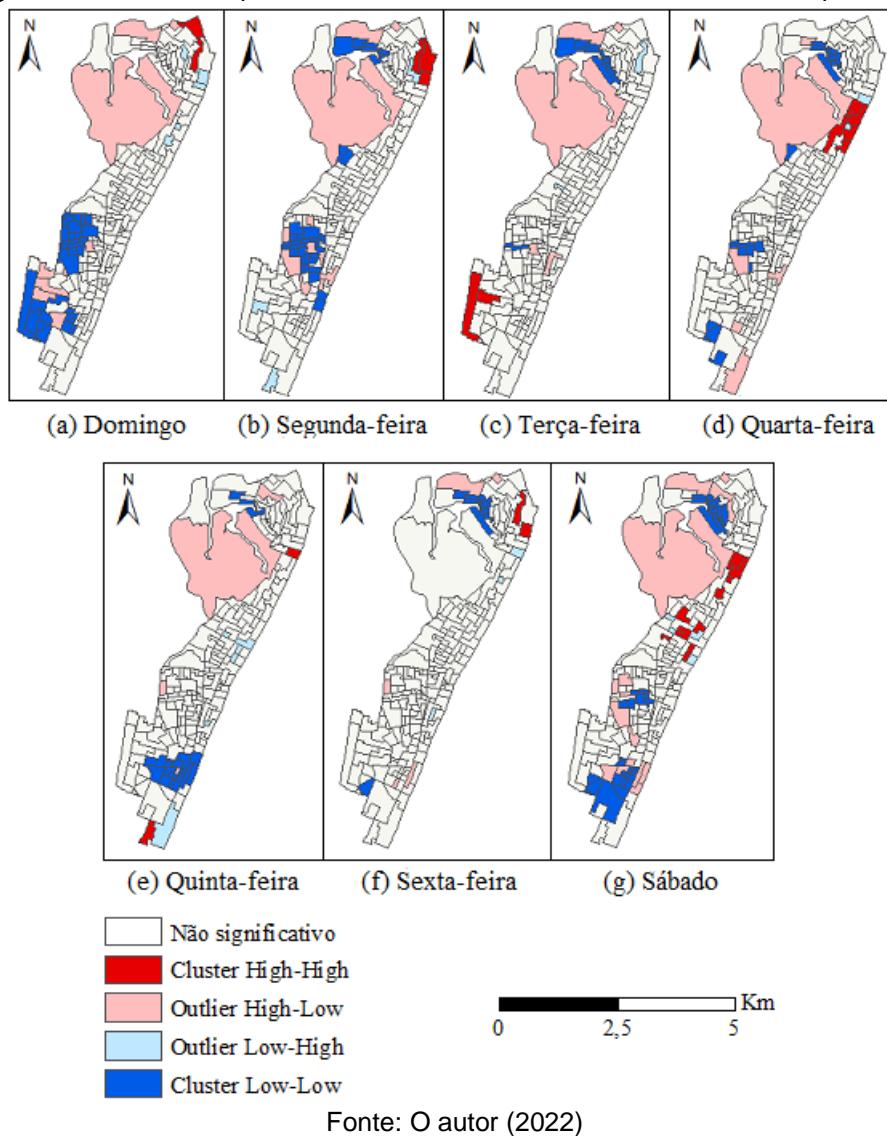
Fonte: O autor (2022)

A distribuição espacial dos *clusters* durante a pandemia (Figura 17) revelou padrões notavelmente distintos entre os dias da semana. Domingo e segunda-feira têm um HH no nordeste em setores vizinhos. O LL localizado no centro-sul apresenta uma área similar em ambos os dias. Contudo, no domingo este *cluster* se estende para os setores menos favorecidos do sudoeste, enquanto na segunda

surgiu um LL no sudeste (mais desenvolvido e próximo à orla). Ademais, o LL menos privilegiado no noroeste aparece na segunda, mas não no domingo. Por fim, na segunda-feira apareceu um LL no centro-norte igual ao da sexta-feira de 2019.

Na terça-feira ao longo da pandemia (Figura 17(c)), parte da região sudoeste que era LL no domingo se tornou HH, ao passo que o HH do nordeste deixou de ser significativo. Já o *cluster* LL do noroeste se expandiu para áreas menos privilegiadas similares, porém com maior densidade populacional (quinto quintil).

Figura 17 - Clusters espaciais de roubos durante os dias da semana na pandemia



Fonte: O autor (2022)

Verificou-se na quarta-feira (Figura 17(d)) que o HH com melhores condições socioeconômicas do nordeste reapareceu, assim como parte do LL do centro-norte (antes visto nas segundas-feiras da pandemia) e o do centro-sul se expandiu. No sul da região de estudo, advieram alguns LL em áreas menos favorecidas em termos de

renda e acesso à iluminação pública e pavimentação (primeiro quintil). Já no extremo sul, na faixa litorânea, um novo HL surgiu no extremo sul (tal qual nas quartas-feiras de 2019), caracterizado pela infraestrutura adequada (quarto ou quinto quintis na maioria dos fatores), pela renda baixa (segundo quintil) e pela população mais jovem ('id\_0\_14' no quinto quintil).

Nos dias de quinta-feira (Figura 17(e)), os *clusters* HH e LL ao norte da região de estudo diminuíram, enquanto o LL localizado no sul se aproximou da área mais rica, próxima à orla. O HL do extremo sul se tornou LH, e ao seu lado surgiu um novo HH numa área pouco privilegiada em termos de renda (segundo quintil) e infraestrutura (maioria dos fatores no segundo quintil) e cuja população é jovem ('id\_0\_14' fator etário mais alto, no terceiro quintil).

Na sexta-feira (Figura 17(f)), os setores do tipo LL e HH presentes no norte da região se expandiram levemente, ao mesmo tempo em que o LL do sul foi reduzido a apenas um setor censitário. Este foi o único dia da semana (e um dos poucos recortes temporais investigados, em geral) em que o maior setor censitário da área, o qual comporta o Parque dos Manguezais, não se mostrou um *outlier* HL significativo. Por fim, nos sábados da pandemia (Figura 17(g)), os *clusters* LL do norte e do sul se expandiram, assim como surgiu um novo no centro-sul. A respeito dos setores HH, o situado no nordeste se deslocou em direção ao sul e surgiu um novo *cluster* deste tipo na porção central da região também.

Ao comparar o ano de 2019 (Figura 16) com o período pandêmico (Figura 17), apenas o domingo e a segunda-feira têm um padrão semelhante, exceto: pelo surgimento de um LL perto do sul no domingo e do deslocamento do LL do sul visto na segunda-feira rumo ao centro. Na terça-feira, o LL do centro-sul foi praticamente extinto durante a pandemia, restando apenas dois setores censitários. Neste dia também apareceu um HH em áreas pouco privilegiadas no sul, enquanto o HH do nordeste deixou de ser significativo e o LL do noroeste se expandiu.

Houve, na quarta-feira, um deslocamento destinado ao sul do HH do nordeste e uma forte redução na extensão do LL do sul comparado a 2019, sobrando apenas duas partes pequenas (uma ao sul e outra no centro-sul). Por sua vez, na quinta-feira houve uma redução na extensão dos *clusters* ao norte, embora tenham se mantido em localidades próximas. No extremo sul, o setor HL se tornou LH, ao lado do qual adveio durante a pandemia um novo HH em área menos desenvolvida.

Na sexta-feira, reduziram-se o HH e o LL situados ao norte (no bairro do Pina), embora estivessem na mesma faixa territorial verificada em 2019. Neste dia os LL se movimentaram do centro para o sul, porém mantendo-se em pequena quantidade de setores. Enfim, no sábado ocorreu um avanço do HH do nordeste em direção ao centro. Percebeu-se também que o LL do sul diminuiu, sendo dividido em duas porções (uma mais ao centro, e outra ao sul). Ambas apresentam boas condições de infraestrutura (quinto quintil), sendo a porção do centro detentora de renda superior (terceiro quintil, enquanto a do sul no segundo quintil).

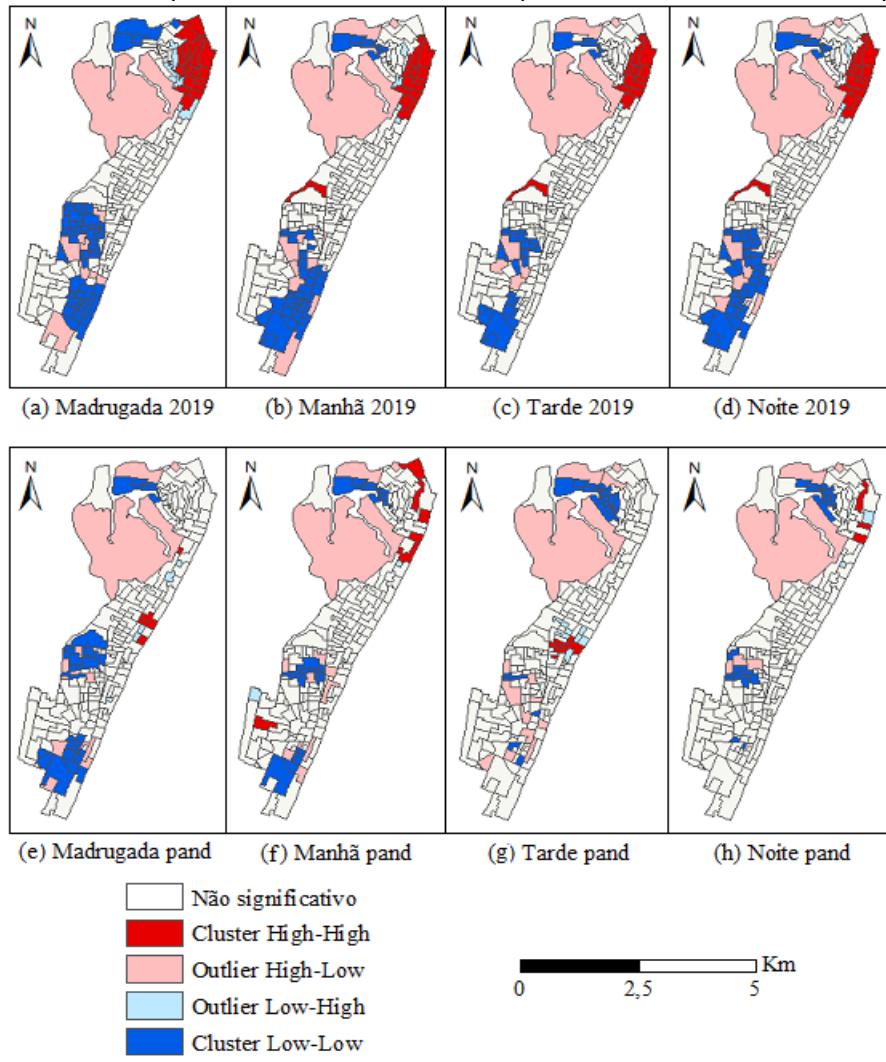
## 6.5 Estudo dos *clusters* espaciais por períodos do dia

A última instância de investigação da concentração espacial dos roubos diz respeito aos períodos do dia durante o ano de 2019 e o trecho do período pandêmico examinado neste estudo (11 de março de 2020 a 31 de maio de 2021). Os respectivos mapas indicando o posicionamento dos *clusters* estão na Figura 18.

Em relação a 2019, não houve grandes oscilações entre os períodos quanto à localização e à extensão dos clusters. Identificou-se setores HH no nordeste e no centro-oeste (exceto na madrugada) – sendo este último no setor vizinho ao shopping Recife. Além disso, houve *clusters* LL no sul e centro-sul rodeados por *outliers* HL. Todas estas áreas já foram extensivamente discutidas em outros recortes temporais.

Por sua vez, durante a pandemia ocorreu uma diferenciação melhor entre os horários. Os setores do tipo LL e HL ao norte se mantiveram em todos os horários (com pequenas variações de extensão), assim como áreas LL circundadas por HL surgiram no centro-sul (estas contendo oscilações maiores em tamanho). Contudo, os *clusters* HH do nordeste foram bastante reduzidos, estando significativos em apenas um setor censitário na madrugada (Figura 18(e)) e em nenhum durante a tarde (Figura 18(g)). Nos períodos da madrugada e da tarde surgiu um HH no centro-leste, em áreas privilegiadas em renda e infraestrutura (quinto quintil). O LL do sul se reduziu ao passar dos períodos do dia. Durante a manhã (Figura 18(f)) houve um HH no sul numa área pouco favorecida em termos de renda (segundo quintil), com população jovem (quinto quintil), preta (quinto quintil na maioria dos setores), pouco adensada (primeiro quintil) e com boa infraestrutura (quarto e quinto quintis em todos os fatores).

Figura 18 - Clusters espaciais de roubos durante os períodos do dia em 2019 e na pandemia



Fonte: O autor (2022)

Em uma análise comparativa entre o ano de 2019 e a época da pandemia (Figura 18), nota-se que durante a madrugada os LL do centro-sul e sul foram mantidos, porém com extensão levemente menor. O cluster HH do nordeste foi praticamente extinto, restando apenas um setor (que antes era LH). Também surgiu um novo HH no centro-leste. No período da manhã, a localização geral do LL se manteve (centro-sul e sul), mas novamente com extensão reduzida. O HH do centro-oeste se tornou não-significativo, porém surgiu outro no sul. A porção norte apresentou um padrão similar a 2019, porém com um tamanho menor de HH.

Na faixa da tarde, ocorreu a extinção do HH no nordeste e a manutenção do LL do noroeste. Na porção central, o HH se deslocou rumo à orla (mais rica e privilegiada); no sul e centro-sul, os LL diminuíram consideravelmente, mas em localidades similares. Por fim, no período da noite, manteve-se a localização dos

*clusters* e *outliers* em relação a 2019, mas em quantidade menor, havendo também a extinção do HH no centro-oeste.

## 6.6 Discussão

Esta seção apresenta as principais descobertas referentes ao estudo descritivo dos índices de roubos e à formação de *clusters* espaciais destes ao longo de diferentes recortes temporais.

### 6.6.1 Acumulados mensais

O advento da pandemia de COVID-19 causou um impacto substancial na rotina das pessoas, inclusive no padrão de movimentação delas em vias públicas. A literatura criminal defende que a ocorrência de roubos é fortemente vinculada à existência de alvos em potencial em um ambiente propício e atrativo a criminosos. As medidas restritivas tomadas pelo Estado para conter o avanço da doença afetaram diretamente essa dinâmica ao redor do mundo, assim como constatado nos bairros de Boa Viagem e Pina pela presente pesquisa.

A região de estudo apresentava tendência de queda no acumulado mensal de roubos nos dois anos anteriores à pandemia, porém isto foi acentuado a partir de abril de 2020. A rigidez dos decretos governamentais fez com que o índice de roubos se mantivesse em um patamar estável até junho de 2020, porém bastante abaixo do ano pré-pandêmico de 2019. Com o relaxamento gradual das medidas, houve uma elevação nas ocorrências em julho de 2020, mas novamente sem grandes oscilações até dezembro de 2020. Esse panorama surpreendeu, devido à expectativa crescente de pessoas nas ruas com o aquecimento do comércio no fim de ano.

Pesquisas anteriores explicam essa queda no número de roubos (ou outros crimes patrimoniais), especialmente no início da pandemia de COVID-19, utilizando fundamentos da Teoria da Atividade de Rotina (FELSON; JIANG; XU, 2020; CECCATO et al., 2021; ESPOSITO; KING, 2021; ESTÉVEZ-SOTO, 2021; LOPEZ; ROSENFELD, 2021; YANG et al., 2021). Os respectivos autores afirmam que as políticas de permanência em casa impostas durante a pandemia restringiram a mobilidade das pessoas (incluindo alvos, guardiões e criminosos motivados) no

espaço público, o que reduziu as condições adequadas de tempo e espaço para gerar oportunidades de roubos.

Em Recife, o início do ano de 2021 foi marcado pela amenidade na atuação do Governo frente à pandemia e a sensação de retomada da normalidade pela sociedade, mesmo em pleno estágio de aceleração em casos e óbitos por COVID-19. Ademais, a campanha de vacinação estava apenas iniciando e seguia um ritmo lento. O verão provavelmente levou as pessoas às ruas, embora as tradicionais festividades carnavalescas estivessem oficialmente proibidas. Consequentemente, mais alvos em potencial estavam em vias públicas, levando os roubos a se aproximarem do patamar pré-pandêmico entre janeiro e março deste ano. Isto corrobora os achados de Yang et al. (2021), que notaram uma tendência de crescimento nos índices de crimes patrimoniais em Chicago à medida que as restrições de circulação eram relaxadas, atingindo até mesmo níveis existentes antes da pandemia. Por fim, em abril e maio de 2021 houve um incremento considerável em relação ao mesmo período em 2020 (no qual houve uma queda abrupta pós-decreto da pandemia).

### **6.6.2 *Clusters* espaciais**

A oscilação nos índices de roubos foi investigada mensalmente em termos da formação de *clusters* espaciais visando traçar diferenças e similaridades antes e durante a pandemia. Durante o ano pré-pandêmico de 2019, houve uma estabilidade maior no posicionamento geográfico do padrão HH da região nordeste ao longo do ano, enquanto apenas em alguns meses no *cluster* LL da região sul (incluindo os cinco primeiros do ano).

O HH do nordeste abrange áreas de baixa densidade populacional, com faixa etária geralmente mais idosa. A população branca se faz mais presente na orla, mas pretos e pardos são mais evidentes na localidade como um todo. Há heterogeneidade socioeconômica advinda não só da renda ser mais elevada na orla do que em outros setores, mas também de fatores de infraestrutura urbana. Serviços como esgotamento sanitário e água encanada apresentam desempenhos opostos em plena orla (considerada de maior valor imobiliário), oscilando entre um nível de oferta muito alto a um baixo ou muito baixo.

Por sua vez, o LL do sul possui densidade populacional baixa ou muito baixa, mas abrange uma área significativa de povoamento alto e muito alto. A população mais jovem (crianças e residentes em idade economicamente ativa) e alfabetizada apresenta um desempenho muito alto em grande parte dos setores. Assim como no HH do nordeste, à medida que se afasta da orla, a renda domiciliar decresce. Embora a infraestrutura urbana seja predominantemente boa, algumas partes detêm oferta baixa ou muito baixa, especialmente na área mais povoada. Em suma, o HH do nordeste e o LL do sul têm características heterogêneas e, com exceção da faixa etária e da densidade populacional, não há um padrão distintivo claro na associação entre questões socioeconômicas e a concentração espacial dos roubos.

Entre junho e setembro de 2019 o LL do sul se deslocou rumo ao centro-sul. Novamente são áreas heterogêneas em termos de renda e provisão de serviços públicos, contendo localidades de maior densidade populacional. Diferente do sul, a renda oscila entre baixa e moderada, com poucos setores de renda muito alta (nos quais residem mais idosos).

Em outubro e novembro de 2019 as concentrações criminais foram bastante distintas dos meses anteriores. Nesse período o HH do nordeste deixou de ser significativo e ressurgiu um LL no noroeste. Em outubro, um grande HH apareceu no sudoeste (áreas de renda baixa e muito baixa), vizinho ao antigo LL identificado no início do ano. Neste mês o setor censitário do Shopping Recife se tornou HH, um local de renda elevada circundado por áreas densamente povoadas e com privação socioeconômica. Isto tende a refletir o esperado aumento na atividade comercial devido ao Dia das Crianças. Por fim, dezembro marcou a retomada dos padrões espaciais vistos no início do ano (HH do nordeste e LL do sul).

O ano de 2020 iniciou com padrões similares aos de janeiro de 2019 e dezembro de 2019. Em janeiro de 2020, os *clusters* HH do nordeste (avançando a áreas menos desenvolvidas) e LL do sul novamente existiram. No mês seguinte, durante o Carnaval e às vésperas do decreto da pandemia, houve mudanças significativas em relação ao mês e ano anteriores. O HH do nordeste foi reduzido a poucas áreas de renda elevada, assim como outros HH surgiram no centro-oeste (shopping Recife) e no sudoeste (renda e densidade populacional baixas).

O advento da pandemia fez com que o *cluster* HH do sudoeste se expandisse para áreas menos desenvolvidas em termos de renda, pavimentação e esgotamento sanitário, especialmente nos meses com restrições governamentais severas (março,

abril e maio de 2020). No nordeste, o HH se posicionou em áreas de renda elevada e população mais idosa, mas condições heterogêneas de infraestrutura durante março e abril; em maio, também avançou para áreas de renda baixa ou muito baixa. Neste período surgiu um novo LL na região central (densidade populacional elevada, renda de moderada a muito alta e infraestrutura razoável). Assim, as regiões central e sul divergiram consideravelmente do ano anterior.

Em junho e julho de 2020 o comércio gradualmente reabriu tendo em vista o estágio de desaceleração nas curvas de casos e de óbitos por COVID-19 em Recife. Poucos *clusters* se mostraram significativos na região. Apenas dois do tipo HH surgiram em locais com renda e infraestrutura urbana em níveis moderados no centro-sul e sudoeste, os quais não tinham aparecido no mesmo período em 2019.

Agosto de 2020 apresentou um tímido retorno do HH do nordeste e do LL do sul, ambos amplamente discutidos. Nos três meses seguintes (setembro, outubro e novembro), a região central passou a comportar um HH em áreas que eram tipicamente não significativas. Em geral, elas apresentam níveis de moderado a muito alto de renda domiciliar, densidade populacional, população branca e provisão de serviços públicos. Isto pode ser associado ao reaquecimento do comércio durante o ponto mais baixo na curva de casos e óbitos por COVID-19 pós-pico da primeira onda da pandemia.

Contudo, em dezembro de 2020 não houve setores HH (apenas LL no noroeste e no sul), o que enfraquece a justificativa supracitada. Esse padrão era inesperado por ser uma época com incremento no fluxo de pessoas em vias públicas para as compras de Natal. Além disso, o horário de funcionamento das instalações comerciais havia sido ampliado no Recife, o que propiciou mais alvos em potencial para roubos. Em comparação a 2019, as poucas semelhanças ocorreram quanto ao HH do nordeste em agosto e setembro, e aos LL do sul (apenas em dezembro) e do noroeste (de agosto a dezembro, exceto setembro).

Nos meses iniciais do ano de 2021, o número de casos e óbitos por COVID-19 acelerou, atingindo-se em maio o pico do acumulado mensal destes índices (na segunda onda da pandemia). Esse crescimento foi impulsionado pela propagação de uma variante mais transmissível do vírus SARS-CoV2 em Recife, pelo crescente desrespeito às medidas de distanciamento social e por medidas restritivas brandas. Por outro lado, a campanha de vacinação teve início, embora que em ritmo lento. O

contexto dessa época provavelmente contribuiu para solidificar mudanças no padrão espacial dos roubos em relação a 2019.

Em janeiro de 2021, retomaram-se padrões de HH ao centro e LL no sul e centro-sul verificados anteriormente entre setembro e outubro de 2020. Apenas a porção norte da região manteve *clusters* como no mês anterior. Em fevereiro e março de 2021, o LL e o HH se deslocaram rumo ao norte: LL ocupando a porção centro-sul e HH retornando ao nordeste. Em comum há a heterogeneidade dessas áreas em termos de densidade populacional, renda domiciliar e infraestrutura urbana, oscilando de muito baixo a muito alto. Abril e maio de 2021 consolidaram essa tendência no centro e no norte, mas a região sul apresentou um HH inédito (desde 2019) em seu extremo. É um local com população jovem, densidade populacional baixa ou muito baixa, renda alta ou baixa, e com infraestrutura heterogênea (muito baixa a muito alta, a depender do fator). Assim, outros fatores precisam ser investigados para compreender o que pode ter tornado setores censitários tão diversos em concentrações espaciais de roubos.

Recife é uma cidade litorânea de clima tropical com poucas oscilações de temperatura ao longo do ano, e cujas estações se distinguem apenas entre períodos secos e chuvosos. Deste modo, não se esperava uma mudança brusca nos *clusters* espaciais neste recorte temporal. Esse padrão de semelhança se fez presente nos *clusters* durante o verão, o outono e o inverno do ano pré-pandêmico de 2019, exceto pelos *clusters* LL ao sul.

O verão de 2020 não teve grandes impactos da pandemia (apenas 9 dias), então a posição dos *clusters* de roubos ficou próxima à de 2019. Em seguida, as medidas de distanciamento social passaram a vigorar, especialmente a quarentena estrita na segunda quinzena de maio de 2020. Isso impactou fortemente a ocorrência de roubos pela menor circulação de pessoas nas ruas e, consequentemente, a formação de *clusters*. Então, no outono de 2020, os *clusters* HH se deslocaram do nordeste para o sudoeste, um ambiente com baixa densidade populacional, baixa renda domiciliar e infraestrutura urbana razoável.

O inverno de 2020 trouxe uma fase de declínio nos casos e óbitos por COVID-19, então flexibilizações passaram a vigorar gradualmente. Os roubos começaram a crescer lentamente, o que fez ressurgir alguns *clusters* HH no nordeste vistos no inverno de 2019. Na primavera de 2020 vivenciou-se o aquecimento do comércio com o Dia das crianças e o Natal junto a uma fase mais branda da pandemia. O

padrão espacial, contudo, não repetiu o verificado em 2019. Os *clusters* HH partiram de uma área menos desenvolvida para outra mais desenvolvida; quanto aos *clusters* LL, eles se expandiram para locais ao sul de característica similar.

No verão de 2021 ocorreu uma aceleração rápida da pandemia e a retomada de algumas medidas restritivas em pleno período carnavalesco. Embora os crimes estivessem em um patamar próximo ao de 2020 (em valores acumulados), a localização dos *clusters* se manteve similar à da primavera de 2020 ao invés do verão de 2019. Já no outono de 2021, no pico da segunda onda, as restrições de circulação eram consideravelmente mais brandas do que no mesmo período de 2020. Então a porção nordeste manteve os *clusters* HH do outono de 2019, mas novos do mesmo tipo surgiram também no extremo sul. A motivação desse novo padrão é incerta, mas provavelmente não decorre apenas da pandemia. O funcionamento do comércio era próximo ao normal (por consequência, o fluxo de pessoas não deveria mudar fortemente, em tese), então se espera que fatores externos tenham influenciado.

A respeito dos dias da semana, os *clusters* HH e LL no ano de 2019 não mudaram substancialmente de posição, contendo áreas de renda geralmente elevada, mas com provisão de infraestrutura bastante mista. Na sexta-feira e no domingo havia padrões mais diferenciados, pois são dias conhecidos na região pela preferência ao lazer (assim como o sábado) devido às diversas opções disponíveis, o que propicia movimentações diferentes no espaço. Na sexta, o LL do sul deixou de ser significativo. Já no domingo, parte de um LL no sudeste foi convertida em um pequeno HH, contendo população predominantemente branca, de renda elevada e com boa provisão de serviços públicos.

Durante a pandemia, houve uma diferenciação maior entre os dias e em relação ao período pré-pandêmico. As áreas com condições socioeconômicas opostas no nordeste frequentemente se mostraram HH (exceto na terça-feira), embora em posições e extensões diferentes. O domingo e a segunda-feira compartilham parte deste HH (sendo o domingo com as áreas de menor renda), bem como parte de um LL no centro-sul. Na quarta-feira, o HH do nordeste se deslocou rumo ao sul para áreas de renda ainda elevada, mas com infraestrutura razoavelmente pior. Um novo HH surgiu na quinta-feira (no extremo sul), porém em área pouco desenvolvida. Na sexta-feira quase não houve formação de *clusters*. O centro-norte deteve setores com condições socioeconômicas opostas que se

mantiveram como LL nas segundas e quartas. No sudoeste, setores menos favorecidos passaram de LL no domingo para HH na terça-feira.

Em comparação ao ano de 2019, a região HH vizinha ao shopping Recife deixou de ser significativa durante a pandemia – possivelmente devido às restrições aplicadas ao comércio. Espacialmente, os dias mais similares à pré-pandemia são o domingo, a segunda-feira e a sexta-feira. Os padrões na região norte foram os mais estáveis, enquanto no sul houve maior oscilação. No centro, poucas áreas foram significativas e novos HH surgiram apenas no sábado. No sul, apareceram novos HH na terça e na quinta, bem como novos LL no domingo e na quarta; enquanto na segunda e na terça a imensa maioria dos setores LL deixaram de ser significativos.

A divisão temporal por períodos do dia também foi investigada. Durante o ano de 2019, não houve grandes oscilações no posicionamento dos *clusters* HH e LL. Destaca-se a madrugada, onde o HH próximo ao shopping Recife deixou de existir, mas o HH do nordeste se estendeu para áreas com alta densidade populacional e renda baixa. Por outro lado, em relação ao agregado do período pandêmico, nota-se uma forte divergência. Houve uma redução generalizada na extensão dos *clusters*. Em termos de localização, os HH situados ao nordeste se mantiveram (em parte) apenas durante a manhã e a noite. Durante a madrugada e a tarde, novos HH surgiram na região central do mapa (com renda domiciliar e infraestrutura razoáveis).

Todavia, o resultado dos *clusters* para períodos do dia deve ser analisado cautelosamente, pois os padrões mesclam diferentes estágios da pandemia, assim como restrições governamentais de severidade variada (consequentemente, uma quantidade oscilante de vítimas em potencial). Essa mesma observação é válida para o recorte por dias da semana.

Ao considerar todos os recortes temporais investigados (meses, estações do ano, dias da semana e períodos do dia), vale ressaltar o setor censitário onde se localiza o Parque dos Manguezais. Ele é a divisão espacial de maior área nos bairros de Boa Viagem e Pina e está situado ao norte da região. O setor se apresentou como *outlier* HL em incríveis 59 dentre os 61 mapas produzidos. Isto denota como esta área, apesar de ser majoritariamente desocupada, concentra uma alta incidência de roubos em relação à vizinhança.

## 7 ROUBOS EM BOA VIAGEM E PINA: ANÁLISE ESTATÍSTICA E GIS-MCDA

O presente capítulo prossegue o estudo da ocorrência de roubos na região de estudo, desta vez sob o ponto de vista estatístico e multicritério com o suporte de técnicas espaciais. São explorados os fatores preditivos de roubos em diferentes estágios da pandemia visando determinar um conjunto reduzido e significativo que seja capaz de explicar os referidos índices criminais. Subsequentemente, os setores censitários mais vulneráveis a roubos são ressaltados.

### 7.1 Análise estatística-espacial dos fatores preditivos de roubos

O estudo teve como alvo um conjunto de 37 determinantes. Deste, 17 refletem o panorama demográfico e socioeconômico da região de estudo em termos de renda domiciliar, provisão de serviços públicos, taxa de alfabetização, densidade populacional, cor e faixa etária. O restante compila instalações comerciais variadas que demonstram o dinamismo da economia em Boa Viagem e Pina, bem como o incentivo à circulação de pessoas – que eventualmente se tornam vítimas em potencial de roubos.

#### 7.1.1 Estatística descritiva das variáveis explanatórias

Esta seção investiga a distribuição espacial dos preditores de roubos e a associação estatística entre estes fatores preditivos.

##### 7.1.1.1 Análise de quintis

Inicialmente os fatores foram dispostos em mapas a fim de revelar padrões espaciais sobre o contexto local. As características socioeconômicas estão representadas por meio de quintis (Figura 19), enquanto os estabelecimentos foram apresentados na forma de densidade Kernel (Figura 20) devido à informação georreferenciada exata da localização destes.

Acerca dos indicadores censitários, a densidade populacional está distribuída em uma faixa central verticalizada na região, obtendo valores maiores em setores censitários de menor área conforme o esperado. O quinto quintil (80-100%) deste

fator está mais presente numa porção ao norte da região (no bairro do Pina), a qual coincide com locais de baixa renda e variância da renda (primeiro quintil, 0-20%) e predominância de pretos e pardos (quinto quintil). Contudo, esta mesma região ao norte também apresenta um elevado índice de alfabetizados (quinto quintil).

A área noroeste, também situada no bairro do Pina, abrange a comunidade da Ilha de Deus e o Shopping Center Rio Mar. Lamentavelmente, como o censo demográfico foi realizado no ano de 2010 e a inauguração do shopping só ocorreu em outubro de 2012, as informações socioeconômicas que dispomos ainda não consideram o impacto local deste empreendimento. O shopping ocupa um setor censitário que era majoritariamente mangue, então a população e o número de domicílios era pequeno e, por conseguinte, não houve resultado expressivo nos 17 indicadores censitários (16 deles estão no primeiro quintil).

Por sua vez, a Ilha de Deus faz limite com o Parque dos Manguezais no extremo noroeste. Ela está no primeiro e segundo quintis (0-20% e 20-40%, respectivamente) de todos os fatores relativos aos serviços públicos, bem como renda, variância da renda e densidade populacional. A população residente é composta significativamente pela faixa etária de 0 a 14 anos de idade (quarto quintil, 60-80%) e por pardos e pretos (quarto e quintis, respectivamente).

O grande setor censitário que compreende o Parque dos Manguezais não é totalmente inhabitado. Parte dele é ocupado por uma população de baixa renda (segundo quintil), consideravelmente preta (quinto quintil) e com crianças e idosos em realce (ambos no quarto quintil). A densidade populacional é bastante baixa (primeiro quintil), visto que a área é extensa e contém um local de preservação ambiental. Os domicílios são majoritariamente próprios (terceiro quintil, 40-60%) e com bom acesso à água encanada (quarto quintil), porém são precários em esgotamento sanitário e iluminação pública (ambos no segundo quintil).

A renda e a variância da renda apresentam valores mais acentuados (quarto e quinto quintis) na faixa litorânea situada a leste, o que a evidencia como local de alto poder aquisitivo e potencialmente vantajoso para tentativas de roubo. Além disso, nesse território está grande parte dos locais cuja população é mais idosa (quinto quintil) e branca (predominantemente quarto e quinto quintis). A prestação de serviços públicos é notável (fatores ‘esgoto’, ‘lixo’, ‘ilumpub’, ‘pavim’ no quarto e quinto quintis, em maioria), porém com um desempenho inferior no acesso à água encanada (primeiro e segundo quintis em área considerável).

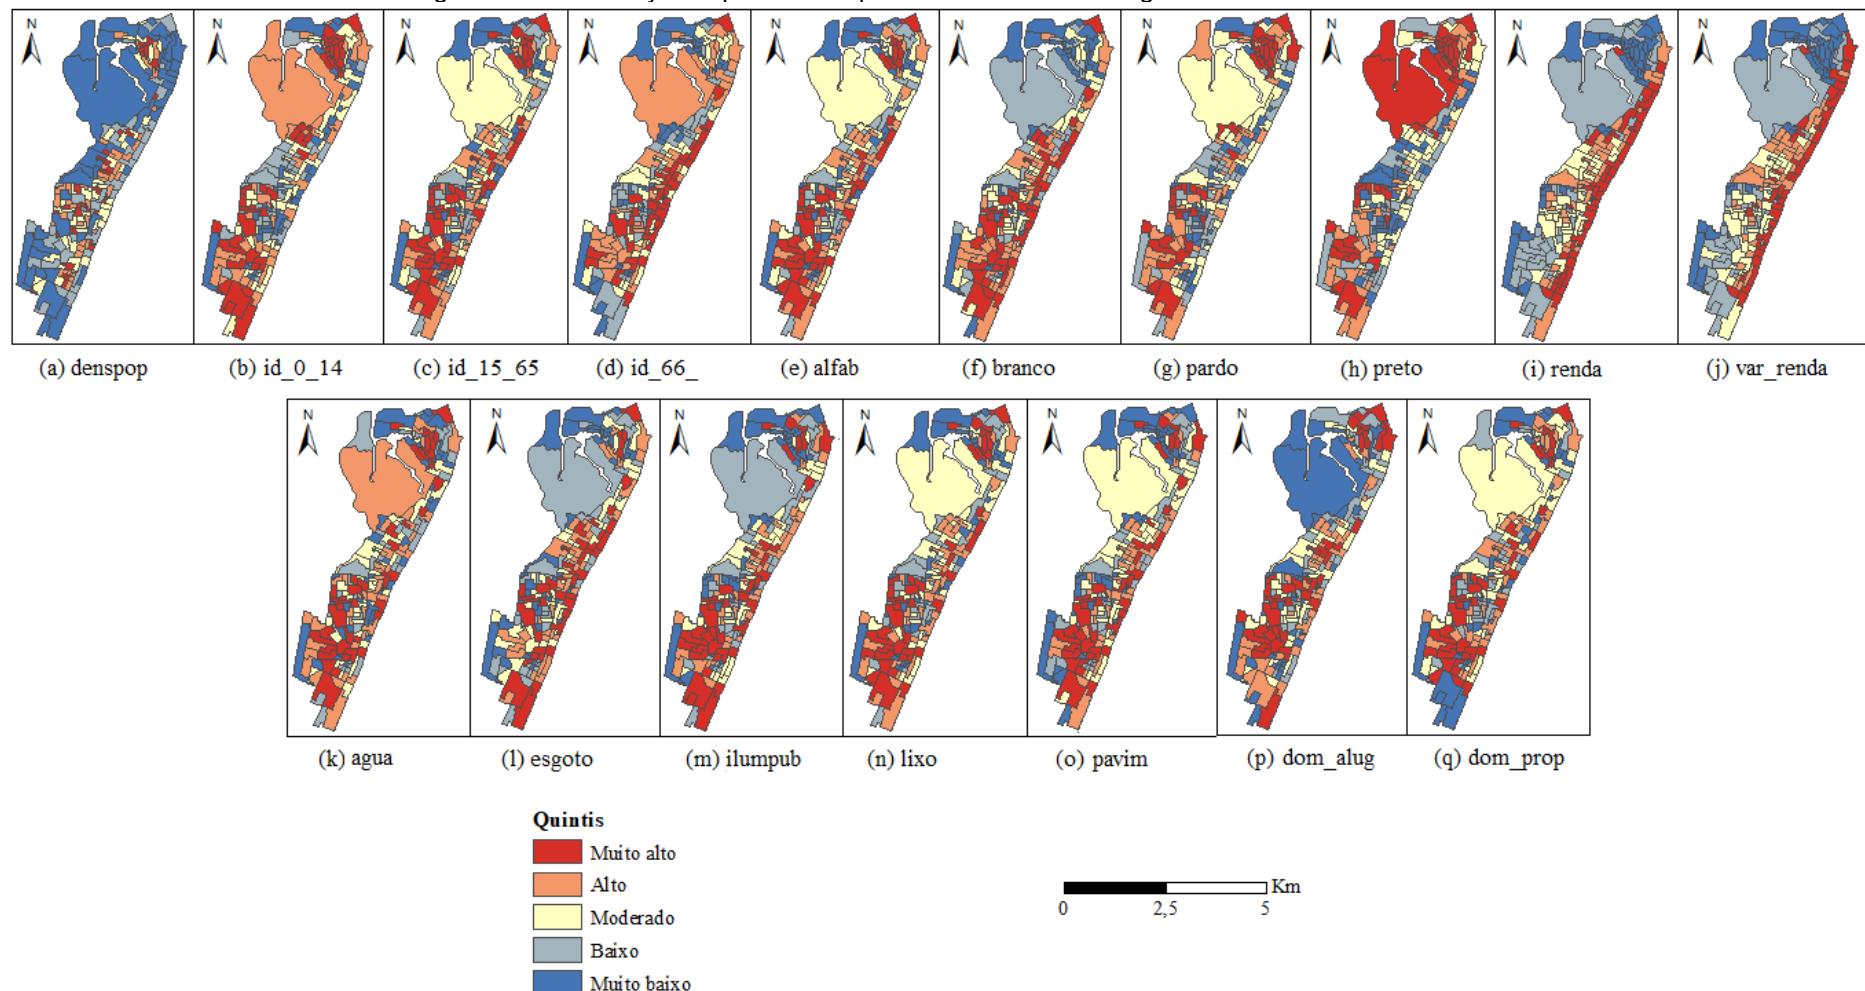
A porção centro-oeste se destaca pela presença do Shopping Center Recife, o qual é historicamente circundado por locais menos privilegiados socioeconomicamente. Há um padrão misto em termos de renda domiciliar, pois os locais estão praticamente divididos em primeiro e quarto quintis. A região não tem um bom acesso à iluminação pública, pavimentação e esgoto (primeiro e segundo quintis predominam), mas sim à água encanada e coleta de lixo (ambos no quarto e quinto quintis). A população residente apresenta um perfil etário mais jovem ('id\_66' no primeiro e segundo quintis, enquanto 'id\_0\_14' e 'id\_15\_65' no quarto e quinto quintis), com cor prevalentemente preta e parda (maioria no quarto e quinto quintis).

O sudoeste da região (em Boa Viagem) compartilha limites territoriais com dois bairros socialmente vulneráveis, Jordão e Ibura. Logo, espera-se que a localidade detenha características semelhantes. De fato, os setores censitários possuem renda e variância da renda baixas (primeiro e segundo quintis). Contudo, a infraestrutura é satisfatória ('água', 'lixo', 'ilumpub', 'pavim' no quarto e quinto quintis), exceto pela provisão de esgotamento sanitário (entre o primeiro e o quarto quartis). Por fim, há um número expressivo de residentes alfabetizados (predomínio do terceiro ao quinto quintis) e a população preta se faz mais presente (maioria no quinto quintil).

O extremo sul da região faz fronteira com o bairro de Piedade, na cidade de Jaboatão dos Guararapes, cuja faixa litorânea é reconhecida como área nobre. A respeito da propriedade dos domicílios, residências próprias não são comuns (primeiro quintil). A localidade é atendida por boa prestação de serviços públicos (fatores 'água', 'esgoto', 'lixo', 'ilumpub' e 'pavim' situados no quarto e quinto quintis). Apenas os setores censitários mais próximos à praia possuem renda elevada (quarto e quinto quintis), enquanto o restante pertence ao segundo quintil. A densidade populacional na região é consideravelmente baixa (predomínio do primeiro quintil). Os residentes são relativamente jovens ('id\_0\_14' e 'id\_15\_65' no quarto e quinto quintis) e com alto índice de alfabetização (quarto e quinto quintis).

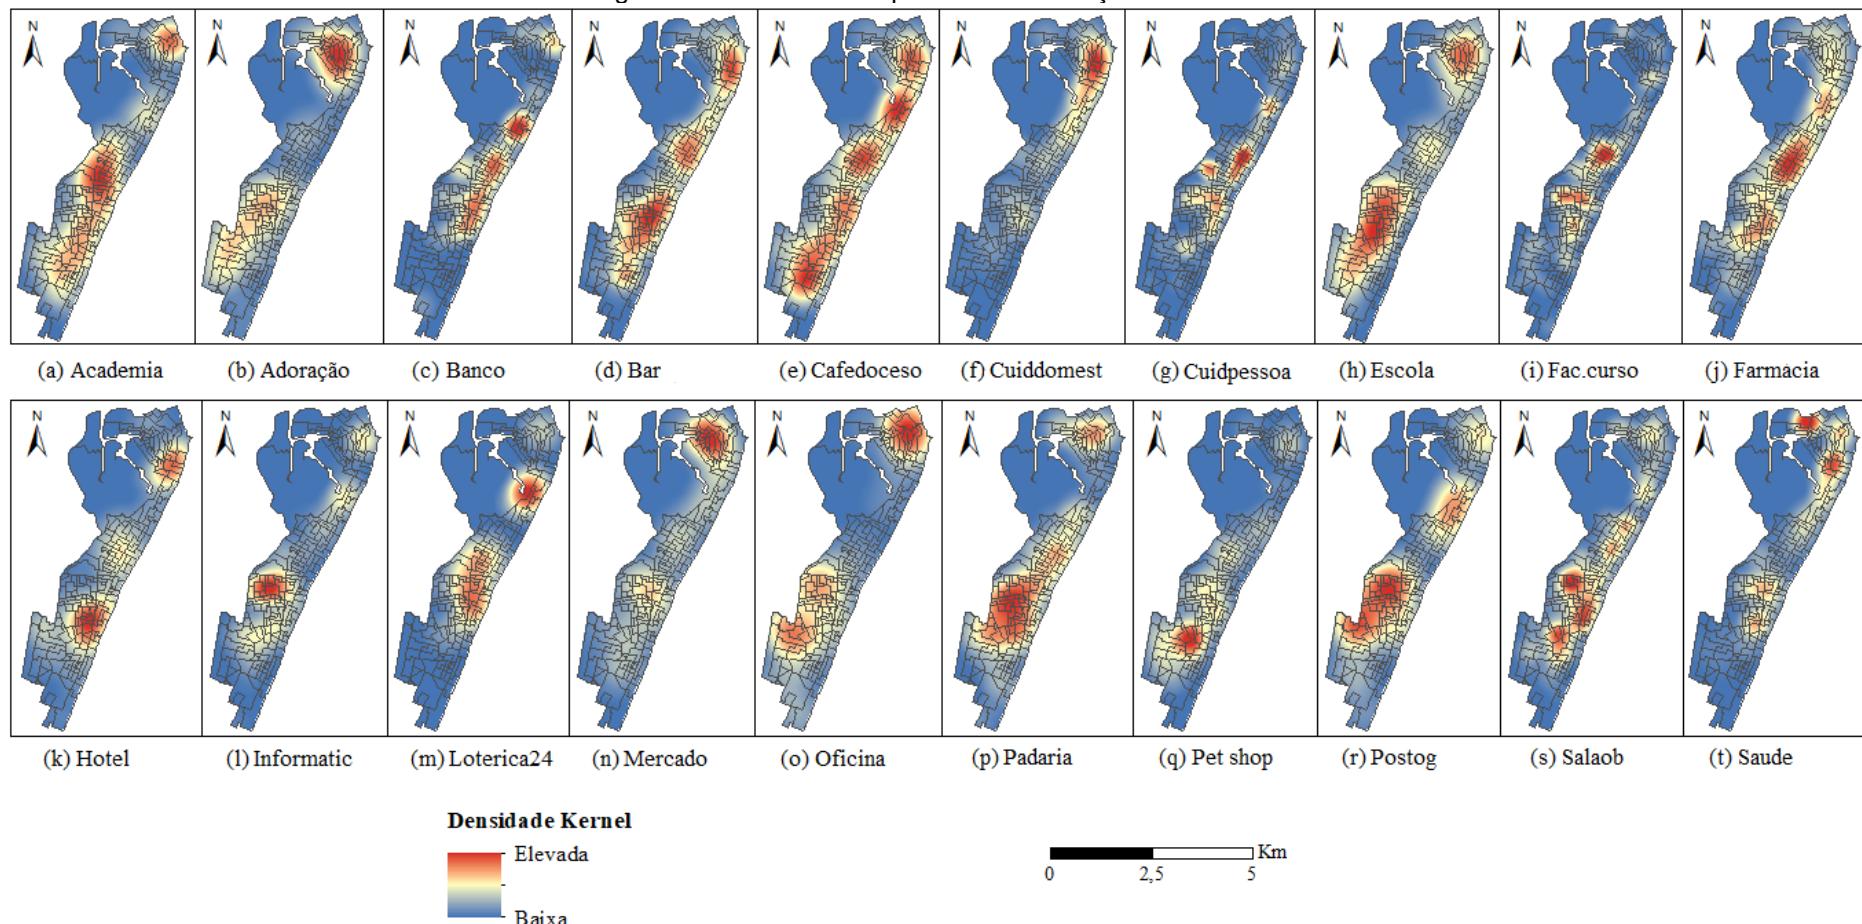
Os estabelecimentos comerciais estão, por sua vez, representados na forma de densidade espacial na Figura 20. Um fator relevante a se discutir é a localização das avenidas Engenheiro Domingos Ferreira e Conselheiro Aguiar, próximas e paralelas às praias da região de estudo. Elas concentram boa parte da atividade comercial da região, como verificado pela distribuição de grande parte dos estabelecimentos, em particular: academias, bancos, bares, cafeteria, lojas de cuidados domésticos e pessoais, farmácias, hotéis, lotéricas e unidades de saúde.

Figura 19 - Distribuição espacial dos quintis dos fatores demográficos e socioeconômicos



Fonte: O autor (2022)

Figura 20 - Densidade espacial das instalações comerciais



Fonte: O autor (2022)

Devido ao potencial turístico local, os hotéis estão mais adensados perto da faixa litorânea, especificamente no nordeste (Pina) e no centro-sudeste (Boa Viagem). Estes dispositivos estão presentes onde há renda elevada. No Pina, eles estão inseridos em ambientes com boa provisão de serviços públicos (terceiro ao quinto quintis, em maioria), enquanto em Boa Viagem nota-se um contexto diversificado (primeiro ao quinto quintis).

Dentre as principais opções de lazer na região estão os bares e ambientes para lanches ('cafedoces'). Eles se concentram mais ao longo das avenidas paralelas à praia, sobretudo em locais socioeconomicamente mais privilegiados. Ademais, ambos os estabelecimentos também se estendem para áreas de renda mais baixa e pior provisão de serviços públicos tanto na porção ao sul e ao centro-sudoeste (ambos em Boa Viagem) quanto ao nordeste (Pina) da região.

As unidades de saúde são bastante representadas por centros médicos – prédios contendo consultórios de especialidades diversas. Essas instalações se concentram em três pontos, sendo dois deles no Pina. Não são áreas extremamente desenvolvidas (renda e infraestrutura), mas que possuem fácil acesso. Por sua vez, as farmácias se adensam mais ao centro-norte (em Boa Viagem), porém também estão próximas à concentração-sul das unidades de saúde.

Bancos e lotéricas apresentam concentrações perto do Parque dos Manguezais, no centro-norte. Entretanto, os bancos mais ao sul se restringem às proximidades da faixa litorânea, enquanto as lotéricas se espalham em áreas no centro-oeste menos privilegiadas em termos de renda e acesso a serviços públicos.

Mercados, padarias, escolas, oficinas e locais de adoração estão mais concentrados em ambientes parecidos: nordeste (Pina) e centro-sul (Boa Viagem). Em geral, são áreas com maior densidade populacional e boa infraestrutura (quarto e quinto quintis). Porém, a renda e a variância da renda são relativamente baixas (ambos entre o primeiro e o segundo quintis) e a população preta e parda predomina (quarto e quinto quintis).

Ao comparar a localização das escolas com a de faculdades e cursos, percebe-se um padrão notavelmente distinto. O último fator atende a localidades com predominância de população branca, renda elevada e boa provisão de serviços públicos (as três características entre o quarto e quinto quintis). A exceção está na região de renda baixa e infraestrutura precária próxima ao Shopping Recife, porém justifica-se pelo esperado fluxo comercial elevado no local. Por sua vez, a

concentração espacial das escolas também abrange essas áreas próximas ao shopping. Há, contudo, uma extensão em direção ao centro-sul (incluindo localidades com melhores condições socioeconômicas) e outra localizada no centro-norte (densidade populacional elevada, com preponderância de pretos e pardos e de privação socioeconômica).

As lojas de cuidados domésticos e pessoais se adensam em locais distintos. O primeiro tipo de estabelecimento se concentra no Pina, em um misto de áreas com melhores (majoritariamente lojas de móveis planejados) e com piores (em suma, armazéns de construção) condições socioeconômicas. O segundo tipo predomina no centro-norte da região de estudo (em Boa Viagem), onde a população possui renda mais elevada (quarto e quinto quintis).

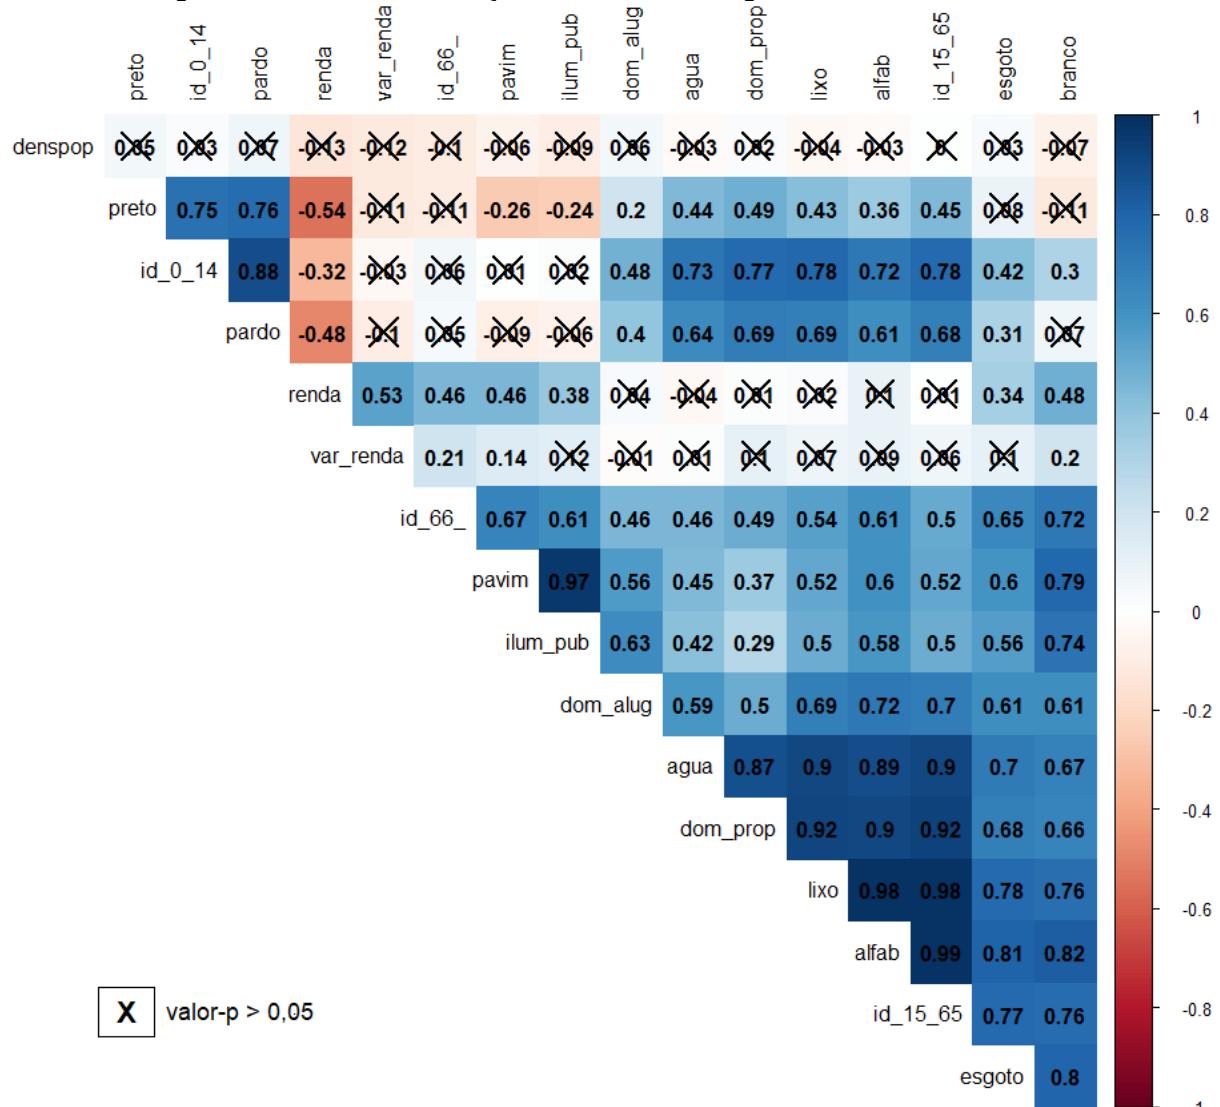
Os petshops se concentram no centro-sul de Boa Viagem. O local apresenta boas condições de infraestrutura (maior parte no quinto quintil) e população economicamente ativa em destaque (maioria dos setores no quinto quintil), mas com renda domiciliar baixa (segundo quintil). Os salões de beleza também estão agrupados nesta região, assim como em áreas vizinhas com características opostas em termos de renda e infraestrutura (melhores condições quando próximo à praia, piores quando perto do Shopping Recife). Na vizinhança desse shopping, em um ambiente mais precário, também se concentram as lojas de informática.

#### *7.1.1.2 Análise de correlação não-espacial*

A intensidade e a direção das associações entre as variáveis explicativas foram exploradas por meio da análise de correlação linear de Pearson, tendo como base pares de preditores oriundos de uma mesma origem (IBGE ou base georreferenciada). Os resultados referentes aos fatores demográficos e socioeconômicos estão na Figura 21, enquanto as relações entre instalações comerciais se encontram na Figura 22. Adotou-se uma escala para representar a correlação de acordo com a cor (azul – positiva; vermelha – negativa) e a intensidade dela. As células marcadas com X denotam associações que não são significativas ( $valor-p > 0,05$ ). Correlações  $\rho$  fracas pertencem ao intervalo de 0 a 0,30, moderadas estão entre 0,31 e 0,60, fortes entre 0,61 e 0,90 e muito fortes entre 0,91 e 1,0 (CALLEGARI-JACQUES, 2007).

Em linhas gerais, a região de estudo consiste em uma mescla de áreas com habitações simplórias ou precárias e de outras compostas por condomínios prediais com valor imobiliário latente (principalmente perto da orla). Entretanto, conforme percebido na Figura 21, a densidade populacional não apresenta correlação significativa com nenhum outro fator, o que a torna uma característica bastante distintiva da região. Esta condição é reafirmada pela comparação visual da Figura 19(a) com os demais indicadores censitários.

Figura 21 - Matriz de correlação dos fatores demográficos e socioeconômicos



Fonte: O autor (2022)

A relação mais expressiva da variância da renda é com a própria renda, mas ainda assim moderadamente ( $\rho = 0,53$ ). Quanto aos demais fatores, a maioria não é significativamente correlacionada. Em termos de infraestrutura, o fator renda só

apresenta associação significativa (embora moderada) com a pavimentação ( $\rho = 0,46$ ), a iluminação pública ( $\rho = 0,38$ ) e o esgotamento sanitário ( $\rho = 0,34$ ).

A renda domiciliar está correlacionada de forma moderada e negativa com a população preta ( $\rho = -0,54$ ) e parda ( $\rho = -0,48$ ), bem como com crianças entre 0 e 14 anos ( $\rho = -0,32$ ). Inclusive, estes três últimos fatores ('pardo', 'preto' e 'id\_0\_14') estão fortemente relacionados entre si ( $\rho$  entre 0,75 e 0,88), mas a relação deles com a população branca é fraca ou não significativa. Por outro lado, a associação da renda com a população branca ( $\rho = 0,48$ ) e com a faixa etária de idosos ( $\rho = 0,46$ ) também é significativa, porém moderada e positiva. Assim, as áreas menos privilegiadas são formadas por: pretos e pardos, baixa renda e jovens.

A faixa etária dos idosos ('id\_66\_') demonstra uma correlação forte com a população branca ( $\rho = 0,72$ ), enquanto as relações com pretos e pardos sequer são significativas. Em termos de infraestrutura, a população idosa está fortemente correlacionada com as áreas com melhores condições de iluminação pública ( $\rho = 0,61$ ), esgotamento sanitário ( $\rho = 0,65$ ) e pavimentação ( $\rho = 0,67$ ).

A população economicamente ativa (fator 'id\_15\_65') possui forte associação com a provisão de água encanada ( $\rho = 0,90$ ), enquanto a relação é muito forte com o serviço de coleta de lixo ( $\rho = 0,98$ ), o número de residentes alfabetizados ( $\rho = 0,99$ ) e o de domicílios próprios ( $\rho = 0,92$ ). Esta faixa etária também apresenta uma associação forte e significativa com a população de crianças ( $\rho = 0,78$ ).

As características referentes à infraestrutura local apresentam algumas associações relevantes. O par iluminação e pavimentação é fortemente relacionado ( $\rho = 0,97$ ), ou seja, áreas com maior presença de um destes fatores tendem a possuir um padrão similar quanto ao outro. A mesma situação ocorre entre o acesso à agua encanada e a provisão de coleta de lixo ( $\rho = 0,90$ ). Por fim, o fator esgotamento sanitário apresenta uma relação mais intensa com água encanada ( $\rho = 0,70$ ) e coleta de lixo ( $\rho = 0,78$ ). Em termos da cor da população, os residentes pretos são os únicos com correlação significativa negativa (embora fraca) com fatores de infraestrutura, especificamente pavimentação ( $\rho = -0,26$ ) e iluminação pública ( $\rho = -0,24$ ). Os pardos só apresentam correlação significativa e forte com a provisão de água encanada ( $\rho = 0,64$ ) e coleta de lixo ( $\rho = 0,69$ ). Por fim, a população branca apresenta relação forte ( $\rho$  acima de 0,70) com todos os cinco fatores relativos a serviços públicos.

O número de residentes alfabetizados exprime uma associação forte com as faixas etárias de 0 a 14 anos ( $\rho = 0,72$ ) e acima dos 66 anos de idade ( $\rho = 0,61$ ), enquanto ela é extremamente forte com a população economicamente ativa ( $\rho = 0,99$ ). Brancos ( $\rho = 0,82$ ) e pardos ( $\rho = 0,61$ ) estão fortemente relacionados com a alfabetização, porém os pretos apenas moderadamente ( $\rho = 0,36$ ). Ao contrário do esperado, não há relação significativa com as variáveis de renda. Quanto à infraestrutura, existe uma associação forte com a provisão de água ( $\rho = 0,89$ ) e esgotamento sanitário ( $\rho = 0,81$ ), além de muito forte com a coleta de lixo ( $\rho = 0,98$ ).

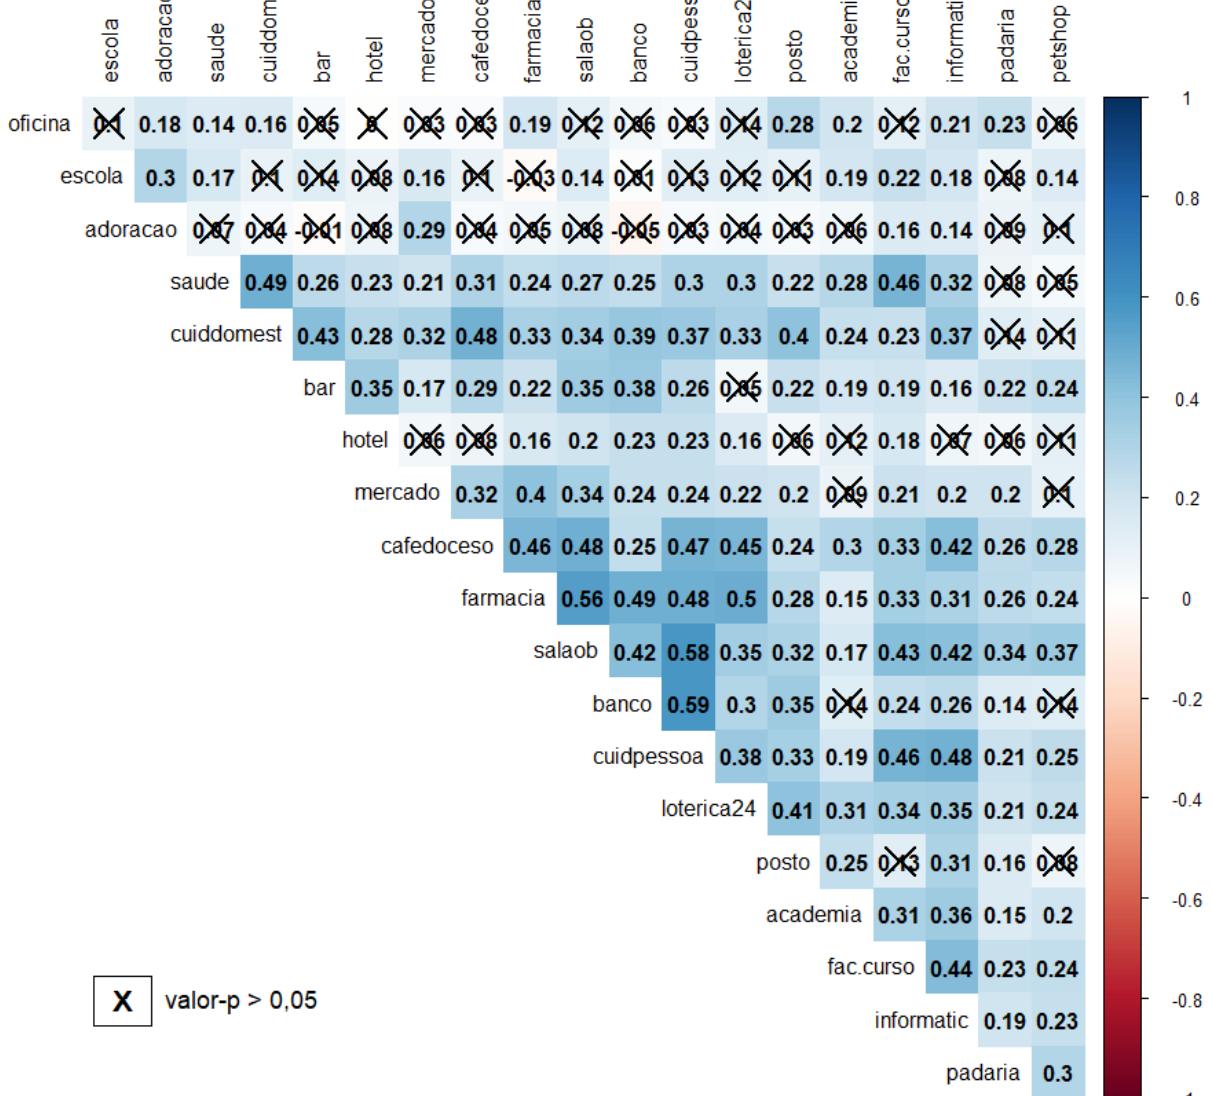
A propriedade do domicílio denota padrões associativos relevantes. Em termos de faixa etária, a população economicamente ativa é a que mais está associada com os domicílios próprios ( $\rho = 0,92$ ) e alugados ( $\rho = 0,70$ ). Por outro lado, as variáveis de renda não apresentam associação significativa com o tipo de propriedade das residências. Em uma comparação referente à infraestrutura, nota-se que os domicílios próprios estão mais fortemente relacionados (do que os alugados) com água, coleta de lixo e esgotamento sanitário. Por sua vez, os alugados superam os próprios na associação com iluminação pública ( $\rho = 0,63$ ) e pavimentação ( $\rho = 0,56$ ).

O grupo de preditores que representa os estabelecimentos comerciais também foi investigado mediante a correlação de Pearson, conforme apresentado na Figura 22. Em linhas gerais, há mais pares de determinantes sem associação significativa do que se verifica na matriz dos fatores demográficos e socioeconômicos (Figura 21). Além disso, não foram encontradas correlações negativas de intensidade forte ou muito forte (o maior  $\rho$  corresponde a 0,59, na faixa moderada). Os estabelecimentos menos correlacionados aos demais são os locais de adoração (apenas 5 fatores significativos dentre os 20 possíveis), as escolas e as oficinas (ambos associados com apenas 8 fatores). Por outro lado, as lojas de informática estão significativamente associadas com 19 das 20 instalações comerciais.

A comparação entre instalações comerciais ocorreu a partir do segmento de mercado, o qual deve ser semelhante ou complementar. Exemplificando, verificou-se que a associação entre os fatores 'escola' e 'fac.curso' é positiva, porém fraca ( $\rho = 0,22$ ). Apesar de ambos serem do setor de educação, espera-se que o público seja diferente – por consequência, o tipo de atenção proferida por criminosos. As escolas têm uma relação mais forte com os locais de adoração ( $\rho = 0,30$ ), enquanto as

faculdades e cursos estão mais associados com lojas de cuidados pessoais e unidades de saúde (ambos com  $\rho = 0,46$ ).

Figura 22 - Matriz de correlação das instalações comerciais



Fonte: O autor (2022)

A intensidade fraca de associação também ocorre entre farmácias e unidades de saúde ( $\rho = 0,24$ ), o que contradiz as expectativas de serem próximas a fim das farmácias reterem clientes logo após saírem de consultórios médicos. As unidades de saúde estão mais correlacionadas com as lojas de cuidados domésticos ( $\rho = 0,49$ ) e faculdades e cursos ( $\rho = 0,46$ ) – o que é ratificado pela proximidade espacial das maiores concentrações destes fatores em Boa Viagem e Pina (Figura 20).

A partição de uma diversidade de lojas entre cuidado pessoal e doméstico pode parecer arbitrária, mas a correlação apenas moderada ( $\rho = 0,37$ ) entre eles

denota que os dois grupos representam parcelas significativamente diferentes de informação. Enquanto o fator 'cuidpessoa' está mais associado com salões de beleza ( $\rho = 0,58$ ) e agências bancárias ( $\rho = 0,59$ ), 'cuiddomest' se relaciona mais intensamente com unidades de saúde ( $\rho = 0,49$ ), cafeterias ( $\rho = 0,48$ ) e bares ( $\rho = 0,43$ ). Vale destacar a associação moderada entre as lojas de cuidados pessoais e as instalações 'fac.curso' ( $\rho = 0,46$ ) e 'informatic' ( $\rho = 0,48$ ), que pode ser explicada pela aparente semelhança de públicos-alvo.

Bares e cafeterias são conhecidos como lugares de lazer que se diferenciam basicamente pelo consumo de bebidas alcoólicas. Em Boa Viagem e Pina eles demonstram uma associação fraca ( $\rho = 0,29$ ). Os dois fatores compartilham uma correlação mais significativa com as lojas de cuidados domésticos (bares com  $\rho = 0,43$ , cafés com  $\rho = 0,48$ ). A segunda relação mais forte deles remete a nichos diferenciados, sendo que os bares se associam mais com os bancos ( $\rho = 0,38$ ), enquanto as cafeterias com os salões de beleza ( $\rho = 0,48$ ).

Apesar de parecerem ter um perfil de público similar sob o ângulo do cotidiano das pessoas, os mercados e padarias apresentam uma associação fraca ( $\rho = 0,20$ ) na região de estudo. Os mercados possuem uma conexão mais intensa com farmácias ( $\rho = 0,40$ ), salões de beleza ( $\rho = 0,34$ ) e lojas de cuidados domésticos ( $\rho = 0,32$ ). Por sua vez, as padarias compartilham a relação moderada com salões de beleza ( $\rho = 0,34$ ), além de serem associadas significativamente com petshops ( $\rho = 0,30$ ) e cafeterias ( $\rho = 0,26$ ) – ambos em um nível fraco.

A atratividade turística dos bairros de Boa Viagem explica a quantidade de hotéis na região. Logo, espera-se que estes estabelecimentos estejam associados com outros que deem suporte aos turistas, principalmente para o lazer. A maioria das associações são fracas ou não significativas, de modo que apenas os bares e restaurantes apresentam uma relação moderada com os hotéis ( $\rho = 0,35$ ).

A conexão existente entre os fatores 'banco' e 'loterica24' é considerada fraca ( $\rho = 0,30$ ), embora ambos tenham o objetivo de prestar serviços bancários. De acordo com a Figura 20, eles se concentram em áreas vizinhas, porém pouco coincidentes na região de estudo, o que pode indicar a intenção de atender públicos diferentes. Os bancos estão mais fortemente relacionados com as lojas de cuidado pessoal ( $\rho = 0,59$ ) e as farmácias ( $\rho = 0,49$ ). Por sua vez, o fator 'loterica24' tem associação mais significativa com farmácias ( $\rho = 0,50$ ), cafeterias ( $\rho = 0,45$ ) e postos

de gasolina ( $\rho = 0,41$ ). Os postos se justificam pela presença de bancos 24 horas na seção de conveniência de alguns deles.

Os fatores ‘salaob’ e ‘cuidpessoa’ apresentam a segunda maior correlação entre os pares de estabelecimentos ( $\rho = 0,58$ ), embora seja de nível moderado. Os salões de beleza, inclusive, são a maior associação dos petshops ( $\rho = 0,37$ ), o que mostra uma ligação entre o cuidado dirigido aos animais de estimação com o de seus tutores.

No setor automotivo, as oficinas e postos de gasolina funcionam de modo complementar, tendo em vista que em alguns locais eles são vizinhos ou até ocupam o mesmo espaço. Contudo, na região de estudo eles apresentam uma associação fraca ( $\rho = 0,28$ ) – que, inclusive, é a maior entre oficinas e quaisquer fatores. Já os postos de gasolina apresentam conexões mais fortes com lotéricas e bancos 24 horas ( $\rho = 0,41$ ) e lojas de cuidados domésticos ( $\rho = 0,40$ ).

### **7.1.2 Associação entre roubos e variáveis explanatórias**

A ocorrência de roubos na região de interesse foi explicada segundo um conjunto de variáveis explanatórias, conduzindo-se estudos em paralelo constando 17 fatores demográficos e socioeconômicos (Quadro 5) e 20 instalações comerciais (Quadro 6). Buscou-se associar a exploração estatística com as diferentes fases da pandemia de COVID-19 (crescimento, pico e queda). Logo, cinco meses foram selecionados conforme o comportamento das curvas de casos e óbitos por COVID-19 em termos da média móvel (Figura 5) e do acumulado mensal (Figura 6) na cidade do Recife. Destes meses, os dados georreferenciados de roubos nos bairros de Boa Viagem e Pina foram retidos para as análises de correlação espacial e regressão (OLS e GWR).

O mês de maio de 2020 foi escolhido por conter o pico (média móvel e acumulado mensal) de casos notificados da primeira onda da pandemia, bem como o pico absoluto no acumulado mensal de óbitos por COVID-19 até o fim do período analisado neste estudo (maio de 2021). Por sua vez, outubro de 2020 fez parte da análise por ter o nível mais baixo de casos (acumulado mensal) e mortes (média móvel e acumulado mensal) da pandemia. Ademais, dezembro de 2020 foi selecionado por deter o segundo maior acumulado mensal em casos até então, além

de uma tendência de crescimento acelerado na média móvel de casos (em parte, devido à vasta reabertura do comércio para as festividades de fim de ano).

No ano de 2021, dois meses foram investigados. Fevereiro foi um destes, pois demonstrou um aumento rápido no acumulado de casos notificados de COVID-19 em comparação ao leve declínio percebido em janeiro, além de registrar também um novo pico da média móvel de casos até então. O mês também foi marcado por festas clandestinas de Carnaval, apesar das restrições governamentais vigentes. Por fim, maio foi selecionado porque apresentou o maior pico da pandemia no acumulado mensal de casos até então, assim como o pico no acumulado e na média móvel de óbitos da segunda onda da doença.

Com os cinco meses definidos, conduziu-se uma análise de correlação espacial por meio da estatística Global Moran's I bivariada entre cada fator preditivo e o acumulado mensal de roubos em Boa Viagem e Pina. Os resultados relativos aos indicadores censitários se encontram no Quadro 9, enquanto os que abrangem as instalações comerciais estão no Quadro 10. As células contêm o valor da estatística e o respectivo pseudo valor-p; as que apresentam associações estatisticamente significativas (valor-p < 0,05) estão marcadas em cinza.

Em relação aos preditores socioeconômicos, alguns deles se destacaram positivamente por terem se mantido significativos por pelo menos dois meses dentre os cinco avaliados. Logo, esses fatores possuem uma influência espacial relevante sobre os roubos. Por exemplo, a densidade populacional se manteve negativamente associada com os roubos durante quatro meses. Isto é, uma elevada densidade populacional nos setores censitários vizinhos influencia linearmente na redução dos roubos em determinado setor.

A renda e a variação da renda estiveram significativas durante três meses; simultaneamente em maio de 2020 e fevereiro de 2021. Dentre os fatores significativos, estes dois foram os únicos que oscilaram em algum momento da correlação negativa para a positiva; para ambos, ocorreu na transição de maio de 2020 a outubro de 2020.

Por fim, as faixas etárias de 0 a 14 anos e acima de 66 anos de idade, a população preta, parda, o acesso a esgotamento sanitário e a presença de domicílios próprios se mostraram significativos em dois meses. De forma simultânea, os fatores 'id\_0\_14', 'pardo' e 'preto' em outubro e dezembro de 2020; 'id\_66\_' e 'esgoto' em outubro de 2020 e fevereiro de 2021.

Em geral, a estatística de correlação dos indicadores censitários produziu valores baixos e sem grandes oscilações (em módulo). Uma prova é que apenas os fatores ‘id\_0\_14’ e ‘id\_66\_’ obtiveram um índice superior a 0,1 (em módulo). Como destaque negativo, ressalta-se que a população branca e a pavimentação das ruas não se mostraram significativas em nenhum mês analisado. Ademais, no mês de maio de 2021 só houve correlação significativa com dois fatores: densidade populacional (negativamente) e variância da renda (positivamente).

Quadro 9 - Correlação espacial entre os indicadores censitários e os roubos em Boa Viagem e Pina

Preditor	Global Moran's I bivariado (pseudovar-p)				
	Mai/2020	Out/2020	Dez/2020	Fev/2021	Mai/2021
denspop	-0,073 (0,008)	-0,049 (0,048)	-0,029 (0,164)	-0,05 (0,050)	-0,073 (0,008)
id_0_14	0,009 (0,380)	-0,095 (0,001)	-0,103 (0,000)	-0,03 (0,157)	-0,007 (0,432)
id_15_65	0,024 (0,208)	-0,022 (0,244)	-0,064 (0,016)	-0,001 (0,496)	0,013 (0,324)
id_66_	0,004 (0,437)	0,124 (0,000)	0,041 (0,090)	0,061 (0,026)	0,004 (0,438)
branco	-0,004 (0,460)	0,03 (0,154)	-0,026 (0,207)	0,02 (0,248)	0,006 (0,410)
pardo	0,034 (0,133)	-0,062 (0,016)	-0,07 (0,007)	-0,013 (0,339)	0,014 (0,309)
preto	0,019 (0,254)	-0,059 (0,021)	-0,06 (0,017)	-0,041 (0,085)	-0,025 (0,204)
alfab	0,024 (0,214)	-0,006 (0,441)	-0,058 (0,029)	0,008 (0,382)	0,011 (0,343)
renda	-0,081 (0,004)	0,086 (0,003)	0,038 (0,100)	0,082 (0,004)	0,022 (0,223)
var_renda	-0,06 (0,008)	0,045 (0,076)	0,023 (0,206)	0,083 (0,010)	0,066 (0,027)
lixo	0,029 (0,168)	-0,012 (0,365)	-0,058 (0,028)	0,006 (0,410)	0,017 (0,275)
agua	0,018 (0,267)	-0,04 (0,094)	-0,077 (0,005)	-0,034 (0,134)	-0,037 (0,113)
esgoto	0,009 (0,372)	0,065 (0,020)	-0,001 (0,500)	0,054 (0,042)	0,044 (0,075)
pavim	0,038 (0,100)	0,026 (0,185)	-0,002 (0,487)	0,022 (0,224)	0,016 (0,291)
ilum_pub	0,063 (0,019)	0,046 (0,066)	0,005 (0,419)	0,042 (0,079)	0,04 (0,093)
dom_alug	0,073 (0,010)	0,014 (0,310)	-0,002 (0,489)	0,03 (0,154)	0,027 (0,174)
dom_prop	-0,004 (0,445)	-0,048 (0,049)	-0,064 (0,016)	-0,023 (0,232)	-0,034 (0,135)

Fonte: O autor (2022)

Os meses com maior quantidade de fatores significativos foram outubro e dezembro de 2020, nos quais oito dentre os 17 preditores alcançaram valor-p inferior a 0,05. Em ambos os meses, as populações preta e parda e os domicílios próprios se sobressaíram (todos com associação negativa aos roubos). A faixa etária das crianças foi significativa em ambos (negativamente), enquanto os idosos se correlacionaram com os crimes apenas em outubro (positivamente) e a população economicamente ativa em dezembro (negativamente). Quanto à infraestrutura, só o esgotamento sanitário teve associação significativa em outubro (positiva), enquanto em dezembro foram a coleta de lixo e a água encanada (ambos negativos).

Por fim, uma análise referente aos blocos de indicadores censitários aponta que, em maio de 2020 e de 2021, as faixas etárias e a cor da população (essa também em fevereiro de 2021) não tiveram associação significativa com os roubos. Dezembro foi o único mês em que as variáveis de renda não foram relevantes, embora tenha sido uma época de efervescência comercial e a renda reflita poder de compra. Os blocos de infraestrutura e renda foram os mais relevantes ao longo do tempo, visto que ao menos uma de suas variáveis foi significativa em quatro dos cinco meses investigados.

A análise de correlação espacial também foi conduzida entre os roubos e os fatores que representam a atividade comercial em Boa Viagem e Pina (Quadro 10). Parte destes preditores foram evidenciados por terem sido estatisticamente significativos em pelo menos três dentre os cinco meses investigados. As lojas de cuidados domésticos foram as mais marcantes, visto que estiveram nessa situação em todos os cinco recortes temporais. Elas demonstraram uma associação positiva com a quantidade de roubos, logo, áreas com grande volume desses crimes tendem a ser circundadas por uma quantidade mais elevada desse tipo de estabelecimento.

Durante três dos cinco meses, os preditores ‘adoração’, ‘banco’, ‘bar’, ‘cuidpessoa’, ‘informatic’, ‘oficina’ também se mostraram significativos. Destes, apenas ‘banco’ e ‘bar’ coincidiram quanto ao momento de relevância (outubro de 2020, fevereiro e maio de 2021), além de que ambos influenciam diretamente (relação positiva) no aumento dos roubos.

Assim como ocorreu para os preditores socioeconômicos, a estatística Global Moran’s I bivariada obteve desempenho baixo e com poucas oscilações dos valores. Isso é ratificado por apenas dois fatores ultrapassarem o índice de 0,1 (em módulo): ‘cafedoceso’ e ‘cuiddomest’. Por outro lado, uma quantidade expressiva de fatores

não foi significativa em nenhum dos meses explorados, sendo eles: 'loterica24', 'mercado', 'padaria', 'postog', 'salaob' e 'saude'.

Quadro 10 - Correlação espacial entre as instalações comerciais e os roubos em Boa Viagem e Pina

Preditor	Global Moran's I bivariado (pseudo valor-p)				
	Mai/2020	Out/2020	Dez/2020	Fev/2021	Mai/2021
Academia	0,08 (0,008)	0,017 (0,280)	0,012 (0,321)	-0,003 (0,487)	0,068 (0,018)
Adoração	0,06 (0,029)	-0,033 (0,133)	-0,049 (0,046)	-0,07 (0,007)	-0,033 (0,140)
Banco	-0,037 (0,117)	0,096 (0,003)	0,039 (0,105)	0,06 (0,029)	0,059 (0,033)
Bar	0,049 (0,057)	0,055 (0,039)	0,038 (0,106)	0,055 (0,038)	0,072 (0,014)
Cafedoceso	0,005 (0,401)	0,034 (0,128)	0,016 (0,267)	0,07 (0,014)	0,103 (0,002)
Cuiddomest	0,063 (0,032)	0,093 (0,003)	0,068 (0,023)	0,078 (0,009)	0,132 (0,000)
Cuidpessoa	0,012 (0,309)	0,082 (0,008)	0,054 (0,050)	0,076 (0,010)	0,052 (0,052)
Escola	0,069 (0,016)	-0,017 (0,300)	-0,034 (0,134)	-0,074 (0,005)	-0,014 (0,341)
Fac.curso	-0,004 (0,491)	0,014 (0,304)	0,019 (0,242)	0,052 (0,045)	0,014 (0,294)
Farmacia	-0,001 (0,469)	0,049 (0,057)	0,036 (0,115)	0,053 (0,045)	0,067 (0,020)
Hotel	0,042 (0,083)	0,071 (0,015)	0,049 (0,061)	0,048 (0,064)	0,007 (0,384)
Informatic	0,068 (0,022)	0,042 (0,083)	0,071 (0,018)	0,038 (0,106)	0,086 (0,006)
Loterica24	-0,031 (0,170)	0,04 (0,092)	0,01 (0,321)	0,001 (0,465)	0,026 (0,185)
Mercado	0,023 (0,213)	-0,017 (0,290)	-0,045 (0,063)	-0,021 (0,253)	0,005 (0,406)
Oficina	0,098 (0,003)	-0,001 (0,493)	0,011 (0,326)	0,055 (0,041)	0,078 (0,013)
Padaria	0,029 (0,159)	-0,01 (0,383)	-0,026 (0,213)	0,011 (0,346)	-0,011 (0,375)
Petshop	0,085 (0,006)	0,039 (0,101)	0,019 (0,247)	-0,013 (0,347)	-0,037 (0,108)
Postog	0,01 (0,341)	0,009 (0,357)	-0,025 (0,230)	-0,012 (0,354)	0,013 (0,310)
Salaob	0,003 (0,422)	0,016 (0,282)	0,013 (0,302)	0,015 (0,291)	-0,013 (0,353)
Saude	0,01 (0,324)	0,014 (0,288)	0,001 (0,424)	0,028 (0,166)	0,053 (0,052)

Fonte: O autor (2022)

Dentre os 14 estabelecimentos comerciais significativos em algum mês, apenas dois tiveram uma correlação espacial negativa com os roubos: escolas e locais de adoração. Inclusive, esses foram os únicos fatores que transitaram da influência positiva para negativa durante os meses em que foram significativos. Em ambos essa mudança de sinal ocorreu entre maio e outubro de 2020 (embora no segundo mês eles ainda não fossem significativos).

A respeito da quantidade de instalações relevantes por mês, fevereiro de 2021 obteve o maior número de fatores (dez), enquanto dezembro de 2020 apresentou apenas quatro. Este padrão em dezembro diverge da expectativa de um maior número de roubos como consequência de um incremento no fluxo comercial nesse fim de ano. Aliás, dentre os quatro estabelecimentos, um não deveria ser afetado pelo fenômeno comercial – os locais de adoração.

Os resultados da correlação espacial para maio de 2020 não refletem de fidedignamente o contexto local. Por ser o momento do primeiro pico de casos e mortes da pandemia, o governo de Pernambuco impôs uma quarentena estrita que permitiu o funcionamento de um conjunto diminuto de serviços essenciais durante a segunda quinzena do mês (JCPE, 2020). Esperava-se que apenas os estabelecimentos autorizados a abrir se mostrassem significativos. Contudo, alguns fatores salientados estiveram fechados ('adoração', 'academia', 'cuiddomest', 'escola', 'oficina') ou atuaram apenas como ponto de coleta ('informatic') durante o mês; apenas os petshops foram significativos e puderam funcionar.

Posteriormente, executou-se uma análise multivariada por meio de modelos de regressão global (OLS) e local (GWR). A variável dependente foi a quantidade mensal de roubos nos cinco meses investigados até aqui, enquanto as variáveis explanatórias foram divididas em dois grupos conforme a origem dos dados. Os modelos parcimoniosos resultantes contendo apenas fatores demográficos e socioeconômicos (oriundos do IBGE) estão no Quadro 11, ao passo que os modelos com instalações comerciais (oriundas do Google Earth) seguem no Quadro 12. Ao lado de cada fator está o sinal do coeficiente no modelo de regressão a fim de contribuir na posterior análise multicritério. Os fatores significativos individualmente na regressão múltipla (valor-p < 0,05) estão marcados com asterisco (\*).

No tocante à regressão para aspectos socioeconômicos (Quadro 11), todos os modelos foram significativos (valor-p < 0,05), apesar de apresentarem valores de R<sup>2</sup> ajustado baixos. A aplicação da regressão GWR aumentou o poder de predição da

maioria dos modelos, visto o aumento no  $R^2$  ajustado em maio e dezembro de 2020 e maio de 2021. Em termos da redução na estatística AICc, só houve melhoria significativa – isto é, acima de 2 unidades (CHATTERJEE; HADI, 2013) – na qualidade dos modelos ao adotar regressão espacial em maio de 2021. Em síntese, houve um progresso considerável na capacidade explicativa dos modelos (aumento no  $R^2$  ajustado) entre maio de 2020 e maio de 2021.

Quadro 11 - Regressão stepwise para indicadores censitários

Mês	Modelo parcimonioso	OLS $R^2$ ajustado (AICc)	GWR $R^2$ ajustado (AICc)	GWR Range do $R^2$ Local
Maio/2020	denspop*(-) + renda*(-) + dom_alug*(+) + pardo*(-)	0,1008 (509,07)	0,1095 (509,05)	0,0967 a 0,1675
Outubro/2020	denspop*(-) + agua(-) + esgoto*(+) + id_66_*(+)	0,1284 (597,21)	0,1207 (600,85)	0,1268 a 0,1727
Dezembro/2020	denspop*(-) + var_renda(-) + id_66_*(+)	0,1294 (630,78)	0,1393 (630,90)	0,1279 a 0,1532
Fevereiro/2021	denspop*(-) + agua*(-) + esgoto*(+) + dom_alug*(+)	0,1747 (610,29)	0,1725 (612,91)	0,1791 a 0,2053
Maio/2021	denspop*(-) + renda*(-) + var_renda*(+) + esgoto*(+) + dom_prop(-) + pavim(+) + id_66_(-)	0,2836 (623,36)	0,3123 (620,82)	0,1256 a 0,4545

Fonte: O autor (2022)

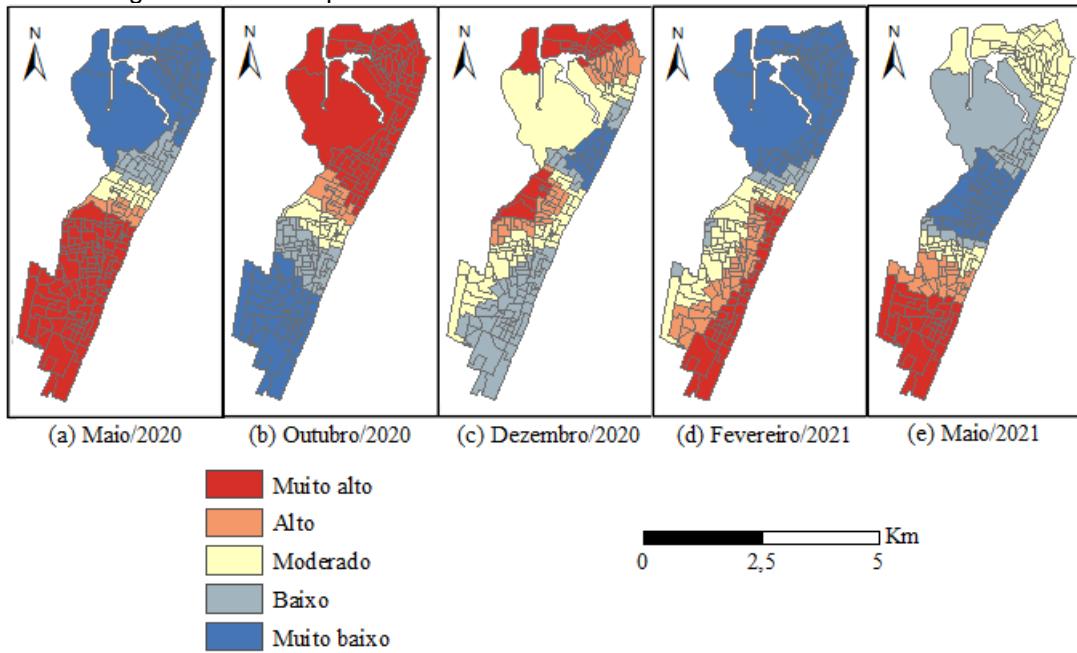
O uso do método GWR possibilitou gerar modelos de regressão para cada um dos 206 setores censitários que constituem os bairros de Boa Viagem e Pina. Como resultado, obteve-se um  $R^2$  local para cada setor. Em dezembro de 2020 e fevereiro de 2021, as amplitudes do intervalo deste coeficiente foram bastante pequenas (em torno de 0,025). Isto denota a pouca influência das características espaciais na predição destes modelos. Por outro lado, no mês de maio de 2021 verificou-se a amplitude mais acentuada (em torno de 0,30) e o maior extremo superior (0,4545) dentre os períodos analisados. Assim, o uso de um modelo espacial foi especialmente importante neste mês.

Alguns determinantes socioeconômicos apareceram mais frequentemente nos modelos parcimoniosos ao longo da pandemia, sendo importantes para a predição de roubos. Assim, vale ressaltar: densidade populacional, renda e variância da

renda, idosos e esgotamento sanitário. A quantidade de variáveis também foi bastante reduzida, pois inicialmente se explorou um conjunto de 17 fatores e os modelos finais têm, no máximo, sete preditores (e no mínimo, três).

O  $R^2$  local foi representado em mapas na Figura 23. Como cada mês apresenta faixas de valores diferentes para o coeficiente, eles foram convertidos na escala de 'muito baixo' a 'muito alto'. A distribuição espacial do poder explicativo da regressão mudou bastante. A predição dos roubos ao norte foi melhor representada em outubro e dezembro de 2020; ao sul em maio de 2020 e fevereiro e maio de 2021; e, por fim, ao centro em todos os meses, exceto maio de 2021.

Figura 23 - Desempenho do  $R^2$  local com base em indicadores censitários



Fonte: O autor (2022)

Acerca dos *clusters* de roubos (Figura 13 e Figura 14), algumas áreas com  $R^2$  'muito alto' coincidiram com *clusters* High-High. Tal fato ocorreu com apenas dois *clusters* em maio de 2020, a maioria destes em outubro de 2020, todos existentes em fevereiro de 2021 e metade dos que surgiram em maio de 2021. Assim, de um modo geral, a regressão espacial obteve melhores resultados nos locais onde há concentração significativa de roubos.

Os resultados para as instalações comerciais estão no Quadro 12. Nenhum fator demonstrou correlação significativa com base no VIF, pois todos tiveram estatística inferior a 2,5 (o máximo permitido era 7,5). Isto é, embora algumas instalações tenham um coeficiente de Pearson significativo quando avaliadas par a

par (Figura 22), essas associações se tornam fracas quando a comparação ocorre simultaneamente com todo o conjunto de 20 preditores. Assim, nenhum fator foi retirado por correlação e o método *stepwise* foi aplicado diretamente.

Quadro 12 - Regressão *stepwise* para instalações comerciais

Mês	Modelo parcimonioso	OLS R <sup>2</sup> ajustado (AIC)	GWR R <sup>2</sup> ajustado (AIC)	GWR Range do R <sup>2</sup> Local
Maio/2020	academia*(-) + banco*(+) + cafedoceso(-) + cuiddomest*(+) + escola*(+) + fac.curso*(+) + loterica24(+) + oficina*(+) + petshop*(+) + saúde(+) +	0,3260 (457,15)	0,3462 (454,76)	0,2902 a 0,4679
Outubro/2020	banco(+) + bar(+) + cafedoceso*(+) + cuiddomest*(-) + cuidpessoa(+) + hotel(+) + petshop(-)	0,1594 (592,35)	0,3779 (573,40)	0,0649 a 0,6131
Dezembro/2020	academia*(+) + banco*(+) + cuidpessoa(+) + escola*(+) + hotel*(+) + informatic(-) + loterica24*(+) + mercado(-) + padaria*(+) + salaob(-) + saúde*(+)	0,4263 (559,36)	0,4331 (555,88)	0,3750 a 0,5357
Fevereiro/2021	academia(+) + cafedoceso(-) + cuidpessoa(+) + hotel*(+) + informatic*(-) + mercado(+) + saude*(+)	0,1973 (609,18)	0,2177 (605,53)	0,1248 a 0,3547
Maio/2021	academia(+) + banco(+) + bar(+) + cafedoceso*(+) + fac.curso(+) + informatic*(-) + oficina*(+) + petshop(-) + postog(-)	0,1796 (652,48)	0,2236 (648,42)	0,1598 a 0,3291

Fonte: O autor (2022)

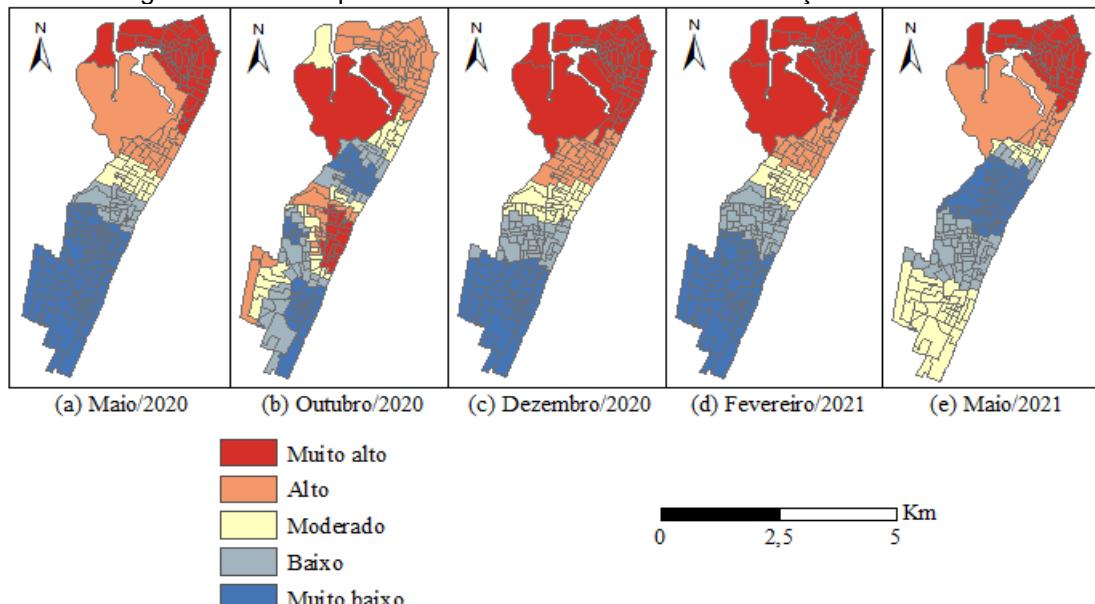
Em geral, os meses de 2020 obtiveram desempenhos superiores aos de 2021 para este conjunto de determinantes. Assim como ocorreu com os indicadores censitários, houve uma melhoria pequena do modelo OLS para o GWR. Porém, aqui todos os modelos tiveram redução significativa no AICc (acima de 2 unidades). Além disso, na comparação mês a mês, a amplitude do R<sup>2</sup> local e o patamar do R<sup>2</sup> ajustado são consideravelmente superiores aos verificados para os preditores socioeconômicos – em ambos os casos, exceto em maio de 2021.

O mês de outubro de 2020 foi o maior beneficiado pela aplicação da regressão espacial, tendo em vista a maior elevação do R<sup>2</sup> ajustado entre os dois métodos, a maior amplitude do R<sup>2</sup> local e o maior valor registrado para este coeficiente (0,6131). Em termos do desempenho geral no GWR, os roubos em dezembro de 2020 tiveram a sua variabilidade melhor explicada pelas instalações comerciais do que nos demais meses devido ao maior registro de R<sup>2</sup> ajustado.

Ao contrário do que houve com os indicadores censitários, a redução na quantidade de variáveis explanatórias no modelo parcimonioso ocorreu em menor escala. Os modelos possuem entre 7 e 11 preditores, sendo que 18 dos 20 estabelecimentos comerciais foram relevantes em ao menos um mês (todos, exceto 'adoração' e 'farmácia'). Alguns fatores apareceram em ao menos três dos cinco meses investigados, sendo eles: 'academia', 'banco', 'cafedoceso', 'cuidpessoa', 'petshop', 'saude' e 'hotel'. Logo, eles são relevantes para a análise estatística. Destes, apenas 'academia', 'cafedoceso' e 'petshop' alternaram o sinal da contribuição (positivo ou negativo) para a predição dos roubos ao longo dos meses.

O  $R^2$  local dos modelos para instalações comerciais também foi representado em mapas na Figura 24. Em comparação à Figura 23, verifica-se que o padrão espacial oscilou consideravelmente menos. Os desempenhos mais altos se concentraram ao norte, enquanto os menores ao sul. As poucas exceções ocorreram em outubro de 2020 com a faixa 'muito alto' localizada no centro-leste da região de estudo e parte da 'muito baixo' no centro-norte, assim como em maio de 2021 a faixa 'muito baixo' esteve situada ao centro.

Figura 24 - Desempenho do  $R^2$  local com base em instalações comerciais



Fonte: O autor (2022)

Comparou-se a localização dos *clusters* de roubos (Figura 13 e Figura 14) e o padrão do  $R^2$  local em Boa Viagem e Pina (Figura 24). A maioria dos *clusters* High-High (HH) em maio de 2020 (ao norte) coincidiram com um desempenho 'muito alto'

do coeficiente, enquanto em outubro de 2020 ocorreu o inverso (HH em área ‘muito baixo’). Em fevereiro de 2021, os HH estiveram em setores com desempenho ‘alto’ ou ‘moderado’, enquanto em maio do mesmo ano eles constaram em áreas de performance ‘moderada’ (no extremo sul) ou ‘muito alta’ (ao norte). Assim, a adoção do GWR foi positiva por apresentar poder explicativo elevado justamente onde os roubos se concentram espacialmente em relação às áreas vizinhas.

## 7.2 Análise multicritério de áreas vulneráveis a roubos

Esta seção dedica-se à construção do modelo multicritério, incluindo o processo de construção dos critérios e a aplicação do modelo.

### 7.2.1 Construção dos critérios

A presente seção descreve a seleção e o desenvolvimento dos critérios para o modelo multicritério, a qual fundamenta-se na prévia exploração estatística e espacial das variáveis explanatórias de roubos.

#### 7.2.1.1 Aspectos demográficos e socioeconômicos

Um dos objetivos do presente estudo consiste em desenvolver um modelo multicritério para classificar os setores censitários de Boa Viagem e Pina quanto à vulnerabilidade a roubos. Para este propósito, é necessário selecionar um conjunto de critérios de avaliação que representem objetivos conflitantes e sejam não redundantes, exaustivos e consistentes (de ALMEIDA, 2013). Neste sentido, utilizou-se como suporte os resultados da fase de exploração estatística dos roubos em relação aos indicadores censitários, além da literatura criminal.

Adotou-se como parâmetro de filtragem inicial a existência de significância estatística da correlação espacial desses fatores com os roubos em pelo menos dois dos cinco meses investigados. Neste recorte, se encaixam os fatores ‘denspop’, ‘renda’, ‘var\_renda’, ‘id\_0\_14’, ‘id\_66\_’, ‘pardo’, ‘preto’, ‘esgoto’ e ‘dom\_prop’. Aqueles que não se destacaram em nenhum mês analisado foram descartados em definitivo, particularmente ‘branco’ e ‘pavim’.

Paralelamente, um novo grupo de preditores relevantes foi formado com aqueles presentes em ao menos dois modelos de regressão parcimoniosos. Isso inclui: 'denspop', 'esgoto', 'id\_66\_', 'renda', 'var\_renda', 'agua' e 'dom\_alug'. Os determinantes que estão na interseção deste grupo com o da filtragem inicial foram definidos como potenciais critérios, sendo eles: 'denspop', 'renda', 'var\_renda', 'id\_66\_' e 'esgoto'.

A densidade populacional foi selecionada como critério. Ela está bastante presente na literatura criminal por consistir nas oportunidades criminais (em termos de alvos em potencial) em determinada área (HARRIES, 1974). Ademais, ela normalmente apresenta uma associação positiva com os roubos em áreas ao nível de microambiente (como bairros ou unidades menores) (HIPP; ROUSSELL, 2013). Contudo, as análises de regressão e de *clusters* indicaram fortes evidências de que essa densidade está negativamente relacionada à ocorrência de roubos na região de estudo. Como, de acordo com a Teoria da Atividade de Rotina, o crime ocorre quando há prováveis infratores, alvos adequados e falta de vigilantes (COHEN; FELSON, 1979), então a densidade populacional pode refletir não apenas o número de potenciais vítimas. Neste caso, também evidencia os vigilantes que podem flagrar e denunciar o roubo. Logo, são áreas de menor interesse aos delinquentes.

A população idosa também se tornou um critério. Embora pesquisas indiquem que os idosos são menos propensos à vitimização por roubos do que outras faixas etárias (BACHMAN, DILLAWY; LACHS, 1998), em Boa Viagem e no Pina essa situação é diferente. Observou-se que essa fatia da população possui correlação moderada e positiva com a renda domiciliar. Com base no conhecimento da região, isto é um indicativo de que pessoas mais velhas tendem a ser associadas com melhores condições financeiras. Adicionalmente, elas se tornam alvos atraentes por terem uma chance maior de ter dificuldades para reagir a crimes devido à senilidade.

O acesso a esgotamento sanitário foi selecionado para a família de critérios. Um melhor desempenho neste fator remete a áreas com infraestrutura mais desenvolvida, o que indica uma população com melhores condições de vida e, consequentemente, mais atrativa à vitimização por crimes patrimoniais. Em consonância com a Teoria da Desorganização Social, esse critério tem sido incluído em outros estudos criminais para capturar a vulnerabilidade socioeconômica em termos da precariedade na provisão de serviços públicos (FIGUEIREDO; MOTA, 2016; PEREIRA; MOTA; ANDRESEN, 2017a).

Julgou-se que o fator ‘esgoto’ por si só não contempla a questão dos serviços públicos de modo suficientemente amplo. Dentre os outros quatro determinantes ressaltados na etapa estatística, a iluminação pública foi selecionada como critério. Embora só tenha se mostrado significativa durante a correlação espacial no mês de maio de 2020, para um valor-p igual a 0,10 ela também seria em outros três meses. Ademais, em comparação aos outros fatores de infraestrutura, ela apresenta valores menores na correlação de Pearson. A iluminação contribui na identificação de criminosos em crimes contra o patrimônio (DAVIES; FARRINGTON, 2020) porque aumenta a chance de ser flagrado, o que inclusive impacta na redução dos roubos (FARRINGTON; WELSH, 2002). Isto é, locais com uma melhor iluminação tendem a ser menos preferíveis aos criminosos. Vale ressaltar que, em um contexto de pandemia, o período noturno pode ser mais perigoso devido às restrições no horário de funcionamento do comércio (isto é, menos pessoas nas ruas), especialmente onde a iluminação é deficitária.

Por outro lado, os fatores ‘renda’ e ‘var\_renda’ representam um único viés da vulnerabilidade a roubos: o poder financeiro da população residente. Além disso, esses fatores são moderadamente correlacionados entre si. A variância da renda apresenta menos correlações significativas com os demais determinantes (apenas 4 dentre 16 possíveis), sendo a maior delas com a renda. Enquanto a renda apresenta correlação moderada com alguns dos potenciais critérios selecionados (‘id\_66’, ‘esgoto’ e ‘renda’), a variância da renda tem apenas uma relação fraca com ‘id\_66’. Logo, ao menos do ponto de vista estatístico, o fator ‘var\_renda’ consegue ser mais distintivo para o presente estudo.

A fim de embasar e concluir a escolha entre os dois fatores, recorreu-se à literatura. A Teoria da Desorganização Social defende a desigualdade de renda como preditor criminal significativo. A associação dele com crimes em geral já foi comprovada por estudos recentes e mostrou-se com tendência crescente ao passar dos anos (HIPP; KANE, 2017). Em países de baixa e média renda, como o Brasil, a desigualdade de renda possui associação forte com os índices de roubos (WOLF; GRAY; FAZEL, 2014). Portanto, optou-se por incorporar a variância da renda ao conjunto de critérios para representar a desigualdade.

A questão da cor da população também é importante na região de estudo, tendo em vista os padrões encontrados nos *clusters* HH e LL. De fato, a diversidade racial da população é um importante preditor de roubos, estando positivamente

associada com estes crimes (HIPP; KANE, 2017), especialmente ao nível de bairros (WENGER, 2019). Assim como ocorreu com a privação socioeconômica e a desigualdade de renda, a heterogeneidade étnica/racial é defendida como forte variável explicativa pela Teoria da Desorganização Social.

Em áreas de maior concentração criminal (HH) a população branca se apresenta em maior número, enquanto na situação contrária (LL) os pretos e pardos predominam. Como os brancos não tiveram correlação espacial significativa com os roubos em nenhum dos cinco meses investigados, julgou-se que esse fator não deve se tornar um critério. Por outro lado, as quantidades de pretos e de pardos se mostraram significativas em dois meses. Estes dois preditores estão fortemente correlacionados entre si e apresentam correlação negativa com o fator 'renda' – cujo os pretos possuem associação mais forte. Isto é, ambos remetem a uma população de menor renda domiciliar e que, provavelmente, não portam itens com valor agregado alto e atraente aos criminosos.

A seleção do critério se restringiu, então, a pretos e pardos. Em relação aos demais critérios já estabelecidos, os pardos possuem associação moderada com 'esgoto', enquanto os pretos possuem fraca com 'ilum\_pub'. Com base nisso e em conhecimentos sobre os bairros investigados, espera-se que ambos residam em ambientes desestruturados e menos atraentes à prática de roubos. Nas regiões LL para roubos (áreas de baixa incidência criminal rodeadas por padrão semelhante), os pretos acabaram tendo uma presença levemente superior aos pardos. Assim, conclui-se que a população preta apresenta maior poder distintivo neste viés de avaliação, de modo que foi estabelecida como critério.

#### *7.2.1.2 Fluxo comercial e de pessoas*

Ao contrário do que ocorreu com as variáveis demográficas e socioeconômicas, julgou-se que cada um dos estabelecimentos comerciais contribui de forma relevante para ocorrência de crimes na região de estudo. Logo, eles serão mantidos integralmente para a análise multicritério. Contudo, de acordo com o contexto criminológico local e a existência de correlação significativa entre os preditores, entende-se que eles devem ser agrupados em fatores não-correlacionados. Para este fim aplicou-se uma Análise fatorial exploratória.

No teste de Kayser-Meyer-Olkin, os valores das medidas de adequação da amostra (MSA) excederam 0,50 tanto para o teste geral (MSA = 0,83) quanto para as variáveis individualmente, conforme o Quadro A.1 (Apêndice A). Por sua vez, o teste de esfericidade de Bartlett foi estatisticamente significativo (valor-p =  $2,93 \times 10^{-157}$ ), logo há correlação suficiente entre os preditores para realizar a Análise fatorial. Deste modo, como ambos os resultados apoiam a hipótese de que há uma estrutura fatorial entre os preditores, então a Análise fatorial é válida (HAIR et al., 2009).

Testes estatísticos também foram conduzidos para auxiliar na definição da quantidade de fatores. Segundo o critério do teste scree verificado na Figura A.1 (Apêndice A), a quantidade ideal seria de sete fatores, visto que o declive do gráfico se torna mais suave a partir do fator seguinte. No que lhe concerne, o critério da raiz latente aponta que seis fatores representam bem o conjunto de variáveis, pois o sexto fator é o último (em ordem crescente) para o qual o autovalor é maior do que 1 conforme disposto no Quadro A.2 (Apêndice A).

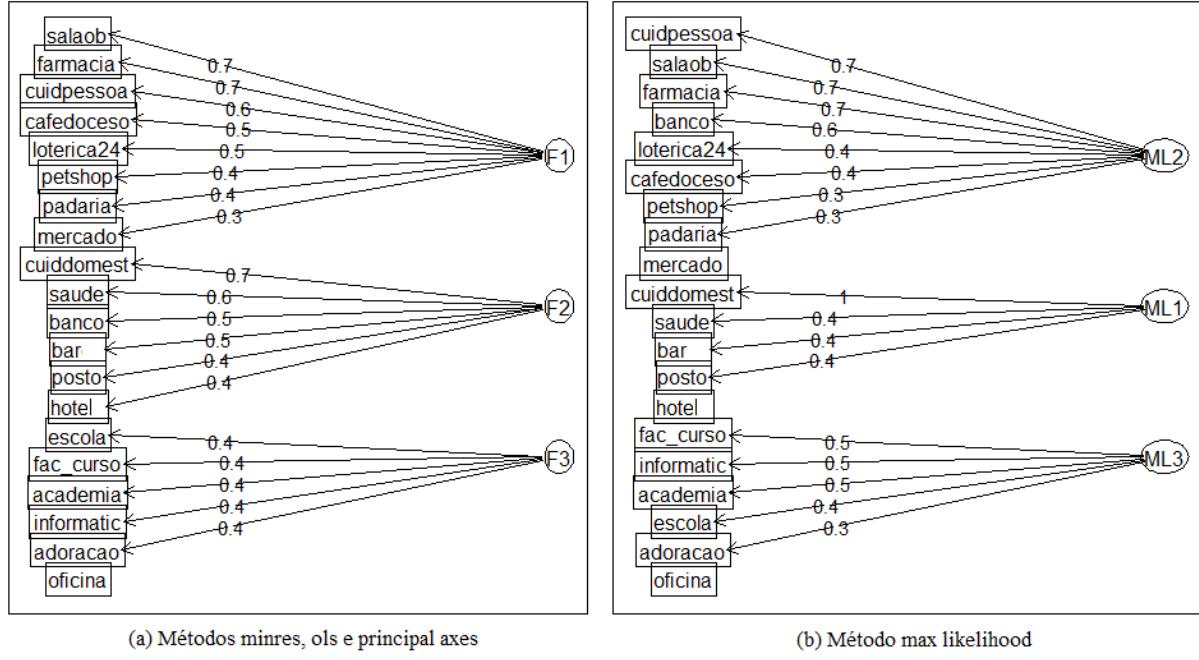
Apesar das sugestões obtidas, optou-se por construir apenas três fatores. Isto se deve às características do ambiente de estudo, bem como ao objetivo de incorporar os fatores a um modelo multicritério. Uma quantidade elevada de critérios favorece um processo de elicitação de preferências longo e com maior propensão a erros e inconsistências na definição de parâmetros, como limiares de preferência e indiferença (DE ALMEIDA, 2013).

A Análise fatorial propriamente dita foi baseada na rotação ortogonal varimax e em quatro métodos de fatoração diferentes: minres, ols, principal axes e max likelihood. As cargas fatoriais e as comunidades (que representam quanto da variância de cada variável é explicado pela Análise fatorial) resultantes estão expostas nos Quadros A.3 e A.4 (Apêndice A). A distribuição das variáveis nos três fatores foi exposta na Figura 25, de modo que as cargas fatoriais maiores do que 0,30 foram representadas por setas.

Os resultados para os métodos minres, ols e principal axes produziram uma mesma estrutura, inclusive com o mesmo valor para as cargas fatoriais, conforme apresentado no Quadro A.3 (Apêndice A). O método max likelihood apresentou uma configuração praticamente igual aos anteriores (apesar das cargas serem distintas), exceto pelo deslocamento da variável ‘bancos’ do segundo para o primeiro fator. Nota-se também que houve um aumento de um para três fatores com carga inferior a 0,30, especificamente ‘mercado’, ‘hotel’ e ‘oficina’.

Como consequência da solidez com que as variáveis explanatórias foram alocadas aos fatores mesmo com métodos diferentes, a estrutura apresentada na Figura 25(a) foi adotada como representante dos critérios relativos aos estabelecimentos comerciais. Ao fator F1 foi atribuído o nome “Qualidade de vida”, pois reflete uma combinação de serviços essenciais ao cotidiano e ao bem-estar das pessoas. O fator F2 recebeu o título de “Poder aquisitivo” porque agrupa atividades tipicamente relacionadas a uma maior movimentação financeira na região de estudo. Isto inclui até mesmo as unidades de saúde, tendo em vista a predominância massiva de clínicas particulares. Por fim, o fator F3 foi denominado “Conhecimento especializado” devido à forte presença de estabelecimentos de educação formal, religiosa ou física. Estes, por sua vez, têm o suporte de lojas de artigos de papelaria e informática. Já o serviço prestado em oficinas requer instruções especializadas.

Figura 25 - Construção dos fatores conforme os métodos de fatoração



Fonte: O autor (2022)

Em seguida construiu-se os valores intracritério destes fatores com base em uma abordagem multicritério espacial pela aplicação do método WLC. Assim, uma soma ponderada dos mapas de densidade espacial Kernel dispostos na Figura 20 foi executada. A definição dos pesos levou em consideração tanto o *range* de valores dos atributos quanto o grau de importância das variáveis.

Como suporte à identificação dos atributos mais importantes dentro de cada fator, recorreu-se aos resultados da exploração estatística-espacial. O processo de

investigação, a seguir, deu-se de forma semelhante ao que foi desenvolvido com os indicadores censitários, porém sem o descarte de preditores.

Um grupo inicial foi formado com os estabelecimentos cuja correlação espacial com os roubos se mostrou significativa em pelo menos três dentre os cinco meses explorados. Assim, foram realçados os seguintes preditores: ‘cuiddomest’, ‘adoração’, ‘banco’, ‘bar’, ‘cuidpessoa’, ‘informatic’ e ‘oficina’.

Construiu-se um segundo grupo com os preditores presentes nos modelos parcimoniosos de pelo menos três dos cinco meses analisados. Logo, as seguintes variáveis explicativas se sobressaíram: ‘academia’, ‘banco’, ‘cafedoceso’, ‘cuidpessoa’, ‘petshop’, ‘saude’ e ‘hotel’. O fator ‘saude’ foi descartado por não ter correlação espacial significativa em nenhum mês.

Por fim, em uma junção desses dois grupos, temos 11 variáveis ressaltadas: ‘academia’, ‘adoração’, ‘banco’, ‘bar’, ‘cafedoceso’, ‘cuidpessoa’, ‘cuiddomest’, ‘hotel’, ‘informatic’, ‘oficina’ e ‘petshop’. Destas, apenas petshops e agências bancárias funcionaram ininterruptamente ao longo da pandemia (até 31 de maio de 2021 neste trabalho). De modo geral, a correlação entre quaisquer pares desses fatores não ultrapassa a faixa moderada (máximo de 0,59), nem mesmo entre estabelecimentos do mesmo segmento de mercado ou com público complementar (como ‘bar’ e ‘cafedoceso’, ‘cuidpessoa’ e ‘cuiddomest’, e ‘hotel’ e ‘bar’).

Essas 11 variáveis receberam um nível de importância maior dentre as 20 inicialmente investigadas. Considerando o contexto local e o *range* de valores dos atributos, estabeleceu-se um valor no intervalo de 0 a 100 a cada variável. Ao final, os pesos foram normalizados utilizando a divisão pela soma, cujo resultado está explicitado no Quadro 13. Estes pesos não possuem relação direta com as cargas fatoriais, embora elas tenham apoiado o analista na elucidação das preferências.

Com a definição dos pesos, aplicou-se o método WLC. A densidade Kernel é um tipo de informação contínua no espaço, enquanto a análise multicritério no presente estudo trabalha com uma quantidade discreta de alternativas na forma de polígonos (especificamente os setores censitários). Neste sentido, foi necessário estabelecer uma medida que representasse a densidade dos estabelecimentos por setor censitário. Optou-se então pela média da densidade, sendo este o atributo usado na soma ponderada dos mapas.

O resultado da agregação das variáveis por fator encontra-se representada em mapas na Figura 26. A distribuição espacial dos fatores é visivelmente distinta, o que

reafirma o entendimento de que eles caracterizam perspectivas diferentes acerca da vulnerabilidade a roubos nesta região. As porções noroeste, sudoeste e extremo sul da região de estudo compartilham os piores desempenhos nos três fatores, enquanto o centro-sul acumula o melhor desempenho simultâneo.

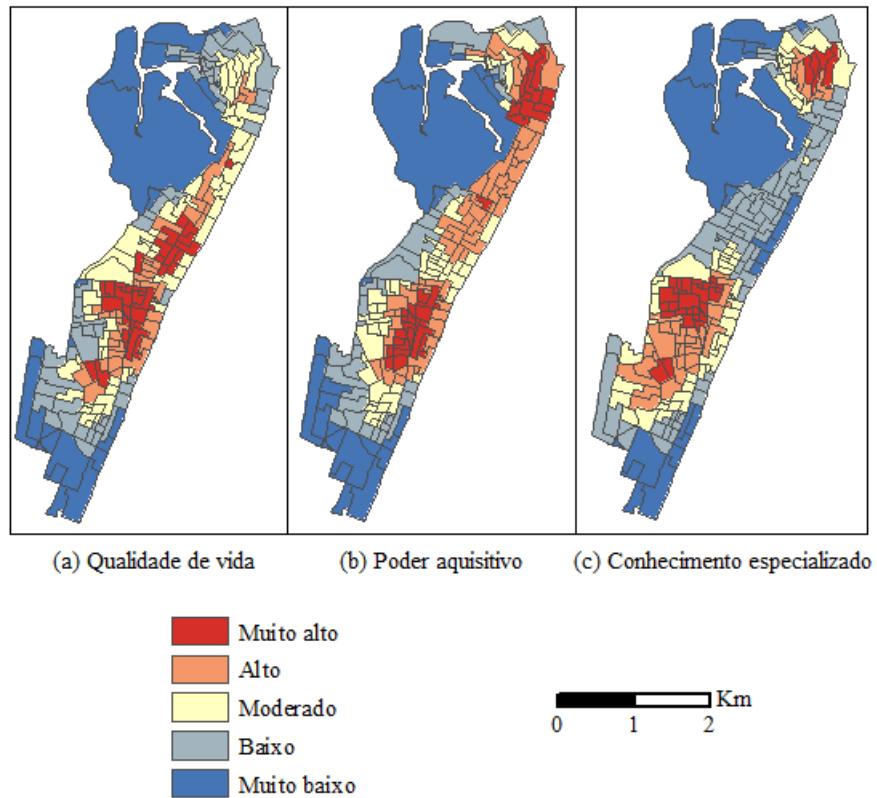
Quadro 13 - Pesos para o método WLC

<b>Variável explicativa</b>	<b>Fator 1</b>	<b>Fator 2</b>	<b>Fator 3</b>
Cafedoceso	0,16		
Cuidpessoa	0,20		
Farmacia	0,10		
Loterica24	0,10		
Mercado	0,10		
Padaria	0,10		
Petshop	0,14		
Salaob	0,10		
Banco		0,220	
Bar		0,198	
Cuiddomest		0,164	
Hotel		0,198	
Posto		0,110	
Saude		0,110	
Academia			0,198
Adoracao			0,198
Escola			0,123
Fac_curso			0,123
Informatic			0,185
Oficina			0,173

Fonte: O autor (2022)

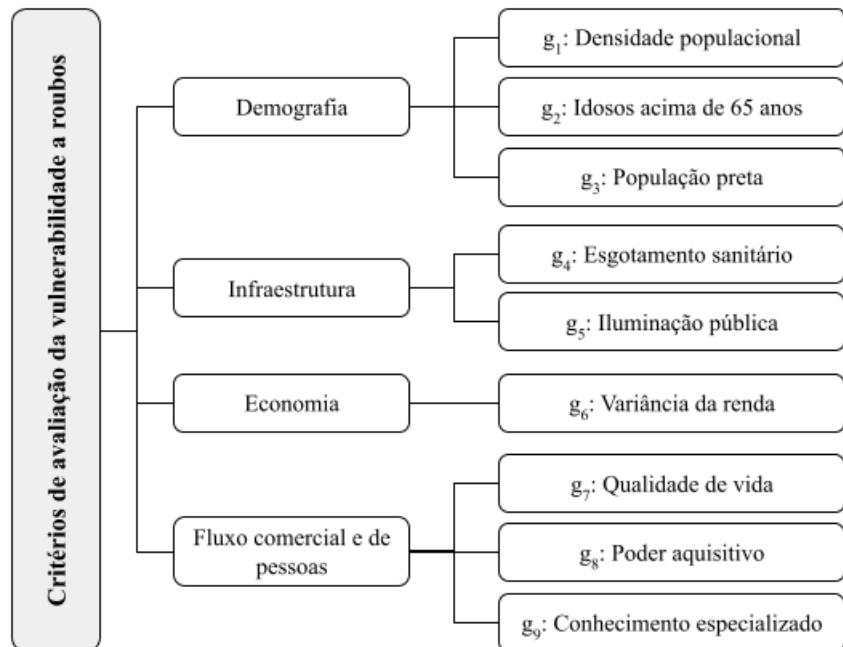
Ao final da etapa de construção de critérios, obteve-se um conjunto com nove, que estão representados na Figura 27. Seis deles referem-se a questões demográficas e socioeconômicas. Estes caracterizam a população residente quanto à renda domiciliar, faixa etária, densidade, cor e provisão de serviços públicos de infraestrutura. Os três critérios restantes apontam como a distribuição espacial dos diferentes tipos de estabelecimentos comerciais fomenta a circulação de transeuntes – os quais provavelmente portam bens materiais de valor agregado razoável (como dinheiro em espécie e eletrônicos) –, despertando a atenção de criminosos.

Figura 26 - Critérios representativos dos estabelecimentos comerciais



Fonte: O autor (2022)

Figura 27 - Resumo dos critérios



Fonte: O autor (2022)

## 7.2.2 Aplicação do modelo multicritério

Em síntese, o conjunto de critérios de avaliação é constituído por seis do tipo ganho (população idosa, acesso a esgotamento sanitário e variância da renda domiciliar e os estabelecimentos comerciais) e três do tipo custo (densidade populacional, provisão de iluminação pública, população preta). Espera-se, então, que eles consigam abranger perspectivas diversas do contexto local em termos de características demográficas, econômicas, espaciais e sociais, assim como estejam fortemente relacionados aos roubos.

Aplicou-se o método multicritério ELECTRE-TRI-nC a fim de classificar os setores censitários em Boa Viagem e Pina quanto à vulnerabilidade a roubos. Os pesos foram obtidos por meio do método Simos revisado, conforme verificado no Quadro 14. Adotou-se uma razão  $Z = 3$  de importância entre os critérios do rank 1 e do rank 6. Por se tratar de uma abordagem não-compensatória, os pesos representam o grau de importância dos critérios.

Quadro 14 - Pesos do modelo multicritério

Critério	Rank	Cartas em branco	Peso não-normalizado
Poder aquisitivo	1		24,2857
		1	
Conhecimento especializado	2		21,4286
Variância da renda	2		21,4286
Pessoas acima de 65 anos	2		21,4286
		1	
Qualidade de vida	3		18,5714
Densidade populacional	3		18,5714
		1	
Iluminação pública	4		15,7143
		2	
População preta	5		11,4286
		1	
Esgotamento sanitário	6		8,5714

Fonte: O autor (2022)

Dentre os critérios que receberam maior peso, destacam-se os que possuem algum tipo de associação com a renda da população. Foi compreendido que, na região de estudo, o interesse dos criminosos para a prática de roubos surge principalmente da percepção de dois elementos: locais com maior potencial de atrair pessoas portando itens de alto valor agregado; e pessoas cujos estereótipos físicos apontem uma idade vista como avançada.

Em seguida, os demais parâmetros do modelo multicritério foram definidos e agregados no Quadro 15. Eles consistem em: pesos  $w_i$ , perfis centrais das categorias  $b_h^r$ , limiares de preferência  $p_i$  e de indiferença  $q_i$ , e sentido de preferência em cada critério  $i$ . As categorias  $C_h$  estão definidas em ordem crescente de vulnerabilidade a roubos: categoria 1 (muito baixa), categoria 2 (baixa); categoria 3 (moderada); categoria 4 (alta); e categoria 5 (muito alta).

A definição dos valores do Quadro 15 fundamentou-se na análise da estatística descritiva dos critérios combinada ao conhecimento do analista. Construíram-se perfis centrais por classe para caracterizar as diferentes nuances da região de estudo. Conforme justificado na seção anterior e sob a perspectiva do criminoso, apenas os critérios “população preta”, “iluminação pública” e “densidade populacional” tiveram direção de preferência de minimização.

Quadro 15 - Parâmetros do ELECTRE-TRI-nC

	$g_1$	$g_2$	$g_3$	$g_4$	$g_5$	$g_6$	$g_7$	$g_8$	$g_9$
$w_i$	0,1150	0,1327	0,0708	0,0531	0,0974	0,1327	0,1150	0,1504	0,1327
$q_i$	350	2	2	30	15	15000	3500	3500	2500
$p_i$	550	4	4	60	30	30000	7000	7000	5000
$b_5^1$	14000	135	3	1400	80	28000000	350000	360000	175000
$b_5^2$	17000	115	6	1200	120	23000000	290000	310000	155000
$b_4^1$	18500	95	10	1000	180	20000000	250000	275000	132000
$b_4^2$	19500	86	14	800	240	16000000	210000	260000	117000
$b_3^1$	21500	75	20	625	280	12500000	180000	230000	100000
$b_3^2$	22500	72	28	550	300	11500000	165000	190000	90000
$b_2^1$	24000	58	38	400	340	8500000	135000	150000	72000
$b_2^2$	27000	50	49	280	380	6500000	110000	115000	66000
$b_1^1$	35000	37	56	170	420	4000000	75000	75000	45000
$b_1^2$	40000	28	90	120	460	2500000	50000	45000	28000
Direção	Min	Max	Min	Max	Min	Max	Max	Max	Max

Fonte: O autor (2022)

O modelo multicritério ELECTRE-TRI-nC foi então executado. Para tanto, realizaram-se testes para definir o nível de credibilidade  $\lambda$ . O modelo demonstrou um comportamento mais estável no intervalo [0,55; 0,65], sendo fixado um nível de 0,6 para a continuação do presente estudo. Os resultados da classificação foram representados na forma de mapa na Figura 28, assim como as respectivas quantidades de alternativas por classe estão no Quadro 16.

Quadro 16 - Frequência de alocações às categorias

Categoria	Frequência	%
$C_1$	20	9,71
$C_{1,2}$	3	1,46
$C_2$	40	19,42
$C_{2,3}$	4	1,94
$C_{2,4}$	2	0,97
$C_3$	70	33,98
$C_{3,4}$	8	3,88
$C_4$	50	24,27
$C_{4,5}$	1	0,49
$C_5$	8	3,88

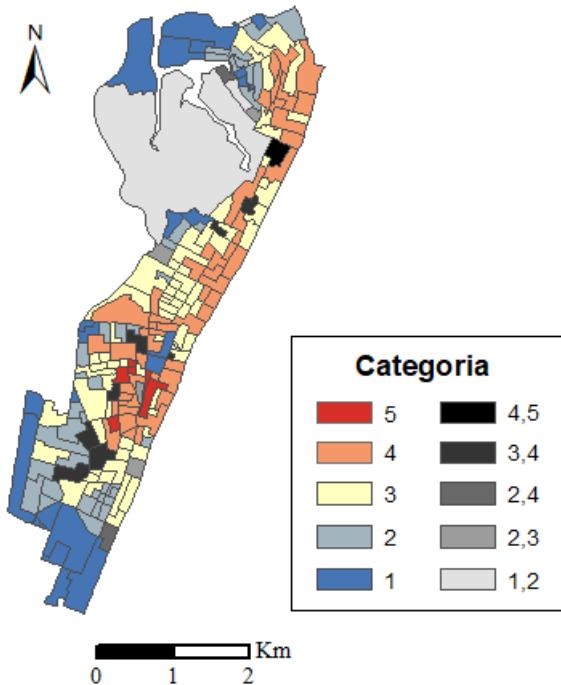
Fonte: O autor (2022)

A maioria dos setores censitários teve uma única classificação para as duas regras de decisão (ascendente e descendente). Dentre as 206 alternativas, apenas 18 delas (ou 8,75% do total) não foram alocadas exclusivamente a uma classe; destas, apenas uma pode ser atribuída a mais de duas classes. Destes 18 setores, 14 se confundem à categoria intermediária “moderada”, o que reforça a capacidade do modelo de discernir as classes extremas (“muito baixa” e “muito alta”). Essa divergência era esperada devido a características do próprio método multicritério, mas a pouca ocorrência dessa situação corrobora com a adequação do modelo.

Apenas oito áreas possuem vulnerabilidade muito alta. Elas estão espacialmente próximas e são circundadas por setores censitários da categoria alta (mais de um quarto das áreas). A vulnerabilidade alta tem uma distribuição mais disseminada, particularmente nas regiões central e nordeste. Além disso, a maioria das alternativas alocáveis às classes alta e muito alta ( $C_{2,4}$ ,  $C_{3,4}$ ,  $C_{4,5}$ ) estão próximas àquelas definidas exclusivamente como alta ou muito alta. Assim, a hesitação do modelo preferencial em alocá-las a uma única classe se mostrou justificável. Como

conclusão, recomenda-se que os locais ressaltados acima (cerca de 30% dos setores) recebam um engajamento prioritário quanto a intervenções de combate e prevenção aos roubos.

Figura 28 - Classificação multicritério da vulnerabilidade a roubos



Fonte: O autor (2022)

As áreas com vulnerabilidade baixa ou muito baixa abrangem boa parte dos locais cujo desempenho dos fatores socioeconômicos é geralmente mais precário na região em termos de renda domiciliar e/ou infraestrutura urbana. Além disso, em relação aos estabelecimentos comerciais, a distribuição espacial desses locais é bastante semelhante aos desempenhos baixo e muito baixo no fator “qualidade de vida” (Figura 26). Assim, ao menos do ponto de vista da ocorrência de roubos, há um indicativo de que estas áreas não requerem um investimento preferencial contra esses crimes. Ao invés disso, sugere-se implementar medidas que proporcionem melhores condições de vida à população local.

### 7.3 Discussão

O estudo aplicou técnicas estatísticas, espaciais e multicritério para avaliar a vulnerabilidade de áreas a roubos durante um período da pandemia de COVID-19. A

princípio, o emprego da correlação de Pearson entre pares de preditores pertencentes a uma mesma vertente explicativa – indicadores censitários e instalações comerciais – possibilitou levantar relações úteis à descrição da região de estudo, ainda sem considerar os dados de roubos propriamente ditos. A correlação entre as instalações comerciais apresentou um nível de associação mais baixo do que houve entre os indicadores censitários, oscilando entre moderado e fraco ou até não significativo.

Algumas correlações contrariaram as expectativas. A densidade populacional surpreendeu por não ter associação significativa com nenhum fator, o que quase ocorreu com a variância da renda. Houve contrasenso na variável de alfabetização por não ter relação significativa com a renda nem com a variância da renda.

Os resultados explicitaram a heterogeneidade socioeconômica da região e como ela está ligada à cor da população residente. A renda domiciliar possui conexão moderada e negativa com pretos, pardos e crianças, ao mesmo tempo em que é moderada e positiva com brancos e idosos. Em relação às variáveis de infraestrutura, os pretos são os únicos com correlação negativa (pavimentação e iluminação pública), enquanto os pardos apresentam correlação positiva e forte com apenas duas variáveis deste segmento, e os brancos positiva e forte com todas elas. A respeito da alfabetização, os brancos e pardos mostram uma relação forte com a variável, mas para os pretos ela é apenas moderada.

Em síntese, a questão histórica do Brasil em que a população preta e parda está infelizmente propensa a residir em locais socialmente vulneráveis pode ser verificada também nos bairros de Boa Viagem e Pina. Tal percepção incrementa a chance de ocorrência de crimes justamente onde essas pessoas vivem, conforme indicado pela Teoria da Desorganização Social. Entretanto, conclusões mais assertivas e fundamentadas dependem da atualização dos dados demográficos e socioeconômicos, visto que os utilizados no presente estudo proveem do censo demográfico 2010.

A aplicação da estatística de correlação espacial serviu para investigar a influência sobre os roubos daqueles indicadores censitários e instalações comerciais localizados em áreas vizinhas. No que concerne às variáveis demográficas, a densidade populacional teve associação negativa com os roubos em quase todos os meses avaliados. Nos picos da primeira (maio de 2020) e da segunda (maio de 2021) ondas da pandemia, as faixas etárias e a cor da população não se mostraram

significativas. Contudo, crianças e idosos se mostraram relevantes em dois dos cinco meses explorados, assim como pretos e pardos.

As variáveis referentes à infraestrutura urbana e à renda obtiveram destaque na correlação espacial em quatro dos cinco meses investigados. Entretanto, embora dezembro de 2020 fosse um momento de ampla retomada dos negócios, as variáveis de renda não foram significativas neste mês. A infraestrutura fez-se significativa principalmente pelo acesso a esgotamento sanitário (fases branda e de aceleração da pandemia); ao contrário do que ocorreu com a pavimentação, que não teve significância estatística ao longo do tempo.

A correlação espacial entre roubos e instalações comerciais demonstrou a insignificância de alguns dispositivos que permaneceram abertos mesmo durante as restrições de circulação mais rígidas (maio de 2020), sendo eles: mercados, padarias, lotéricas e agências de autoatendimento 24 horas, postos de gasolina e unidades de saúde. A última pode ser parcialmente justificada pela ampliação da oferta de teleconsultas. Inclusive, o único estabelecimento significativo no mês de maio de 2020 e que tinha autorização para funcionar foi o setor de petshops. Assim, nem mesmo a potencial aglomeração de pessoas nestes locais atrai o interesse para roubos em regiões vizinhas. Contudo, a ocorrência desses crimes dentro dos setores censitários onde os estabelecimentos estão não pode ser descartada.

As únicas instalações comerciais que tiveram associação negativa com os roubos foram as escolas e os locais de adoração. Apesar disso, ambos possuíam relação positiva com os crimes no pico da primeira onda (maio de 2020). Entende-se, então, que o movimento de reabertura gradual do comércio pode ter impactado nessa relação. Os locais com significância ressaltada durante as diferentes fases da pandemia são: agências bancárias; bares e restaurantes; lojas de cuidados pessoais, de cuidados domésticos e de informática; oficinas automotivas e locais de adoração. Assim, entende-se que o público que frequenta esses ambientes atrai a atenção de criminosos para os setores censitários vizinhos, à espreita de pessoas portando bens de valor agregado razoavelmente elevado. Entretanto, esses resultados devem ser contextualizados ao ambiente, visto que outras características da vizinhança também podem favorecer a prática criminal nesses locais.

O conjunto de 37 preditores de roubos, divididos entre indicadores censitários e instalações comerciais, também foi investigado mediante modelos de regressão em cinco meses importantes da pandemia de COVID-19. Do ponto de vista demográfico,

a densidade populacional esteve presente em todos os cinco modelos parcimoniosos possíveis com associação significativa e negativa com os roubos, mesmo no momento mais rígido das restrições de circulação (maio de 2020). Isto de certa forma corrobora com o que se verificou na análise de correlação espacial e na literatura criminal. Hodgkinson et al. (2022) encontraram uma contribuição positiva desta variável para a predição de furtos em locais onde estes crimes diminuíram durante a pandemia. O tamanho da população também está relacionado à redução de roubos em Chicago (CAMPEDELLI et al., 2021).

A população idosa demonstrou uma relação positiva com os roubos nas fases branda e de aceleração da pandemia, mas no segundo pico (maio de 2021) inverteu-se para negativa. Essa associação positiva também foi percebida por Campedelli et al. (2021), pois perceberam que áreas com um menor percentual de população acima de 65 anos tendiam a apresentar uma maior redução dos índices de roubos pós-*lockdown*. Os autores também notaram que uma maior desigualdade de renda levava a uma menor redução dos roubos. No presente trabalho, este fator foi representado pela variância de renda. De fato, ela fez parte de modelos parcimoniosos na fase de aceleração (relação negativa) e no segundo pico de casos e mortes (relação positiva).

Questões infraestruturais não foram verificadas até então na literatura criminal ligada à pandemia, mas são fatores particularmente relevantes no contexto heterogêneo brasileiro – que também se verifica na região de estudo. Nos modelos de regressão, foi ressaltada a provisão de esgotamento sanitário, com associação sempre positiva aos roubos nos diferentes estágios da pandemia – tanto na fase mais branda quanto nas de aceleração e de pico de casos e mortes.

Estudos publicados até o momento (janeiro de 2022) não tratam do ambiente construído em modelos inferenciais como a regressão linear. Deste modo, o presente trabalho contribui fortemente nesse sentido, especialmente por abranger uma diversidade de instalações comerciais que caracterizam a dinâmica de serviços local. Os modelos parcimoniosos modificaram bastante ao longo dos meses, o que mostra as diferenças no impacto sobre a predição dos roubos conforme o avanço da pandemia. Contudo, os resultados estatísticos não devem ser percebidos como verdade absoluta antes de uma análise a posteriori, senão podem surgir conclusões precipitadas. Isto é essencial principalmente no estágio mais severo do distanciamento social (maio de 2020). Neste mês alguns preditores se mostraram

significativos, mas as instalações permaneceram grande parte do tempo fechadas ao público, como escolas, faculdades e cursos, lanchonetes, academias, oficinas e lojas de cuidados domésticos.

O uso da regressão espacial GWR permitiu os coeficientes variarem conforme as particularidades locais em cada fator. Além disso, obteve-se uma visão espacial das flutuações no desempenho dos modelos estatísticos ao longo da região de estudo e das diferentes fases da pandemia. O patamar muito alto do poder preditivo das regressões baseadas em fatores socioeconômicos oscilou fortemente conforme o estágio pandêmico. No mês com o anti-pico de casos e mortes por COVID-19 (outubro de 2020) esse patamar se manteve ao norte, enquanto nos meses de pico (maio de 2020 e maio de 2021) esteve ao sul; em dezembro de 2020 e fevereiro de 2021 (aceleração nos índices de casos e mortes), se deslocou em direção ao sul.

No que tange ao modelo GWR com estabelecimentos comerciais, o desempenho muito alto se deu no território ao norte na maioria dos meses. A exceção foi em outubro de 2020 (época de menor intensidade da pandemia e reaquecimento do comércio), em que também se posicionou na faixa central da região. Uma curiosa interseção entre os modelos para estabelecimentos e para indicadores censitários ocorreu em maio de 2021, quando o desempenho muito baixo da predição para ambos ocorreu nessa mesma porção central. De um modo geral, a regressão espacial teve melhores resultados nos locais onde houve a formação de *clusters* High-High de roubos.

A adoção da análise fatorial para agregar os estabelecimentos comerciais em poucos fatores significativos facilitou a construção do modelo multicritério, mantendo um bom valor distintivo entre os fatores sob a visão preferencial do analista. Contudo, a opção por produzir apenas três fatores ao invés da sugestão de seis ou sete possivelmente fez com que as cargas fatoriais fossem menores do que o desejado – embora sem prejuízo à posterior modelagem.

Apesar disso, o resultado obtido na análise fatorial é coerente sob a visão do analista, pois permitiu a união em um mesmo fator dos negócios pertencentes a segmentos de mercado próximos, mas que na análise de correlação não haviam demonstrado uma associação intensa. É o caso de: escolas com faculdades e cursos; e mercados com padarias. Outros se mantiveram em um mesmo fator, mas a associação já era moderada (bares e restaurantes com hotéis) ou forte (salões de beleza e lojas de cuidado pessoal). Por outro lado, a correlação fraca entre outros

pares de variáveis levou-as a fatores distintos, como: farmácias e unidades de saúde, bares e lanchonetes, bancos e lotéricas ou banco 24 horas, e oficinas automotivas e postos de gasolina.

A construção de fatores condensando os estabelecimentos comerciais mediante uma técnica de agregação espacial facilitou a análise e compreensão da região de estudo. Em relação ao fator “qualidade de vida”, a distribuição espacial é semelhante à densidade das farmácias, restaurantes e salões de beleza, embora estas variáveis tenham recebido o menor peso. No caso do fator “poder aquisitivo”, o padrão espacial dos bares e hotéis se mostrou mais parecida, tendo ambos recebido o segundo maior peso dentre as variáveis. Por fim, a distribuição do fator “conhecimento especializado” possui comportamento similar ao das escolas e oficinas, embora também não detenham o maior peso.

Estes resultados reafirmam a importância de uma avaliação não baseada apenas no valor absoluto dos fatores (nem nas variáveis de maior impacto), mas em como se dispõem espacialmente. O paralelo traçado com os estabelecimentos comerciais de padrão similar facilita a atuação dos órgãos públicos no sentido de perceberem de modo mais palpável os ambientes que remetem a um maior risco de roubos. Os resultados matemáticos puros podem ser de difícil interpretação para decisões rotineiras de onde atuar.

O modelo multicritério discerniu as partições espaciais da região de estudo em categorias de vulnerabilidade a roubos, fundamentado por critérios representativos do padrão socioeconômico e do fluxo de pessoas e de negócios. Assim, cooperou-se com os gestores de segurança pública numa avaliação ampla, que ultrapassa a típica análise restrita à oscilação da quantidade de crimes por área. Consegue-se compreender como as características locais são atrativas à prática criminal, o que contribui para o direcionamento de intervenções que até mesmo se antecipem às ocorrências. Neste sentido, o modelo revela um pequeno percentual de locais muito vulneráveis a roubos. Isto fornece aos decisores um número mais gerenciável de locais cuja atuação imediata tem o potencial de impactar notavelmente os índices criminais na região de estudo. Em um contexto de escassez crônica de recursos públicos, essa forma de direcionamento estratégico se mostra cabível.

## 8 CONCLUSÃO

Este capítulo expõe as principais conclusões obtidas com o presente estudo, assim como apresenta as limitações e as sugestões para trabalhos futuros.

### 8.1 Considerações finais

O trabalho dedicou-se a avaliar a vulnerabilidade a roubos em uma região da cidade do Recife, levando em consideração os efeitos da pandemia de COVID-19 sobre a dinâmica local. Para isso, uma seção enfatizou apenas a propagação espacial da doença na cidade durante parte da primeira onda de infecções no ano de 2020. Logo, além de ressaltar locais preocupantes em relação à criminalidade, o estudo também consegue subsidiar ações contra o progresso da doença no Recife.

Em relação à COVID-19, uma análise aprofundada feita em escala espacial relativamente pequena permitiu assimilar onde se localizam e o que há em comum entre as áreas com alta concentração de casos notificados e de taxa de letalidade. Conjuntamente, desvendou-se fatores explicativos que ajudam a caracterizar as áreas de risco de transmissão do vírus SARS-CoV2. Os padrões obtidos acerca das características socioeconômicas e do fluxo de pessoas durante a pandemia podem orientar os esforços de prevenção da disseminação da doença na cidade. Logo, revelam-se condições que tornam uma região propensa a um avanço mais forte dos índices de infecção e, infelizmente, de óbitos.

Os achados revelam a influência exercida pela idade, renda e escolaridade da população sobre o comportamento do vírus nos bairros do Recife. Tal fato serve de indicativo para problemas estruturais mais aprofundados, inclusive lidando com a desigualdade social, uma vez que a menor taxa de letalidade devido ao COVID-19 foi encontrada em áreas onde a população é mais rica e com melhores condições de vida. Os modelos estatísticos também podem auxiliar na reformulação do planejamento urbano, proporcionando impactos positivos ampliados sobre outras questões não diretamente relacionadas à doença, como a violência.

A pandemia impactou a ocorrência de roubos nos bairros de Boa Viagem e Pina. No estágio inicial da pandemia houve uma queda acentuada nos índices desses crimes, acelerando uma tendência percebida em anos anteriores. Uma provável explicação é a rigidez nas medidas restritivas nesse período, visto que as

atividades rotineiras das pessoas em espaços públicos foram alteradas, reduzindo as oportunidades para praticar roubos. O gradual relaxamento dessas medidas foi acompanhado pelo paulatino crescimento dos índices de roubos, apresentando tendência de retorno a patamares pré-pandêmicos.

Ocorreu um novo aumento nos casos e óbitos por COVID-19 em Recife no final de 2020, de modo que o pico da segunda onda foi atingido em maio de 2021. Contudo, a movimentação de pessoas em vias públicas e o funcionamento do comércio eram próximos ao normal. A taxa de roubos na região de estudo se manteve crescente, mas os padrões espaciais se modificaram – principalmente nas porções sul e centro-sul. Logo, investigações devem ser realizadas acerca dos fatores que influenciaram essas mudanças, mas que provavelmente não foram considerados no presente estudo.

Do ponto de vista espacial, o dimensionamento dos *clusters* de roubos foi reduzido, de um modo geral, em comparação ao período pré-pandêmico. Entretanto, a evolução dessa concentração espacial em termos das características demográficas e socioeconômicas locais não apresentou um padrão nítido, nem mesmo antes do decreto da pandemia de COVID-19. A migração de *clusters* (High-High ou Low-Low) de áreas mais para menos privilegiadas (e vice-versa) restringiu-se a casos pontuais, independentemente dos recortes temporais. O deslocamento normalmente era para setores espacialmente próximos, porém preservando características similares.

Inclusive, alguns *clusters* incluíam locais de condição socioeconômica totalmente oposta, como visto no nordeste (HH), no centro-norte e no centro-sul (ambos LL) da região de estudo. As distinções mais evidentes entre as áreas HH e LL consistiam na densidade populacional e na faixa etária. Normalmente, as HH detinham baixa densidade e população ligeiramente mais idosa, enquanto as LL incorporavam setores de baixa e de alta densidade contendo população predominantemente mais jovem (crianças e população economicamente ativa).

A propagação espacial da COVID-19 (ao nível da cidade do Recife) não se deu de modo semelhante à evolução da ocorrência de roubos antes e durante a pandemia (ao nível dos bairros de Boa Viagem e Pina). Enquanto as áreas com população com mais crianças e/ou idosos se mostraram mais propensas ao avanço da doença, os índices de roubos normalmente apresentavam apenas uma associação positiva com a população idosa. As variáveis de infraestrutura foram

mais significativas e diversificadas para a predição dos roubos do que para a da COVID-19. Além disso, as padarias, mercados e lotéricas tão reiterados nos modelos preditivos parcimoniosos para os casos da doença não tiveram o mesmo destaque nos modelos de roubos (embora, neste caso, o universo de instalações comerciais fosse maior). Por fim, o deslocamento das áreas mais desenvolvidas para as menos desenvolvidas verificado para a COVID-19 não se mostrou claro para os roubos.

Integrar as abordagens estatística, espacial e multicritério na construção do modelo de apoio a decisão para roubos contribuiu substancialmente para a elucidação das preferências do decisor. As diferentes técnicas empregadas ressaltaram as características locais que fazem esses crimes se concentrarem em partes da região de estudo ao longo do tempo. Ademais, obteve-se a significância de associação dos roubos com os valores dos preditores em áreas vizinhas, e a variação espacial na intensidade e no sinal dessa associação em modelos preditivos multivariados. A representação dos resultados intermediários e finais em mapas também favoreceu ao decisor, pois serviu de ferramenta visual simples para a identificação de padrões. Assim, colaborou-se para reduzir o esforço cognitivo do decisor na definição de parâmetros para a modelagem multicritério, respeitando as particularidades locais.

O panorama da vulnerabilidade de áreas a roubos produzido pelo modelo multicritério se mostrou coerente com os resultados de *clusters* de roubos ao longo da pandemia. Os locais com concentração do tipo High-High no nordeste da região apresentaram vulnerabilidade alta, assim como o inverso (níveis baixos) ocorreu com os Low-Low localizados no sul.

Os padrões supracitados de *clusters* espaciais foram os mais comuns antes e em parte significativa da pandemia, então conseguir replicá-los em um modelo multivariado reafirma a singularidade deles e demonstra a veracidade do próprio modelo. Uma das poucas situações não captadas foi o surgimento de áreas High-High no sul, que foram identificadas apenas ao final do período de análise. Logo, há evidências de que esse padrão é atípico na região, de modo que a influência de fatores externos precisa ser explorada.

O impacto econômico do presente trabalho reside na contribuição estratégica para priorizar investimentos em áreas que são tipicamente suscetíveis à propagação da doença e/ou à ocorrência de roubos. Deste modo, as atuais políticas de

segurança pública podem ser reestruturadas a fim de destinar os historicamente escassos recursos públicos a locais críticos. Contribui-se para racionalizar gastos com alicerce em dados além das taxas criminais.

Do ponto de vista social, o trabalho serve para esclarecer os locais que demandam atenção do Estado em medidas mitigadoras à disseminação da doença e em preventivas/combativas ao avanço da criminalidade. Melhorias decorrentes disso – como benfeitorias na infraestrutura urbana (esgotamento sanitário, iluminação pública), nos serviços educacionais e de saúde – beneficiam a qualidade de vida da população local (quiçá de áreas vizinhas). A informação também é útil à sociedade em geral para embasar cobranças de ações urgentes do poder público.

A contribuição em termos financeiros deste trabalho está na indicação dos locais que são mais vulneráveis à roubos, pois são ambientes que devem ser analisados com cautela antes do desenvolvimento e expansão de negócios empresariais. Por outro lado, a identificação das características locais mais associadas à propagação da COVID-19 auxilia na imposição de medidas restritivas de circulação em estágios de alta circulação do vírus, o que, por consequência, afeta o desempenho das atividades comerciais.

## 8.2 Limitações e Estudos futuros

Os dados sociodemográficos extraídos do censo demográfico 2010 estão defasados. Contudo, optou-se por utilizá-los por esta ser a principal fonte oficial brasileira, cujos dados são públicos, acurados e fruto de uma metodologia ratificada pelo meio acadêmico. A extração dos estabelecimentos comerciais no Google Earth e no Google Maps também é limitada, pois não há a garantia de que todos os existentes na área de estudo estão registrados na plataforma. Além disso, o ideal seria desenvolver modelos com dados atualizados dessas variáveis explicativas em momentos anteriores e posteriores ao início da pandemia. Assim, distinguir-se-iam problemas crônicos da sociedade daqueles decorrentes do período de excepcionalidade.

O aspecto da mobilidade dos potenciais alvos de roubos na região de estudo é bastante relevante, em especial quando se verifica elevado fluxo comercial. Assim, sugere-se considerar elementos espaciais indicativos do acesso a transporte público (paradas de ônibus, estações de metrô) e privado (pontos de táxi, zonas de

estacionamento). Adicionalmente, mensurar a população ambiental permite refletir sobre a flutuação acumulada dos alvos em diferentes períodos do dia e da semana, sendo uma métrica mais exata do que apenas os residentes.

Os dados de casos e óbitos por COVID-19 usados servem de indicativo da realidade brasileira, porém apresentam uma acentuada subnotificação devido à capacidade limitada de realizar testes. Ademais, os dados georreferenciados estão disponíveis apenas para um curto período (abril a julho de 2020) e ao nível de bairros. Assim, estudos futuros devem incluir casos e óbitos atualizados na forma de pontos a fim de possibilitar a redução da escala espacial das análises – por exemplo, segmentos de rua. Além disso, é necessário investigar se os padrões espaciais verificados na primeira onda de infecções em 2020 sofreram alterações adiante.

Por imprecisão nos dados, não se utilizou informações sobre o estado de saúde prévio das pessoas infectadas (principalmente comorbidades), o que é um fator essencial na propensão a casos graves de COVID-19. Estudos futuros também devem considerar o ritmo da campanha de vacinação para a evolução dos *clusters* e determinantes significativos, visto que no período explorado em 2020 as vacinas ainda não estavam disponíveis. Adicionalmente, sugere-se considerar as variações no nível de aderência às medidas de restrição nos modelos.

A demanda dos estabelecimentos comerciais foi assumida como estática ao longo do tempo nos modelos. Contudo, ela naturalmente varia conforme os dias da semana, períodos do dia e épocas de festividades. Estas mudanças alteram a quantidade de pessoas nas ruas, impactando na atratividade à prática criminal.

Em relação aos modelos criminais, pode-se investigar outras divisões espaciais menores cujas dimensões sejam mais padronizadas do que os setores censitários, tais como *grids*. A exploração dos crimes ocorreu com base apenas na agregação por polígonos. Logo, recomenda-se investigar padrões dos pontos georreferenciados em si, como o raio de influência dos roubos, a localização deles ao longo do tempo e a formação de *clusters* (ao nível de ponto).

Considerou-se as áreas verdes inhabitadas durante a modelagem. Todavia, isto gera uma distorção em parte dos dados socioeconômicos, principalmente no cálculo da densidade populacional e na avaliação por quintis da área. No modelo multicritério, inclusive, estes locais podem afetar a classificação: espera-se que áreas habitadas sejam mais propensas a roubos do que aquelas com cobertura vegetal densa (por exemplo, o Parque dos Manguezais).

Indica-se estender as análises de *clusters* e de regressão dos dados criminais para outros recortes temporais. Dentre esses estão: os horários comercial e não-comercial, os períodos no ano de maior movimento no comércio (Natal, Dia da Mães), as diferentes fases da pandemia (subida, pico, queda, vale). Em relação às regressões, o período pré-pandemia pode ser investigado para traçar comparações.

Apenas os roubos e a sua perspectiva espaço-temporal foram explorados. Recomenda-se expandir para uma análise comparativa com os crimes violentos intencionais (como homicídios) para confrontar os padrões na região de estudo durante a pandemia (considerando as medidas restritivas vigentes). Ademais, sugere-se explorar cada crime em relação ao criminoso e à vítima, incluindo idade, ocupação, antecedentes criminais e escolaridade.

A incidência da COVID-19 poderia ter sido incluída como preditor nos modelos estatísticos criminais, visando associar diretamente os índices criminais com a propagação da doença. Contudo, não havia dados disponíveis ao nível de setor censitário. Vale salientar que em Campedelli et al. (2021) a variável “casos de COVID-19” não se mostrou significativa.

O estudo apresenta uma abordagem multicritério em que o próprio analista assumiu o papel do decisor. Isto é, conduziu-se uma simulação baseada na exploração de dados. Embora os resultados sejam pertinentes e consigam refletir o panorama local, o modelo seria enriquecido com as preferências de um decisor pertencente a setores estratégicos da segurança pública em Pernambuco. Assim, o problema poderia ser tratado com maior profundidade em termos de conhecimento da região e da dinâmica do combate aos roubos. Também se sugere uma decisão em grupo devido ao caráter abrangente da questão da segurança, envolvendo secretarias de governo (como finanças e educação) e representantes populares.

## REFERÊNCIAS

- ABRAMS, D. S. COVID and crime: An early empirical look. **Journal of public economics**, v. 194, p. 104344, 2021.
- ADEYEMI, R. A.; MAYAKI, J.; ZEWOTIR, T. T.; RAMROOP, S. Demography and Crime: A Spatial analysis of geographical patterns and risk factors of Crimes in Nigeria. **Spatial Statistics**, v. 41, p. 100485, 2021.
- ADHIKARI, S. P.; MENG, S.; WU, Y.J.; MAO, Y.P.; YE, R.X.; WANG, Q.Z.; SUN, C.; SYLVIA, S.; ROZELLE, S.; RAAT, H.; ZHOU, H. Epidemiology, causes, clinical manifestation and diagnosis, prevention and control of coronavirus disease (COVID-19) during the early outbreak period: a scoping review. **Infectious diseases of poverty**, v. 9, n. 1, p. 1-12, 2020.
- AGARWAL, P.; HUNT, K.; ZHUANG, J.; SARKAR, B.; SARKAR, A.; SHARMA, R. An exploratory analysis for performance assessment of state police forces in India: an eclectic approach. **Operational Research**, v. 21, n. 2, p. 1125-1151, 2021.
- AL KINDI, K. M.; AL-MAWALI, A.; AKHARUSI, A.; ALSHUKAILI, D.; ALNASIRI, N.; AL-AWADHI, T.; CHARABI, Y.; EL KENAWY, A.M. Demographic and socioeconomic determinants of COVID-19 across Oman-A geospatial modelling approach. **Geospatial Health**, v. 16, n. 1, 2021.
- ALDSTADT, J. Spatial Clustering. In: FISCHER, M. M.; GETIS, A. (Eds.). **Handbook of Applied Spatial Analysis**. Berlin/Heidelberg: Springer Science & Business Media, 2010. p. 279-300.
- ALI, T.; MORTULA, M.; SADIQ, R. GIS-based vulnerability analysis of the United States to COVID-19 occurrence. **Journal of Risk Research**, v. 24, n. 3-4, p. 416-431, 2021.
- ALLMENDINGER, R.; EHRGOTT, M.; GANDIBLEUX, X.; GEIGER, M. J.; KLAMROTH, K.; LUQUE, M. Navigation in multiobjective optimization methods. **Journal of Multi-Criteria Decision Analysis**, v. 24, n. 1-2, p. 57-70, 2017.
- ALMEIDA, E. **Econometria Espacial Aplicada**. Campinas: Alínea, 2012.
- ALMEIDA-DIAS, J.; FIGUEIRA, J. R.; ROY, B. Electre Tri-C: A multiple criteria sorting method based on characteristic reference actions. **European Journal of Operational Research**, v. 204, n. 3, p. 565–580, 2010.
- ALMEIDA-DIAS, J.; FIGUEIRA, J. R.; ROY, B. A multiple criteria sorting method where each category is characterized by several reference actions: The Electre Tri-nC method. **European Journal of Operational Research**, v. 217, n. 3, p. 567–579, 2012.
- ALSHOGRAN, O. Y.; ALTAWALBEH, S. M.; AL-AZZAM, S. I.; KARASNEH, R. Predictors of Covid-19 case fatality rate: An ecological study. **Annals of Medicine and Surgery**, v. 65, p. 102319, 2021.

ALVAREZ, P. A.; ISHIZAKA, A.; MARTÍNEZ, L. Multiple-criteria decision-making sorting methods: A survey. **Expert Systems with Applications**, v. 183, p. 115368, 2021.

ALVES, M. C.; ARIAS, E. D. Understanding the Fica Vivo programme: two-tiered community policing in Belo Horizonte, Brazil. **Policing and Society**, v. 22, n. 1, p. 101-113, 2012.

ALVES, P. Pernambuco libera aulas presenciais para crianças e adolescentes em escolas privadas. **Portal G1**, 2020. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2020/10/29/pernambuco-libera-aulas-presenciais-para-criancas-e-adolescentes-em-escolas-privadas.ghtml>>. Acesso em: 10 out. 2021.

AMDAOUD, M.; ARCURI, G.; LEVRATTO, N. Are regions equal in adversity? A spatial analysis of spread and dynamics of COVID-19 in Europe. **The European Journal of Health Economics**, v. 22, p. 1-14, 2021.

ANDERSEN, L. M.; HARDEN, S. R.; SUGG, M. M.; RUNKLE, J. D.; LUNDQUIST, T. E. Analyzing the spatial determinants of local Covid-19 transmission in the United States. **Science of the Total Environment**, v. 754, p. 142396, 2021.

ANDRESEN, M. A. **Environmental criminology**: Evolution, theory, and practice. New York: Routledge, 2014.

ANDRESEN, M. A.; CURMAN, A. S.; LINNING, S. J. The trajectories of crime at places: Understanding the patterns of disaggregated crime types. **Journal of quantitative criminology**, v. 33, n. 3, p. 427-449, 2016.

ANDRESEN, M. A.; HODGKINSON, T. Predicting property crime risk: An application of risk terrain modeling in Vancouver, Canada. **European Journal on Criminal Policy and Research**, v. 24, n. 4, p. 373-392, 2018.

ANDRESEN, M. A.; HODGKINSON, T. Somehow I always end up alone: COVID-19, social isolation and crime in Queensland, Australia. **Crime science**, v. 9, n. 1, p. 1-20, 2020.

ANDRESEN, M. A.; LINNING, S. J.; MALLESON, N. Crime at places and spatial concentrations: Exploring the spatial stability of property crime in Vancouver BC, 2003–2013. **Journal of Quantitative Criminology**, v. 33, n. 2, p. 255-275, 2017.

ANSELIN, L. Local indicators of spatial association—LISA. **Geographical analysis**, v. 27, n. 2, p. 93-115, 1995.

ANSELIN, L. **Exploring Spatial Data with GeoDa**: A Workbook. Urbana, IL, USA: Spatial Analysis Laboratory, 2005.

APRÍGIO, M. Com Carnaval 2021 cancelado, Procon Pernambuco encerra festa clandestina, interdita e notifica bares e restaurantes. **Portal NE10**, 2021. Disponível em: <<https://jc.ne10.uol.com.br/pernambuco/2021/02/12030188-com-carnaval-2021->>.

cancelado--procon-pernambuco-encerra-festa-clandestina--interdita-e-notifica-bares-e-restaurantes.html>. Acesso em: 10 out. 2021.

ARAL, N.; BAKIR, H. Spatiotemporal Analysis of Covid-19 in Turkey. **Sustainable Cities and Society**, v. 76, p. 103421, 2022.

ASP – ANUÁRIO DE SEGURANÇA PÚBLICA. 2021. **15º Anuário de Segurança Pública**. Disponível em: <<https://forumseguranca.org.br/anuario-brasileiro-segurança-publica/>>. Acesso em: 20 jan. 2022.

BACHMAN, R.; DILLAWAY, H.; LACHS, M. S. Violence against the elderly: A comparative analysis of robbery and assault across age and gender groups. **Research on aging**, v. 20, n. 2, p. 183-198, 1998.

BALMORI DE LA MIYAR, J. R.; HOEHN-VELASCO, L.; SILVERIO-MURILLO, A. The U-shaped crime recovery during COVID-19: evidence from national crime rates in Mexico. **Crime science**, v. 10, n. 1, p. 1-23, 2021.

BAMBRA, C.; RIORDAN, R.; FORD, J.; MATTHEWS, F. The COVID-19 pandemic and health inequalities. **Journal of Epidemiology & Community Health**, v. 74, n. 11, p. 964-968, 2020.

BARTSCH, S. M.; O'SHEA, K. J.; WEDLOCK, P. T.; STRYCH, U.; FERGUSON, M. C.; BOTTAZZI, M. E.; RANDALL, S. L.; SIEGMUND, S. S.; COX, S. N.; HOTEZ, P. J.; LEE, B.Y. The Benefits of Vaccinating With the First Available COVID-19 Coronavirus Vaccine. **American journal of preventive medicine**, v. 60, n. 5, p. 605-613, 2021.

BASILIO, M. P.; PEREIRA, V. Operational research applied in the field of public security. **Journal of Modelling in Management**, v. 15, n. 3, p. 1227-1276, 2020.

BASILIO, M. P.; PEREIRA, V.; COSTA, H. G. Classifying the integrated public safety areas (IPSAs): a multi-criteria based approach. **Journal of Modelling in Management**, v. 14, n. 1, p. 106-133, 2019.

BATELLA, W. B.; DINIZ, A. M. A. Spatial analysis of violent crime determinants in Minas Gerais State. **Sociedade & Natureza**, v. 22, n. 1, p. 151-163, 2010.

BATTY, M. Agents, cells, and cities: new representational models for simulating multiscale urban dynamics. **Environment and Planning A**, v. 37, n. 8, p. 1373-1394, 2005.

BECKER, G. S. Crime and punishment: An economic approach. **Journal of Political Economy**, v. 76, p. 169–217, 1968.

BELTON, V.; STEWART, T. **Multiple Criteria Decision Analysis**. Boston: Kluwer Academic Publishers, 2002.

BERMUDI, P. M. M.; LORENZ, C.; DE AGUIAR, B. S.; FAILLA, M. A.; BARROZO, L. V.; CHIARAVALLOTTI-NETO, F. Spatiotemporal ecological study of COVID-19

mortality in the city of São Paulo, Brazil: shifting of the high mortality risk from areas with the best to those with the worst socio-economic conditions. **Travel medicine and infectious disease**, v. 39, p. 101945, 2021.

BERNASCO, W.; BLOCK, R. Robberies in Chicago: A block-level analysis of the influence of crime generators, crime attractors, and offender anchor points. **Journal of Research in Crime and Delinquency**, v. 48, n. 1, p. 33-57, 2011.

BILAL; BASHIR, M. F.; SHAHZAD, K.; KOMAL, B.; BASHIR, M. A.; BASHIR, M.; TAN, D.; FATIMA, T.; NUMAN, U. Environmental quality, climate indicators, and COVID-19 pandemic: insights from top 10 most affected states of the USA. **Environmental Science and Pollution Research**, v. 28, p. 32856-32865, 2021.

BOOTS, B.; OKABE, A. Local statistical spatial analysis: Inventory and prospect. **International Journal of Geographical Information Science**, v. 21, n. 4, p. 355-375, 2007.

BORCHERDING, K.; EPPEL, T.; VON WINTERFELDT, D. Comparison of weighting judgments in multiattribute utility measurement. **Management Science**, v. 37, n. 12, p. 1603-1619, 1991.

BOUYSSOU, D.; MARCHANT, T.; PIRLOT, M.; TSOUKIAS, A.; VINCKE, P. **Evaluation and decision models with multiple criteria**: Stepping stones for the analyst. New York: Springer Science & Business Media, 2006.

BRANTINGHAM, P. J.; BRANTINGHAM, P. L. Introduction: The dimensions of crime. In: BRANTINGHAM, P. L.; BRANTINGHAM, P. J. (Eds.). **Environmental criminology**. Prospect Heights: Waveland Press, 1981a. p. 7-26.

BRANTINGHAM, P. J.; BRANTINGHAM, P. L. Notes on the geometry of crime. In: \_\_\_\_\_. **Environmental criminology**. Prospect Heights: Waveland Press, 1981b. p. 27-54.

BRANTINGHAM, P. L.; BRANTINGHAM, P. J. Environment, routine and situation: Toward a pattern theory of crime. In: CLARKE, R. V.; FELSON, M. (Eds.). **Routine activity and rational choice**. New Brunswick: Transaction Publishers, 1993. p. 259-294.

BRANTINGHAM, P. L.; BRANTINGHAM, P. J. The criminality of place: Crime generators and crime attractors. **European Journal on Criminal Policy and Research**, v. 3, n. 3, p. 5-26, 1995.

BRASIL. Constituição (1988). **Constituição da República Federativa do Brasil**. Brasília, DF: Senado Federal, 1988.

BRUNSDON, C.; FOTHERINGHAM, A. S.; CHARLTON, M. E. Geographically weighted regression: a method for exploring spatial nonstationarity. **Geographical analysis**, v. 28, n. 4, p. 281-298, 1996.

- BUCKINGHAM-JEFFERY, E.; MORBEY, R.; HOUSE, T.; ELLIOT, A. J.; HARCOURT, S.; SMITH, G. E. Correcting for day of the week and public holiday effects: improving a national daily syndromic surveillance service for detecting public health threats. **BMC Public Health**, v. 17, n. 1, p. 1-9, 2017.
- BUNTING, R. J.; CHANG, O. Y.; COWEN, C.; HANKINS, R.; LANGSTON, S.; WARNER, A.; YANG, X.; LOUDERBACK, E. R.; ROY, S. S. Spatial patterns of larceny and aggravated assault in Miami–Dade County, 2007–2015. **The Professional Geographer**, v. 70, n. 1, p. 34-46, 2018.
- CALLEGARI-JACQUES, S. M. **Bioestatística: princípios e aplicações**. Porto Alegre: Aramed, 2007.
- CAMPEDELLI, G. M.; FAVARIN, S.; AZIANI, A.; PIQUERO, A. R. Disentangling community-level changes in crime trends during the COVID-19 pandemic in Chicago. **Crime Science**, v. 9, n. 1, p. 1-18, 2020.
- CANO, I.; RIBEIRO, E. Old strategies and new approaches towards policing drug markets in Rio de Janeiro. **Police Practice and Research**, v. 17, n. 4, p. 364-375, 2016.
- CARTER, J.; LOUDERBACK, E. R.; VILDOSOLA, D.; ROY, S. S. Crime in an Affluent City: Spatial Patterns of Property Crime in Coral Gables, Florida. **European Journal on Criminal Policy and Research**, v. 26, n. 4, p. 547-570, 2020.
- CASTRO, M. C.; KIM, S.; BARBERIA, L.; RIBEIRO, A. F.; GURZENDA, S.; RIBEIRO, K. B.; ABBOTT, E.; BLOSSOM, J.; RACHE, B.; SINGER, B. H. Spatiotemporal pattern of COVID-19 spread in Brazil. **Science**, v. 372, n. 6544, p. 821-826, 2021.
- CECCATO, V.; KAHN, T.; HERRMANN, C.; ÖSTLUND, A. Pandemic Restrictions and Spatiotemporal Crime Patterns in New York, São Paulo, and Stockholm. **Journal of Contemporary Criminal Justice**, p. 10439862211038471, 2021.
- CECCATO, V.; MOREIRA, G. The Dynamics of Thefts and Robberies in São Paulo's Metro, Brazil. **European Journal on Criminal Policy and Research**, v. 27, n. 3, p. 353-373, 2021.
- CHATTERJEE, S.; HADI, A. S. **Regression Analysis by Example**. Hoboken: John Wiley & Sons, 2013.
- CHEN, J.; LIU, L.; XIAO, L.; XU, C.; LONG, D. Integrative Analysis of Spatial Heterogeneity and Overdispersion of Crime with a Geographically Weighted Negative Binomial Model. **ISPRS International Journal of Geo-Information**, v. 9, n. 1, p. 60, 2020.
- COHEN, L. E.; FELSON, M. Social change and crime rate trends: A routine activity approach. **American sociological review**, v. 44, n. 4, p. 588-608, 1979.

CONNEALY, N. T.; PIZA, E. L. Risk factor and high-risk place variations across different robbery targets in Denver, Colorado. **Journal of criminal justice**, v. 60, p. 47-56, 2019.

COWEN, C.; LOUDERBACK, E. R.; ROY, S. S. The role of land use and walkability in predicting crime patterns: A spatiotemporal analysis of Miami-Dade County neighborhoods, 2007–2015. **Security Journal**, v. 32, n. 3, p. 264-286, 2019.

CRUZ, W. L. M. Crescimento do e-commerce no Brasil: desenvolvimento, serviços logísticos e o impulso da pandemia de Covid-19. **GeoTextos**, v. 17, n. 1, 2021.

CUTRINI, E.; SALVATI, L. Unraveling spatial patterns of COVID-19 in Italy: Global forces and local economic drivers. **Regional Science Policy & Practice**, p. 1-36, 2021.

DA SILVA, C. F. A.; MEIRA, L. H.; DE OLIVEIRA, L. K.; DOS SANTOS, P. R. G.; DE OLIVEIRA, I. K. Analysis of spatial correlation between public transportation system users and covid-19 cases: A case study in Recife (PE). **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 16, n. 4, p. 346-359, 2020.

DALE, M. R. T.; FORTIN, M. J. **Spatial analysis**: A Guide for Ecologists. Cambridge: Cambridge University Press, 2014.

DAVIES, M. W.; FARRINGTON, D. P. An examination of the effects on crime of switching off street lighting. **Criminology & Criminal Justice**, v. 20, n. 3, p. 339-357, 2020.

DE ALMEIDA, A. T. **Processo de Decisão Nas Organizações**: Construindo Modelos de Decisão Multicritério. São Paulo: Atlas, 2013.

DE ALMEIDA, A. T.; CAVALCANTE, C. A. V.; ALENCAR, M. H.; FERREIRA, R. J. P.; DE ALMEIDA-FILHO, A. T.; GARCEZ, T. V. **Multicriteria and multiobjective models for risk, reliability and maintenance decision analysis**. Springer International Publishing, 2015.

DE ALMEIDA, A. T.; DE ALMEIDA, J. A.; COSTA, A. P. C. S.; DE ALMEIDA-FILHO, A. T. A new method for elicitation of criteria weights in additive models: Flexible and interactive tradeoff. **European Journal of Operational Research**, v. 250, n. 1, p. 179-191, 2016.

DE ALMEIDA, A. T.; FREJ, E. A.; MORAIS, D. C.; COSTA, A. P. C. Multiple Criteria Group Decisions with Partial Information About Preference. In: KILGOUR, D.M.; EDEN, C. (Eds.). **Handbook of Group Decision and Negotiation**. Springer, Cham, 2020.

DE LIMA, J.; MAIA, M. L.; LUCAS, K. Income vs. travel time: Why do the poorest and the richest travel fastest in northeastern Brazil?. **Transportation research procedia**, v. 25, p. 4285-4295, 2017.

DE SOUZA, C. D. F.; MACHADO, M. F.; DO CARMO, R. F. Human development, social vulnerability and COVID-19 in Brazil: a study of the social determinants of health. **Infectious Diseases of Poverty**, v. 9, n. 1, p. 1-10, 2020.

DIARIOPE. Dia das mães terá lojas abertas por mais tempo. **Diário de Pernambuco**, 2021. Disponível em: <<https://www.diariodepernambuco.com.br/noticia/economia/2021/05/dia-das-maes-tera-lojas-abertas-por-mais-tempo.html>>. Acesso em: 10 out. 2021.

DRUCK, S.; CARVALHO, M S.; CÂMARA, G.; MONTEIRO, A. M. V. **Análise Espacial de Dados Geográficos**. Brasília: EMBRAPA, 2004.

EJIOGU, K. U. Block-level analysis of the attractors of robbery in a downtown area. **Sage Open**, v. 10, n. 4, p. 2158244020963671, 2020.

ENGELEN, P. J.; LANDER, M. W.; VAN ESSEN, M. What determines crime rates? An empirical test of integrated economic and sociological theories of criminal behavior. **The Social Science Journal**, v. 53, n. 2, p. 247-262, 2016.

ESPOSITO, M. M.; KING, A. New York City: COVID-19 quarantine and crime. **Journal of Criminal Psychology**, 2021.

ESTÉVEZ-SOTO, P. R. Crime and COVID-19: Effect of changes in routine activities in Mexico City. **Crime Science**, v. 10, n. 1, p. 1-17, 2021.

FARRINGTON, D. P.; WELSH, B. C. Improved street lighting and crime prevention. **Justice Quarterly**, v. 19, n. 2, p. 313-342, 2002.

FATIMA, M.; O'KEEFE, K. J.; WEI, W.; ARSHAD, S.; GRUEBNER, O. Geospatial Analysis of COVID-19: A Scoping Review. **International Journal of Environmental Research and Public Health**, v. 18, n. 5, p. 2336, 2021.

FELSON, M.; JIANG, S.; XU, Y. Routine activity effects of the Covid-19 pandemic on burglary in Detroit, March, 2020. **Crime Science**, v. 9, n. 1, p. 1-7, 2020.

FENG, S. Q.; PIZA, E. L.; KENNEDY, L. W.; CAPLAN, J. M. Aggravating effects of alcohol outlet types on street robbery and aggravated assault in New York City. **Journal of crime and justice**, v. 42, n. 3, p. 257-273, 2019.

FERREIRA, M. C. Spatial association between the incidence rate of Covid-19 and poverty in the São Paulo municipality, Brazil. **Geospatial Health**, v. 15, n. 2, 2020.

FIGUEIRA, J.; ROY, B. Determining the weights of criteria in the ELECTRE type methods with a revised Simos' procedure. **European Journal of Operational Research**, v. 139, n. 2, p. 317-326, 2002.

FIGUEIREDO, C. J. J.; MOTA, C. M. M. Learning Preferences in a Spatial Multiple Criteria Decision Approach: An Application in Public Security Planning. **International Journal of Information Technology & Decision Making**, v. 18, n. 04, p. 1403-1432, 2019.

FIGUEIREDO, C. J. J.; MOTA, C. M. M. A classification model to evaluate the security level in a city based on GIS-MCDA. **Mathematical Problems in Engineering**, v. 2016, 2016.

FIGUEIREDO, C. J. J.; MOTA, C. M. M.; ROSA, A. G. F.; SOUZA, A. P. G.; LIMA, S. M. S. Vulnerability to COVID-19 in Pernambuco, Brazil: A geospatial evaluation supported by multiple-criteria decision aid methodology. **Geospatial Health**, v. 17, n. s1, p. 1000, 2022.

FIPEZAP. 2021. **FIPEZAP - Índice de preços de imóveis anunciados**. Disponível em: <<https://www.fipe.org.br/pt-br/publicacoes/relatorios/#relatorio-fipezap>>. Acesso em: 24 out. 2021.

FISCHER, M. M.; WANG, J. **Spatial data analysis**: models, methods and techniques. Berlin/Heidelberg: Springer Science & Business Media, 2011.

FLORINDO, A. A.; TURRELL, G.; GARCIA, L. M. T.; BARBOSA, J. P. A. S.; CRUZ, M. S.; FAILLA, M. A.; AGUIAR, B. S.; BARROZO, L. V.; GOLDBAUM, M. Mix of destinations and sedentary behavior among Brazilian adults: a cross-sectional study. **BMC Public Health**, v. 21, n. 1, p. 1-7, 2021.

FOLHAPE. PE proíbe bares, restaurantes e ambulantes no Bairro do Recife e Sítio Histórico de Olinda no fim de semana de carnaval. **Folha de Pernambuco**, 2021. Disponível em: <<https://www.folhape.com.br/noticias/recife-suspende-ponto-facultativo-durante-o-carnaval/172023/>>. Acesso em: 10 out. 2021.

FOTHERINGHAM, A. S. Geographically Weighted Regression. In: FOTHERINGHAM, A. S.; ROGERSON, P. A. **The SAGE handbook of spatial analysis**. SAGE Publications Ltd, 2009. p. 243-253.

G1PE. Com mais 2.511 infectados, PE tem maior média móvel de casos da Covid-19 desde início da pandemia. **Portal G1**, 2021h. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/04/29/pernambuco-confirma-mais-99-mortes-e-2511-casos-da-covid-19.ghtml>>. Acesso em: 10 out. 2021.

G1PE. Confira regras para retomada das atividades econômicas em Pernambuco durante a pandemia. **Portal G1**, 2020. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2020/06/02/confira-regras-para-retomada-das-atividades-economicas-em-pernambuco-durante-a-pandemia.ghtml>>. Acesso em: 10 out. 2021.

G1PE. Em oito dias, 63.180 pessoas são vacinadas contra a Covid-19 em Pernambuco. **Portal G1**, 2021e. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/01/27/em-oito-dias-63180-pessoas-sao-vacinadas-contra-a-covid-19-em-pernambuco.ghtml>>. Acesso em: 10 out. 2021.

G1PE. Fiscalização do Procon e do Corpo de Bombeiros interdita quatro bares no Recife. **Portal G1**, 2021b. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/01/11/fiscalizacao-do-procon-e>>.

do-corpo-de-bombeiros-interdita-quatro-bares-no-recife.ghml>. Acesso em: 10 out. 2021.

G1PE. Marina que promovia festa clandestina é interditada pelo Procon em Jaboatão. **Portal G1**, 2021g. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/02/15/marina-que-promovia-festa-clandestina-e-interditada-pelo-procon-em-jaboatao-dos-guararapes.ghml>>. Acesso em: 10 out. 2021.

G1PE. PE proíbe bares, restaurantes e ambulantes no Bairro do Recife e Sítio Histórico de Olinda no fim de semana de carnaval. **Portal G1**, 2021f. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/02/10/pe-proibe-bares-restaurantes-e-ambulantes-no-bairro-do-recife-e-sitio-historico-de-olinda-no-fim-de-semana-de-carnaval.ghml>>. Acesso em: 10 out. 2021.

G1PE. Pernambuco registra redução no ritmo de vacinação contra Covid. **Portal G1**, 2021j. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/05/28/pernambuco-registra-reducao-no-ritmo-de-vacinacao-contra-a-covid-19.ghml>>. Acesso em: 10 out. 2021.

G1PE. Primeiro dia do Enem tem índice de abstenção de 48,4% em Pernambuco. **Portal G1**, 2021d. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/01/17/primeiro-dia-do-enem-tem-indice-de-abstencao-de-484percent-em-pernambuco.ghml>>. Acesso em: 10 out. 2021.

G1PE. Proibição de som ao vivo ou mecânico em praias, bares e restaurantes de Pernambuco entra em vigor nesta sexta. **Portal G1**, 2021c. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/01/15/proibicao-de-som-ao-vivo-ou-mecanico-em-pernambuco-entra-em-vigor-nesta-sexta.ghml>>. Acesso em: 10 out. 2021.

G1PE. Três bares são interditados pelo Procon ao descumprirem protocolos contra a Covid-19. **Portal G1**, 2021a. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/01/04/tres-bares-no-grande-recife-sao-interditados-pelo-procon-ao-descumprirem-protocolos-contra-a-covid-19.ghml>>. Acesso em: 10 out. 2021.

G1PE. Vacina contra Covid: mais 4,2 mil doses de CoronaVac e 208 mil de AstraZeneca chegam a PE. **Portal G1**, 2021i. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/04/29/vacina-contra-covid-mais-42-mil-de-coronavac-e-208-mil-de-astrazeneca-chegam-a-pernambuco.ghml>>. Acesso em: 10 out. 2021.

GARCIA, M. L. T.; PANDOLFI, A. F.; LEAL, F. X.; STOCCO, A.F.; BORREGO, A. E.; BORGES, R. E.; OLIVEIRA, E. F. D. A.; LANG, A. E.; ANDRADE, C. O.; SALAZAR, S. N.; MENANDRO, L. M.; SPOLANDER, G. The COVID-19 pandemic, emergency aid and social work in Brazil. **Qualitative Social Work**, v. 20, n. 1-2, p. 356-365, 2021.

- GATES, A.; KLEIN, M.; ACQUAOTTA, F.; GARLAND, R. M.; SCOVRONICK, N. Short-term association between ambient temperature and homicide in South Africa: a case-crossover study. **Environmental health**, v. 18, n. 1, p. 1-7, 2019.
- GERELL, M.; KARDELL, J.; KINDGREN, J. Minor covid-19 association with crime in Sweden. **Crime science**, v. 9, n. 1, p. 1-9, 2020.
- GETIS, A. Spatial Autocorrelation. *In: FISCHER, M. M.; GETIS, A. (Eds.). Handbook of Applied Spatial Analysis.* Berlin/Heidelberg: Springer Science & Business Media, 2010. p. 255-278.
- GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.
- GOMES, D. S.; ANDRADE, L. A.; RIBEIRO, C. J. N.; PEIXOTO, M. V. S.; LIMA, S. V. M. A.; DUQUE, A. M.; CIRILO, T. M.; GÓES, M. A. O.; LIMA, A. G. C. F.; SANTOS, M. B.; ARAÚJO, K. C. G. M.; SANTOS, A. D. Risk clusters of COVID-19 transmission in northeastern Brazil: prospective space-time modelling. **Epidemiology & Infection**, v. 148, p. e188, 2020.
- GPI – Índice Global da Paz. 2021. **Global Peace Index**. Disponível em: <<https://www.visionofhumanity.org/maps/#/>>. Acesso em 20 jan. 2022.
- GRECO, S.; FIGUEIRA, J.; EHRGOTT, M. (Eds.). **Multiple Criteria Decision Analysis: State of the Art Surveys**. vol. 1-2. 2. ed. New York: Springer, 2016.
- GRECO, S.; MATARAZZO, B.; SŁOWIŃSKI, R. Decision Rule Approach. *In: FIGUEIRA, J.; GRECO, S.; EHRGOTT, M. (Eds.). Multiple Criteria Decision Analysis: State of the Art Surveys*. 1. ed. New York: Springer, 2005.
- GRIFFITH, D. A. **Spatial autocorrelation and spatial filtering**. Berlin: Springer, 2003.
- GROFF, E.; MCCORD, E. S. The role of neighborhood parks as crime generators. **Security journal**, v. 25, n. 1, p. 1-24, 2012.
- GULMA, U. L.; EVANS, A.; HEPPENSTALL, A.; MALLESON, N. Diversity and burglary: Do community differences matter?. **Transactions in GIS**, v. 23, n. 2, p. 181-202, 2019.
- HABERMAN, C. P.; KELSAY, J. D. The topography of robbery: does slope matter?. **Journal of quantitative criminology**, v. 37, n. 3, p. 625-645, 2021.
- HADDON JR, W. The changing approach to the epidemiology, prevention, and amelioration of trauma: the transition to approaches etiologically rather than descriptively based. **American journal of public health and the Nations health**, v. 58, n. 8, p. 1431-1438, 1968.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.

HALFORD, E.; DIXON, A.; FARRELL, G.; MALLESON, N.; TILLEY, N. Crime and coronavirus: social distancing, lockdown, and the mobility elasticity of crime. **Crime science**, v. 9, n. 1, p. 1-12, 2020.

HANAOKA, K. New insights on relationships between street crimes and ambient population: Use of hourly population data estimated from mobile phone users' locations. **Environment and Planning B: Urban Analytics and City Science**, v. 45, n. 2, p. 295-311, 2018.

HARRIES, K. D. **The geography of crime and justice**. New York: McGraw Hill, 1974.

HEYWOOD, I.; CORNELIUS, S.; CARVER, S. **An Introduction to Geographical Information Systems**. Harlow: Prentice Hall, 2002.

HIPP, J. R.; KANE, K. Cities and the larger context: What explains changing levels of crime?. **Journal of criminal justice**, v. 49, p. 32-44, 2017.

HIPP, J. R.; KIM, Y. A. Explaining the temporal and spatial dimensions of robbery: Differences across measures of the physical and social environment. **Journal of Criminal Justice**, v. 60, p. 1-12, 2019.

HIPP, J. R.; ROUSSELL, A. Micro-and macro-environment population and the consequences for crime rates. **Social Forces**, v. 92, n. 2, p. 563-595, 2013.

HODGKINSON, T.; ANDRESEN, M. A.; FRANK, R.; PRINGLE, D. Crime down in the Paris of the prairies: Spatial effects of COVID-19 and crime during lockdown in Saskatoon, Canada. **Journal of Criminal Justice**, v. 78, p. 101881, 2022.

HOELSCHER, K. Institutional reform and violence reduction in Pernambuco, Brazil. **Journal of Latin American Studies**, v. 49, n. 4, p. 855-884, 2017.

HOHL, A.; DELMELLE, E. M.; DESJARDINS, M. R.; LAN, Y. Daily surveillance of COVID-19 using the prospective space-time scan statistic in the United States. **Spatial and Spatio-temporal Epidemiology**, v. 34, p. 100354, 2020.

HUANG, X.; ZHOU, H.; YANG, X.; ZHOU, W.; HUANG, J.; YUAN, Y. Spatial Characteristics of Coronavirus Disease 2019 and Their Possible Relationship with Environmental and Meteorological Factors in Hubei Province, China. **GeoHealth**, p. e2020GH000358, 2021.

HUGHES, G. D.; MBAMALU, O. N.; OKONJI, C. O.; PUOANE, T. R. The Impact of Health Disparities on COVID-19 Outcomes: Early Findings from a High-Income Country and Two Middle-Income Countries. **Journal of Racial and Ethnic Health Disparities**, p. 1-8, 2021.

- IBGE. 2016. **Censo 2010**. Disponível em: <<https://censo2010.ibge.gov.br/resultados.html>>. Acesso em: 21 fev. 2021.
- IBGE. 2020. **Instituto Brasileiro de Geografia e Estatística**: Cidades e Estados. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/pe.html>>. Acesso em: 19 aug. 2020.
- IYANDA, A. E.; ADELEKE, R.; LU, Y.; OSAYOMI, T.; ADARALEGBE, A.; LASODE, M.; CHIMA-ADARALEGBE, N. J.; OSUNDINA, A. M. A retrospective cross-national examination of COVID-19 outbreak in 175 countries: a multiscale geographically weighted regression analysis (January 11-June 28, 2020). **Journal of Infection and Public Health**, v. 13, n. 10, p. 1438-1445, 2020.
- JABŁOŃSKA, K.; ABALLÉA, S.; TOUMI, M. Factors influencing the COVID-19 daily deaths' peak across European countries. **Public Health**, v. 194, p. 135-142, 2021.
- JCPE. Saiba quais são as atividades essenciais autorizadas a funcionar em Pernambuco durante a pandemia do coronavírus. **Portal NE10**, 2020. Disponível em: <<https://jc.ne10.uol.com.br/pernambuco/2020/05/5608881-saiba-quais-sao-as-atividades-essenciais-autorizadas-a-funcionar-em-pernambuco-durante-a-pandemia-do-coronavirus.html>>. Acesso em: 10 out. 2021.
- JENKS, G. F.; CASPALL, F. C. Error on choroplethic maps: definition, measurement, reduction. **Annals of the Association of American Geographers**, v. 61, n. 2, p. 217-244, 1971.
- JN. Agências da Caixa voltam a registrar longas filas em todo o Brasil. **Portal G1 – Jornal Nacional**, 2020. Disponível em: <<https://g1.globo.com/jornal-nacional/noticia/2020/07/24/agencias-da-caixa-voltam-a-registrar-longas-filas-em-todo-o-brasil.ghtml>>. Acesso em: 06 ago. 2020.
- KAMEDA, K.; BARBEITAS, M. M.; CAETANO, R.; LÖWY, I.; OLIVEIRA, A. C. D. D.; CORRÊA, M. C. D. V.; CASSIER, M. Testing COVID-19 in Brazil: fragmented efforts and challenges to expand diagnostic capacity at the Brazilian Unified National Health System. **Cadernos de Saúde Pública**, v. 37, p. e00277420, 2021.
- KANG, J. Y.; MICHELS, A.; LYU, F.; WANG, S.; AGBODO, N.; FREEMAN, V. L.; WANG, S. Rapidly measuring spatial accessibility of COVID-19 healthcare resources: a case study of Illinois, USA. **International Journal of Health Geographics**, v. 19, n. 1, p. 1-17, 2020.
- KEENEY, R.; RAIFFA, H. **Decisions with Multiple Objectives**: Preferences and Value Trade-Offs. Cambridge: Cambridge University Press, 1976.
- KERR, L.; KENDALL, C.; SILVA, A. A. M. D.; AQUINO, E. M. L.; PESCARINI, J. M.; ALMEIDA, R. L. F.; ICHIHARA, M. Y.; OLIVEIRA, J. F.; ARAÚJO, T. V. B.; SANTOS, C. T.; JORGE, D. C. P.; MIRANDA FILHO, D. B.; SANTANA, G.; GABRIELLI, L.; ALBUQUERQUE, M. F. P. M.; ALMEIDA-FILHO, N.; SILVA, N. J.; SOUZA, R.; XIMENES, R. A. A.; MARTELLI, C. M. T.; BRANDÃO FILHO, S. P.; SOUZA, W. V.; BARRETO, M. L. COVID-19 in Northeast Brazil: achievements and limitations in the

responses of the state governments. **Ciência & Saúde Coletiva**, v. 25, p. 4099-4120, 2020.

KINNEY, J. B.; BRANTINGHAM, P. L.; WUSCHKE, K.; KIRK, M. G.; BRANTINGHAM, P. J. Crime attractors, generators and detractors: Land use and urban crime opportunities. **Built environment**, v. 34, n. 1, p. 62-74, 2008.

KRONBICHLER, A.; KRESSE, D.; YOON, S.; LEE, K. H.; EFFENBERGER, M.; SHIN, J. I. Asymptomatic patients as a source of COVID-19 infections: A systematic review and meta-analysis. **International journal of infectious diseases**, v. 98, p. 180-186, 2020.

KWOK, C. Y. T.; WONG, M. S.; CHAN, K. L.; KWAN, M. P.; NICHOL, J. E.; LIU, C. H.; WONG, J. Y. H.; WAI, A. K. C.; CHAN, L. W. C.; XU, Y.; LI, H.; HUANG, J.; KAN, Z. Spatial analysis of the impact of urban geometry and socio-demographic characteristics on COVID-19, a study in Hong Kong. **Science of the Total Environment**, v. 764, p. 144455, 2021.

LAK, A.; SHARIFI, A.; BADR, S.; ZALI, A.; MAHER, A.; MOSTAFAVI, E.; KHALILI, D. Spatio-temporal Patterns of the COVID-19 Pandemic, and Place-based Influential Factors at the Neighborhood scale in Tehran. **Sustainable Cities and Society**, v. 72, p. 103034, 2021.

LANGTON, S.; DIXON, A.; FARRELL, G. Small area variation in crime effects of COVID-19 policies in England and Wales. **Journal of Criminal Justice**, v.75, p. 101830, 2021.

LEE, S. I. Developing a bivariate spatial association measure: an integration of Pearson's r and Moran's I. **Journal of Geographical Systems**, v. 3, n. 4, p. 369-385, 2001.

LEE, S. M.; OLSON, D. L. Goal Programming. In: GAL, T.; STEWART, T. J.; HANNE, T. (Eds.). **Multicriteria Decision Making: Advances in MCDM Models, Algorithms, Theory, and Applications**. Boston: Kluwer Academic Publishers, 1999.

LEE, Y.; ECK, J. E.; O, S.; MARTINEZ, N. N. How concentrated is crime at places? A systematic review from 1970 to 2015. **Crime Science**, v. 6, n. 1, p. 1-16, 2017.

LI, B.; PENG, Y.; HE, H.; WANG, M.; FENG, T. Built environment and early infection of COVID-19 in urban districts: A case study of Huangzhou. **Sustainable Cities and Society**, v. 66, p. 102685, 2021.

LI, S. L.; PEREIRA, R. H. M.; PRETE, C. A. J. R.; ZAREBSKI, A. E.; EMANUEL, L.; ALVES, P. J. H.; PEIXOTO, P. S.; BRAGA, C. K. V.; DE SOUZA SANTOS, A. A.; DE SOUZA, W. M.; BARBOSA, R. J.; BUSS, L. F.; MENDRONE, A.; DE ALMEIDA-NETO, C.; FERREIRA, S. C.; SALLES, N. A.; MARCILIO, I.; WU, C. H.; GOUVEIA, N.; NASCIMENTO, V. H.; SABINO, E. C.; FARIA, N. R.; MESSINA, J. P. Higher risk of death from COVID-19 in low-income and non-White populations of São Paulo, Brazil. **BMJ Global Health**, v. 6, n. 4, p. e004959, 2021.

LIMA, E. E. C.; GAYAWAN, E.; BAPTISTA, E. A.; QUEIROZ, B. Spatial pattern of COVID-19 deaths and infections in small areas of Brazil. **PLoS One**, v. 16, n. 2, p. e0246808, 2021.

LIU, L.; HU, T.; BAO, S.; WU, H.; PENG, Z.; WANG, R. The Spatiotemporal Interaction Effect of COVID-19 Transmission in the United States. **ISPRS International Journal of Geo-Information**, v. 10, n. 6, p. 387, 2021.

LIU, C.; LIU, Z.; GUAN, C. The impacts of the built environment on the incidence rate of COVID-19: A case study of King County, Washington. **Sustainable cities and society**, v. 74, p. 103144, 2021.

LOPEZ, E.; ROSENFIELD, R. Crime, quarantine, and the US coronavirus pandemic. **Criminology & public policy**, v. 20, n. 3, p. 401-422, 2021.

LYU, J.; MIAO, T.; DONG, J.; CAO, R.; LI, Y.; CHEN, Q. Reflection on lower rates of COVID-19 in children: Does childhood immunizations offer unexpected protection?. **Medical hypotheses**, v. 143, p. 109842, 2020.

MA, Q.; GAO, J.; ZHANG, W.; WANG, L.; LI, M.; SHI, J.; ZHAI, Y.; SUN, D.; WANG, L.; CHEN, B.; JIANG, S.; ZHAO, J. Spatio-temporal distribution characteristics of COVID-19 in China: a city-level modeling study. **BMC Infectious Diseases**, v. 21, n. 1, p. 1-14, 2021.

MAITI, A.; ZHANG, Q.; SANNIGRAHI, S.; PRAMANIK, S.; CHAKRABORTI, S.; CERDA, A.; PILLA, F. Exploring spatiotemporal effects of the driving factors on COVID-19 incidences in the contiguous United States. **Sustainable Cities and Society**, v. 68, p. 102784, 2021.

MALCZEWSKI, J. **GIS and multicriteria decision analysis**. New York: Wiley, 1999.

MALCZEWSKI, J. GIS-based multicriteria decision analysis: a survey of the literature. **International Journal of Geographical Information Science**, v. 20, n. 7, p. 703-726, 2006.

MALCZEWSKI, J. Multiple criteria decision analysis and geographic information systems. In: FIGUEIRA, J.; GRECO, S.; EHRGOTT, M. (Eds.). **Trends in Multiple Criteria Decision Analysis**. New York: Springer, 2010. p. 369–395.

MALCZEWSKI, J. Multicriteria Analysis. In: HUANG, B. **Comprehensive Geographic Information Systems**. Amsterdam: Elsevier, 2017. p. 197-217.

MALCZEWSKI, J.; RINNER, C. **Multicriteria Decision Analysis in Geographic Information Science**. Berlin: Springer, 2015.

MALLESON, N.; ANDRESEN, M. A. Exploring the impact of ambient population measures on London crime hotspots. **Journal of Criminal Justice**, v. 46, p. 52-63, 2016.

MALLESON, N.; STEENBEEK, W.; ANDRESEN, M. A. Identifying the appropriate spatial resolution for the analysis of crime patterns. **PloS One**, v. 14, n. 6, p. e0218324, 2019.

MANDA, S. O. M.; DARIKWA, T.; NKWENIKA, T.; BERGQUIST, R. A Spatial Analysis of COVID-19 in African Countries: Evaluating the Effects of Socio-Economic Vulnerabilities and Neighbouring. **International Journal of Environmental Research and Public Health**, v. 18, n. 20, p. 10783, 2021.

MANSOUR, S.; AL KINDI, A.; AL-SAID, A.; AL-SAID, A.; ATKINSON, P. Sociodemographic determinants of COVID-19 incidence rates in Oman: Geospatial modelling using multiscale geographically weighted regression (MGWR). **Sustainable Cities and Society**, v. 65, p. 102627, 2021.

MARTINES, M. R.; FERREIRA, R. V.; TOPPA, R. H.; ASSUNÇÃO, L. M.; DESJARDINS, M. R.; DELMELLE, E. M. Detecting space-time clusters of COVID-19 in Brazil: mortality, inequality, socioeconomic vulnerability, and the relative risk of the disease in Brazilian municipalities. **Journal of Geographical Systems**, v. 23, n. 1, p. 7-36, 2021.

MARTINS, R. A. Abordagens Quantitativa e Qualitativa. *In: MIGUEL, P. A. C. (org.). Metodologia de pesquisa em engenharia de produção e gestão de operações.* Rio de Janeiro: Elsevier, 2012.

MARTINS, F. S.; GÓES, G. S.; NASCIMENTO, J. A. S. Potential and effective remote work in Brazil: looking into the gap between metrics. **EconomiA**, v. 22, n. 3, p. 265-277, 2021.

MENDES, F. Serviços, em recuperação gradual, podem impulsionar economia no fim do ano **Portal Veja**, 2021. Disponível em: <<https://veja.abril.com.br/economia/servicos-devem-impulsionar-retomada-no-fim-de-2021/>>. Acesso em: 15 jan. 2022.

MILLER, J. M. Criminology as Social Science. *In: \_\_\_\_\_(Ed.). 21st century criminology: A reference handbook.* Los Angeles: Sage, 2009.

MOHLER, G.; BERTOZZI, A. L.; CARTER, J.; SHORT, M. B.; SLEDGE, D.; TITA, G. E.; UCHIDA, C. D.; BRANTINGHAM, P. J. Impact of social distancing during COVID-19 pandemic on crime in Los Angeles and Indianapolis. **Journal of Criminal Justice**, v. 68, p. 101692, 2020.

MOLLALO, A.; VAHEDI, B.; RIVERA, K. M. GIS-based spatial modeling of COVID-19 incidence rate in the continental United States. **Science of the Total Environment**, v. 728, p. 138884, 2020.

MOORE, J. P.; OFFIT, P. A. SARS-CoV-2 vaccines and the growing threat of viral variants. **JAMA**, v. 325, n. 9, p. 821-822, 2021.

MORABITO NETO, R.; PUREZA, V. Modelagem e Simulação. In: MIGUEL, P. A. C. (org.). **Metodologia de pesquisa em engenharia de produção e gestão de operações**. Rio de Janeiro: Elsevier, 2012.

MORAES, L. Pernambuco volta à incerteza sobre liberação de eventos com público acima de 300 pessoas. **Portal NE10**, 2020. Disponível em: <<https://jc.ne10.uol.com.br/economia/2020/11/12003578-pernambuco-volta-a-incerteza-sobre-liberacao-de-eventos-com-publico-acima-de-300-pessoas.html>>. Acesso em: 10 out. 2021.

MORAN, P. A. P. The interpretation of statistical maps. **Journal of the Royal Statistical Society. Series B (Methodological)**, v. 10, n. 2, p. 243-251, 1948.

MOROSINI, L. Comércio vê medida como positiva e amplia horário de funcionamento. **Diário de Pernambuco**, 2020. Disponível em: <<https://www.diariodepernambuco.com.br/noticia/economia/2020/12/comercio-ve-medida-como-positiva-e-amplia-horario-de-funcionamento.html>>. Acesso em: 10 out. 2021.

MOROSINI, L. Eventos sociais e corporativos são suspensos em Pernambuco. **Diário de Pernambuco**, 2021. Disponível em: <<https://www.diariodepernambuco.com.br/noticia/economia/2021/01/eventos-sociais-e-corporativos-sao-suspensos-em-pernambuco.html>>. Acesso em: 10 out. 2021.

MOTA, C. M. M.; FIGUEIREDO, C. J. J.; PEREIRA, D. V. S. Identifying areas vulnerable to homicide using multiple criteria analysis and spatial analysis. **Omega**, v. 100, p. 102211, 2021.

NASCIMENTO, A. PE volta a proibir eventos e shows e impede realização de festas de Natal e Réveillon. **Diário de Pernambuco**, 2020b. Disponível em: <<https://www.diariodepernambuco.com.br/noticia/economia/2020/12/pernambuco-volta-a-proibir-festas-shows-e-impede-realizacao-de-festas.html>>. Acesso em: 10 out. 2021.

NASCIMENTO, A. Pernambuco terá retorno de aulas presenciais no dia 6 de outubro apenas para o ensino médio. **Diário de Pernambuco**, 2020a. Disponível em: <<https://www.diariodepernambuco.com.br/noticia/vidaurbana/2020/09/volta-as-aulas-pernambuco-tera-retorno-de-atividades-presenciais-no-d.html>>. Acesso em: 10 out. 2021.

NEPOMUCENO, T. C. C.; DARAIO, C.; COSTA, A. P. Multicriteria Ranking for the Efficient and Effective Assessment of Police Departments. **Sustainability**, v. 13, n. 8, p. 4251, 2021.

NISBET, R. Feature Selection in KNIME. In: NISBET, R.; ELDER, J.; MINER, G. **Handbook of statistical analysis and data mining applications**. 2. ed. London: Academic press, 2018. p. 377-391.

NIVETTE, A. E.; ZAHNOW, R.; AGUILAR, R.; AHVEN, A.; AMRAM, S.; ARIEL, B.; BURBANO, M. J. A.; ASTOLFI, R.; BAIER, D.; BARK, H. M.; BEIJERS, J. E. H.;

BERGMAN, M.; BREETZKE, G.; CONCHA-EASTMAN, I. A.; CURTIS-HAM, S.; DAVENPORT, R.; DÍAZ, C.; FLEITAS, D.; GERELL, M.; JANG, K. H.; KÄÄRIÄINEN, J.; LAPPI-SEPPÄLÄ, T.; LIM, W. S.; REVILLA, R. L.; MAZEROLLE, L.; MEŠKO, G.; PEREDA, N.; PERES, M. F. T.; POBLETE-CAZENAVE, R.; ROSE, S.; SVENSSON, R.; TRAJTENBERG, N.; VAN DER LIPPE, T.; VELDKAMP, J.; PERDOMO, C. J. V.; EISNER, M. P. A global analysis of the impact of COVID-19 stay-at-home restrictions on crime. **Nature Human Behaviour**, v. 5, n. 7, p. 868-877, 2021.

OLIVEIRA, I. A. S. J.; CARAYANNIS, E. G.; FERREIRA, F. A.; JALALI, M. S.; CARLUCCI, D.; FERREIRA, J. J. Constructing home safety indices for strategic planning in residential real estate: A socio-technical approach. **Technological Forecasting and Social Change**, v. 131, p. 67-77, 2018.

OLUYOMI, A. O.; GUNTER, S. M.; LEINING, L. M.; MURRAY, K. O.; AMOS, C. COVID-19 Community Incidence and Associated Neighborhood-Level Characteristics in Houston, Texas, USA. **International Journal of Environmental Research and Public Health**, v. 18, n. 4, p. 1495, 2021.

OMS. WHO Director-General's opening remarks at the media briefing on COVID-19 - 11 March 2020. **Organização Mundial de Saúde**, 2020. Disponível em: <<https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>>. Acesso em: 30 out. 2021.

OYANA, T. J. **Spatial Analysis with R**: Statistics, Visualization, and Computational Methods. 2. ed. Boca Raton: CRC Press, 2020.

OYANA, T. J.; MARGAI, F. M. **Spatial Analysis**: Statistics, Visualization, and Computational Methods. Boca Raton: CRC Press, 2015.

PANA, T. A.; BHATTACHARYA, S.; GAMBLE, D. T.; PASDAR, Z.; SZLACHETKA, W. A.; PERDOMO-LAMPIGNANO, J. A.; EWERS, K. D.; MCLERNON, D. J.; MYINT, P. K. Country-level determinants of the severity of the first global wave of the COVID-19 pandemic: an ecological study. **BMJ Open**, v. 11, n. 2, p. e042034, 2021.

PEREIRA, D. V. S.; MOTA, C. M. M. Human development index based on ELECTRE-TRI-C multicriteria method: An application in the city of Recife. **Social Indicators Research**, v. 125, n. 1, p. 19-45, 2016.

PEREIRA, D. V. S.; ANDRESEN, M. A.; MOTA, C. M. M. A temporal and spatial analysis of homicides. **Journal of Environmental Psychology**, v. 46, p. 116-124, 2016.

PEREIRA, D. V. S.; MOTA, C. M. M.; ANDRESEN, M. A. Social disorganization and homicide in Recife, Brazil. **International Journal of Offender Therapy and Comparative Criminology**, v. 61, n. 14, p. 1570-1592, 2017a.

PEREIRA, D. V. S.; MOTA, C. M. M.; ANDRESEN, M. A. The homicide drop in Recife, Brazil: a study of crime concentrations and spatial patterns. **Homicide studies**, v. 21, n. 1, p. 21-38, 2017b.

PEREZ-VINCENT, S. M.; SCHARGRODSKY, E.; MEJÍA, M. G. Crime under lockdown: The impact of COVID-19 on citizen security in the city of Buenos Aires. **Criminology & public policy**, v. 20, n. 3, p. 463-492, 2021.

PERSAD, R. A. Hierarchical Bayesian modeling for the spatial analysis of robberies in Toronto, Canada. **Spatial Information Research**, v. 28, n. 2, p. 173-185, 2020.

PHS. 2020. **Pernambuco contra a COVID-19**. Disponível em: <<https://www.pecontracoronavirus.pe.gov.br/>>. Acesso em: 08 jul. 2020.

PRADO, K. H. J.; COLAÇO JÚNIOR, M. Data Science Applied to Crime Analysis Based on Brazilian Open Government Data. **Journal of Applied Security Research**, p. 1-33, 2020.

PRATT, T. C.; CULLEN, F. T. Assessing macro-level predictors and theories of crime: A meta-analysis. **Crime and Justice**, v. 32, p. 373-450, 2005.

QUICK, M.; LAW, J.; LI, G. Time-varying relationships between land use and crime: A spatio-temporal analysis of small-area seasonal property crime trends. **Environment and Planning B: Urban Analytics and City Science**, v. 46, n. 6, p. 1018-1035, 2019.

QUININO, L. R. M.; VASCONCELLOS, F. H. M.; DINIZ, I. S.; AGUIAR, L. R.; RAMOS, Y. T. D. M.; BASTIANI, F. D. Spatial and temporal aspects and factors associated with the spread of Covid-19 to the interior of the State of Pernambuco, Brazil. **Ciência & Saúde Coletiva**, v. 26, p. 2171-2182, 2021.

RADIL, S. M. Spatial Analysis of Crime. In: HUEBNER, B.M.; BYNUM, T. S. **The Handbook of Measurement Issues in Criminology and Criminal Justice**. Wiley Online Library, 2016. p. 535-554.

RATTON, J. L.; DAUDELIN, J. Construction and deconstruction of a homicide reduction policy: the case of pact for life in Pernambuco, Brazil. **International Journal of Criminology and Sociology**, v. 7, p. 173-183, 2018.

RAYMUNDO, C. E.; OLIVEIRA, M. C.; ELEUTERIO, T. D. A.; ANDRÉ, S. R.; DA SILVA, M. G.; QUEIROZ, E. R. D. S.; MEDRONHO, R. D. A. Spatial analysis of COVID-19 incidence and the sociodemographic context in Brazil. **PLoS One**, v. 16, n. 3, p. e0247794, 2021.

ROBERTS, K. A.; COLLEY, L.; AGBAEDENG, T. A.; ELLISON-HUGHES, G. M.; ROSS, M. D. Vascular manifestations of COVID-19–thromboembolism and microvascular dysfunction. **Frontiers in cardiovascular medicine**, v. 7, p. 598400, 2020.

ROGERSON, P. A. **Statistical Methods for Geography**. SAGE Publications, 2001.

ROQUE, G. Por dois dias seguidos, PE bate recorde do número de pacientes na fila por leitos de UTI em 2021. **Portal G1**, 2021. Disponível em: <<https://g1.globo.com/pe/pernambuco/noticia/2021/05/20/por-dois-dias-seguidos->>

pernambuco-bate-recorde-do-numero-de-pacientes-na-fila-por-leitos-de-uti.ghtml>. Acesso em: 10 out. 2021.

ROSA, A. G. F.; SOUZA, A. P. G.; MOTA, C. M. M.; FIGUEIREDO, C. J. J. Construção de um modelo multicritério para apoio a tomada de decisão em segurança pública. *In: LI Simpósio Brasileiro de Pesquisa Operacional*, Limeira, 2019. **Anais...**

ROY, B. **Multicriteria Methodology for Decision Aiding**. Dordrecht: Springer, 1996.

ROY, B. Paradigms and Challenges. *In: GRECO, S.; FIGUEIRA, J.; EHRENGOTT, M. (Eds.). Multiple Criteria Decision Analysis: State of the Art Surveys*. vol. 1-2. 2. ed. New York: Springer, 2016.

ROY, B.; BOUYSSOU, D. **Aide multicritère à la décision**: méthodes et cas. Paris: Economica, 1993.

RUMMENS, A.; HARDYNS, W. The effect of spatiotemporal resolution on predictive policing model performance. **International Journal of Forecasting**, v. 37, n. 1, p. 125-133, 2021.

SALO, A.; HÄMÄLÄINEN, R. P. Preference assessment by imprecise ratio statements. **Operations Research**, v. 40, n. 6, p. 1053-1061, 1992.

SALO, A.; PUNKKA, A. Rank inclusion in criteria hierarchies. **European Journal of Operational Research**, v. 163, n. 2, p. 338-356, 2005.

SAMPSON, R. J.; GROVES, W. B. Community structure and crime: Testing social-disorganization theory. **American Journal of Sociology**, v. 94, n. 4, p. 774-802, 1989.

SANTOS, J. M. Governo de Pernambuco libera eventos corporativos com até 100 pessoas a partir de segunda-feira. **Portal NE10**, 2020. Disponível em: <<https://jc.ne10.uol.com.br/blogs/jamildo/2020/09/04/governo-de-pernambuco-libera-eventos-corporativos-com-ate-100-pessoas-a-partir-de-segunda-feira/index.html>>. Acesso em: 10 out. 2021.

SCHINASI, L. H.; HAMRA, G. B. A time series analysis of associations between daily temperature and crime events in Philadelphia, Pennsylvania. **Journal of Urban Health**, v. 94, n. 6, p. 892-900, 2017.

SCOTT, S. M.; GROSS, L. J. COVID-19 and crime: Analysis of crime dynamics amidst social distancing protocols. **PLoS One**, v. 16, n. 4, p. e0249414, 2021.

SDS - SECRETARIA DE DEFESA SOCIAL DE PERNAMBUCO. 2021. **Indicadores criminais**, 2021. Disponível em: <<http://www.sds.pe.gov.br/>>. Acesso em: 25 out. 2021.

SEPLAG. 2022. **COVID-19 no Mundo, no Brasil e em Pernambuco**. Disponível em: <<https://dados.seplag.pe.gov.br/apps/corona.html#painel>>. Acesso em: 15 jan. 2022.

SHAW, C. R.; MCKAY, H. D. **Juvenile delinquency and urban areas**: A study of rates of delinquency in relation to differential characteristics of local communities in American cities. Chicago: University of Chicago Press, 1942.

SIDDIQI, H. K.; LIBBY, P.; RIDKER, P. M. COVID-19—a vascular disease. **Trends in Cardiovascular Medicine**, v. 31, n. 1, p. 1-5, 2021.

SIGLER, T.: MAHMUDA, S.; KIMPTON, A.; LOGINOVA, J.; WOHLAND, P.; CHARLES-EDWARDS, E.; CORCORAN, J. The socio-spatial determinants of COVID-19 diffusion: the impact of globalisation, settlement characteristics and population. **Globalization and Health**, v. 17, n. 1, p. 1-14, 2021.

SILVA, C.; MELO, S.; SANTOS, A.; JUNIOR, P. A.; SATO, S.; SANTIAGO, K.; SÁ, L. Spatial Modeling for Homicide Rates Estimation in Pernambuco State-Brazil. **ISPRS International Journal of Geo-Information**, v. 9, n. 12, p. 740, 2020.

SILVA, P.; LI, L. Urban crime occurrences in association with built environment characteristics: An African case with implications for urban design. **Sustainability**, v. 12, n. 7, p. 3056, 2020.

SILVA, J.; RIBEIRO-ALVES, M. Social inequalities and the pandemic of COVID-19: the case of Rio de Janeiro. **Journal of Epidemiology & Community Health**, v. 75, p. 975-979, 2021.

SILVERMAN, B. W. **Density estimation for statistics and data analysis**. London: Chapman & Hall, 1986.

SINGHAL, T. A review of coronavirus disease-2019 (COVID-19). **The Indian Journal of Pediatrics**, v. 87, n. 4, p. 281-286, 2020.

SIS. 2020. **Instituto Brasileiro de Geografia e Estatística**: Síntese de Indicadores Sociais 2020. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/saude/9221-sintese-de-indicadores-sociais.html?=&t=downloads>>. Acesso em: 09 mai. 2021.

SLUTKIN, G. Violence is a Contagious Disease. *In: Contagion of Violence*: Workshop Summary. Washington, DC: National Academy Press, 2013.

SMS. 2014. **Secretaria Municipal de Saúde do Recife**: Plano Municipal de Saúde 2014-2017. Disponível em: <[http://www2.recife.pe.gov.br/sites/default/files/plano\\_municipal\\_de\\_saude\\_2015\\_revisado\\_menor.pdf](http://www2.recife.pe.gov.br/sites/default/files/plano_municipal_de_saude_2015_revisado_menor.pdf)>. Acesso em: 9 mai. 2021.

SOUZA, A. P. G.; MOTA, C. M. M.; ROSA, A. G. F.; FIGUEIREDO, C. J. J.; CANDEIAS, A. L. B. A spatial-temporal analysis at the early stages of the COVID-19

pandemic and its determinants: the case of Recife neighborhoods, Brazil. **PLoS One**, v. 17, n. 5, p. e0268538, 2022. DOI: 10.1371/journal.pone.0268538

SOUZA, A. P. G.; ROSA, A. G. F.; MOTA, C. M. M.; FIGUEIREDO, C. J. J. Modelo de suporte a decisão no combate a roubos e furtos sob uma perspectiva espacial. *In: LII Simpósio Brasileiro de Pesquisa Operacional*, João Pessoa, 2020a. **Anais...**

SOUZA, A. P. G.; ROSA, A. G. F.; FIGUEIREDO, C. J. J.; MOTA, C. M. M. Modelo GIS-MCDM para identificação de áreas vulneráveis ao SARS-COV-19. *In: LII Simpósio Brasileiro de Pesquisa Operacional*, João Pessoa, 2020b. **Anais...** SSPE. Pernambuco confirma nova variante da Covid-19 em 2 pacientes do Amazonas. **PE contra coronavírus**, 2021. Disponível em: <<https://www.pecontracoronavirus.pe.gov.br/pernambuco-confirma-nova-variante-da-covid-19-em-2-pacientes-do-amazonas/>>. Acesso em: 10 out. 2021.

SUGUMARAN, R.; DEGROOTE, J. **Spatial decision support systems**: Principles and practices. Boca Raton: CRC Press, 2010.

SUN, Y.; HU, X.; XIE, J. Spatial inequalities of COVID-19 mortality rate in relation to socioeconomic and environmental factors across England. **Science of The Total Environment**, v. 758, p. 143595, 2021.

SUTHERLAND, E. H. **Principles of criminology**. 3. ed. Philadelphia: Lippincott, 1939.

TAVARES, J. P.; COSTA, A. C. Spatial Modeling and Analysis of the Determinants of Property Crime in Portugal. **ISPRS International Journal of Geo-Information**, v. 10, n. 11, p. 731, 2021.

TOBLER, W. R. A computer movie simulating urban growth in the Detroit region. **Economic Geography**, v. 46, n. sup1, p. 234-240, 1970.

TÔRRES, L. Variante P1 do coronavírus já predomina em Pernambuco. **Diário de Pernambuco**, 2021. Disponível em: <<https://www.diariodepernambuco.com.br/noticia/vidaurbana/2021/05/variante-p1-do-coronavirus-ja-predomina-em-pernambuco.html>>. Acesso em: 10 out. 2021.

VALENTE, R. Spatial and temporal patterns of violent crime in a Brazilian state capital: A quantitative analysis focusing on micro places and small units of time. **Applied Geography**, v. 103, p. 90-97, 2019.

VAN HERWIJNEN, M.; RIETVELD, P. Spatial dimensions in multicriteria analysis. *In: THILL, J. C. (Ed.). Spatial multicriteria decision making and analysis: A geographic information sciences approach*. London: Ashgate, 1999. p. 77-99.

VERITY, R. et al. Estimates of the severity of coronavirus disease 2019: a model-based analysis. **The Lancet infectious diseases**, v. 20, n. 6, p. 669-677, 2020.

- VIEZZER, J.; BIONDI, D. The influence of urban, socio-economic, and eco-environmental aspects on COVID-19 cases, deaths and mortality: A multi-city case in the Atlantic Forest, Brazil. **Sustainable Cities and Society**, v. 69, p. 102859, 2021.
- WANG, J.; WU, X.; WANG, R.; HE, D.; LI, D.; YANG, L.; YANG, Y.; LU, Y. Review of associations between built environment characteristics and severe acute respiratory syndrome coronavirus 2 infection risk. **International Journal of Environmental Research and Public Health**, v. 18, n. 14, p. 7561, 2021.
- WANG, Q.; DONG, W.; YANG, K.; REN, Z.; HUANG, D.; ZHANG, P.; WANG, J. Temporal and spatial analysis of COVID-19 transmission in China and its influencing factors. **International Journal of Infectious Diseases**, v. 105, p. 675-685, 2021.
- WANG, L.; LEE, G.; WILLIAMS, I. The spatial and social patterning of property and violent crime in toronto neighbourhoods: A spatial-quantitative approach. **ISPRS International Journal of Geo-Information**, v. 8, n. 1, p. 51, 2019.
- WEBER, M. Decision making with incomplete information. **European Journal of Operational Research**, v. 28, n. 1, p. 44-57, 1987.
- WEINSTEIN, B.; DA SILVA, A. R.; KOUZOUKAS, D. E.; BOSE, T.; KIM, G. J.; CORREA, P. A.; PONDUGULA, S.; LEE, Y.; KIM, J.; CARPENTER, D. O. Precision mapping of COVID-19 vulnerable locales by epidemiological and socioeconomic risk factors, developed using South Korean data. **International Journal of Environmental Research and Public Health**, v. 18, n. 2, p. 604, 2021.
- WEISBURD, D. The law of crime concentration and the criminology of place. **Criminology**, v. 53, n. 2, p. 133-157, 2015.
- WHEELER, D. C.; PÁEZ, A. Geographically Weighted Regression. In: FISCHER, M. M.; GETIS, A. (Eds.). **Handbook of Applied Spatial Analysis**. Berlin/Heidelberg: Springer Science & Business Media, 2010. p. 461-486.
- WOLF, A.; GRAY, R.; FAZEL, S. Violence as a public health problem: An ecological study of 169 countries. **Social Science & Medicine**, v. 104, p. 220-227, 2014.
- WOLFF, M. J. Policing and the logics of violence: a comparative analysis of public security reform in Brazil. **Policing and society**, v. 27, n. 5, p. 560-574, 2017.
- WONG, D. V. S.; WANG, F. Spatial Analysis Methods. In: HUANG, B. **Comprehensive Geographic Information Systems**. Amsterdam: Elsevier, 2017. p. 125-147.
- XIONG, Y.; WANG, Y.; CHEN, F.; ZHU, M. Spatial statistics and influencing factors of the COVID-19 epidemic at both prefecture and county levels in Hubei Province, China. **International Journal of Environmental Research and Public Health**, v. 17, n. 11, p. 3903, 2020.

XU, R.; XIONG, X.; ABRAMSON, M. J.; LI, S.; GUO, Y. Ambient temperature and intentional homicide: A multi-city case-crossover study in the US. **Environment International**, v. 143, p. 105992, 2020.

YANG, M.; CHEN, Z.; ZHOU, M.; LIANG, X.; BAI, Z. The Impact of COVID-19 on Crime: A Spatial Temporal Analysis in Chicago. **ISPRS International Journal of Geo-Information**, v. 10, n. 3, p. 152, 2021.

YU, X. Risk interactions of coronavirus infection across age groups after the peak of COVID-19 epidemic. **International Journal of Environmental Research and Public Health**, v. 17, n. 14, p. 5246, 2020.

ZAVADSKAS, E. K.; TURSKIS, Z.; KILDIENĖ, S. State of art surveys of overviews on MCDM/MADM methods. **Technological and Economic Development of Economy**, v. 20, n. 1, p. 165-179, 2014.

ZHANG, H.; MCCORD, E. S. A spatial analysis of the impact of housing foreclosures on residential burglary. **Applied Geography**, v. 54, p. 27-34, 2014.

ZHENG, A.; WANG, T.; LI, X. Spatiotemporal Characteristics and Risk Factors of the COVID-19 Pandemic in New York State: Implication of Future Policies. **ISPRS International Journal of Geo-Information**, v. 10, n. 9, p. 627, 2021.

ZOPOUNIDIS, C.; DOUMPOS, M. Multicriteria classification and sorting methods: a literature review. **European Journal of Operational Research**, v. 138, n. 2, p. 229-246, 2002.

## APÊNDICE A – ANÁLISE FATORIAL

O Apêndice A apresenta resultados estatísticos obtidos durante a etapa de Análise Fatorial Exploratória dos estabelecimentos comerciais considerados preditores de roubos.

Quadro A.1 – Medidas de adequação da amostra (MSA) dos estabelecimentos comerciais

Academia	Adoração	Banco	Bar	Cafedoces
0,86	0,59	0,82	0,76	0,85
Cuiddomest	Cuidpessoas	Escola	Fac_curso	Farmacia
0,84	0,85	0,73	0,86	0,84
Hotel	Informatic	Loterica24	Mercado	Oficina
0,71	0,91	0,81	0,80	0,61
Padaria	Petshop	Posto	Salaob	Saude
0,86	0,85	0,81	0,91	0,84

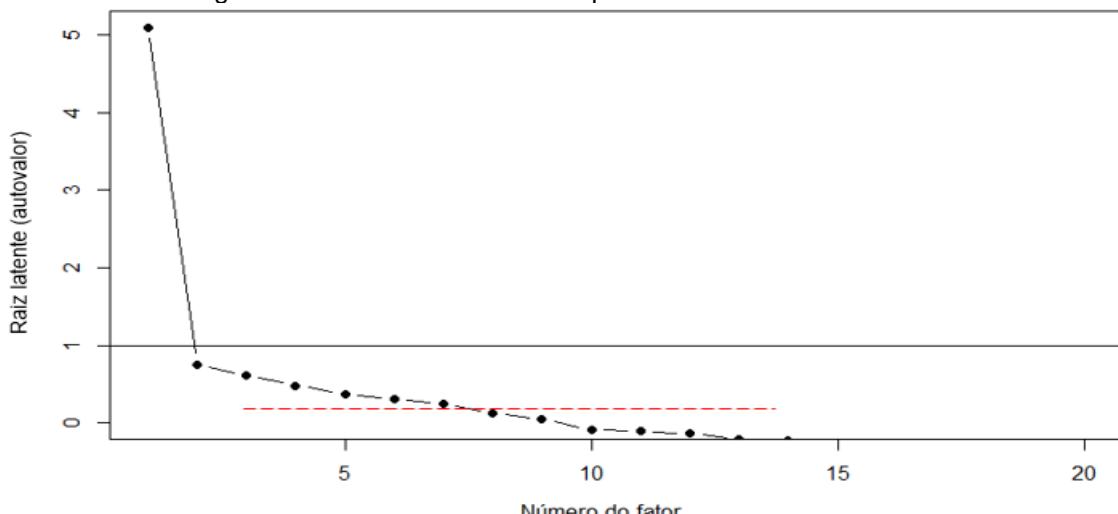
Fonte: O autor (2022)

Quadro A.2 – Autovalores (raízes latentes) associados a cada fator

Fator 1	Fator 2	Fator 3	Fator 4	Fator 5
5,764	1,574	1,355	1,289	1,157
Fator 6	Fator 7	Fator 8	Fator 9	Fator 10
1,137	0,923	0,864	0,820	0,695
Fator 11	Fator 12	Fator 13	Fator 14	Fator 15
0,655	0,608	0,559	0,494	0,475
Fator 16	Fator 17	Fator 18	Fator 19	Fator 20
0,407	0,374	0,317	0,283	0,250

Fonte: O autor (2022)

Figura A.1 – Gráfico de autovalor para o critério de teste scree



Fonte: O autor (2022)

Quadro A.3 – Análise factorial usando os métodos de fatoração Minres, Ols e Principal axes

Variável explicativa	Cargas rotacionadas			Comunalidade
	Fator PA1	Fator PA3	Fator PA2	
bar	0,2	0,48	0,04	0,27
academia	0,15	0,25	0,41	0,26
escola	0,04	0,07	0,44	0,2
padaria	0,4	0,03	0,2	0,2
petshop	0,41	0,01	0,21	0,21
adoracao	0,07	-0,07	0,4	0,17
banco	0,46	0,52	-0,18	0,51
cafedoceso	0,51	0,33	0,22	0,42
farmacia	0,7	0,27	0	0,56
hotel	0,09	0,36	0,03	0,14
loterica24	0,46	0,27	0,24	0,34
mercado	0,35	0,19	0,19	0,19
oficina	0,11	0,08	0,29	0,1
posto	0,28	0,38	0,15	0,24
salaob	0,71	0,28	0,13	0,6
saudé	0,1	0,55	0,34	0,43
cuidpessoa	0,62	0,41	0,06	0,55
cuiddomest	0,19	0,74	0,16	0,61
informatic	0,4	0,29	0,41	0,41
fac_curso	0,39	0,25	0,42	0,39
<b>Variância acumulada</b>	0,15	0,27	0,34	-

Fonte: O autor (2022)

Quadro A.4 – Análise fatorial usando os métodos de fatoração Max likelihood

Variável explicativa	Cargas rotacionadas			Comunalidade
	Fator PA1	Fator PA3	Fator PA2	
bar	0,28	0,39	0,04	0,236
academia	0,16	0,15	0,46	0,257
escola	0,04	0,03	0,4	0,167
padaria	0,32	0,06	0,23	0,157
petshop	0,34	0,03	0,25	0,182
adoracao	0,01	-0,01	0,34	0,114
banco	0,62	0,34	-0,14	0,518
cafedoceso	0,43	0,39	0,3	0,43
farmacia	0,67	0,24	0,09	0,509
hotel	0,19	0,26	0,03	0,104
loterica24	0,43	0,24	0,3	0,336
mercado	0,3	0,26	0,18	0,188
oficina	0,06	0,11	0,27	0,086
posto	0,3	0,35	0,15	0,237
salaob	0,69	0,23	0,21	0,578
sauda	0,18	0,42	0,36	0,342
cuidpessoa	0,71	0,27	0,14	0,598
cuiddomest	0,12	0,98	0,15	0,993
informatic	0,38	0,26	0,46	0,427
fac_curso	0,43	0,1	0,5	0,451
<b>Variância acumulada</b>	0,16	0,26	0,35	-

Fonte: O autor (2022)