

# Análise espacial do índice de criminalidade na área urbana do município de Caucaia, Ceará, Brasil

*Spatial analysis of crime rate in the urban area of Caucaia, Ceará, Brazil*

*Análisis espacial de la tasa de criminalidad en el área urbana de Caucaia, Ceará, Brasil*

Flávio do Nascimento Moreira Júnior <sup>1</sup>, Aryberg de Souza Duarte <sup>2</sup>, Wagner Vinicius Amorin <sup>3</sup>, Marcelo Davi Santos <sup>4</sup> e Paula Alves Tomaz <sup>5</sup>

<sup>1</sup> ProPGeo/UECE, LEURC/UECE, SUPESP/SSPDSCE, Fortaleza - CE, Brasil. E-mail: nascimento.flavio@gmail.com

 <https://orcid.org/0000-0003-0447-5911>

<sup>2</sup> ProPGeo/UECE, Fortaleza-CE, Brasil. E-mail: arybergduarte@gmail.com

 <https://orcid.org/0000-0002-4867-6240>

<sup>3</sup> ProPGeo/UECE, LEURC/UECE, Fortaleza - CE, Brasil. E-mail: wagner.amorin@uece.br

 <https://orcid.org/0000-0002-4108-5798>

<sup>4</sup> CAEN/UFC, Fortaleza - CE, Brasil. E-mail: davisantos@caen.ufc.br

 <https://orcid.org/0000-0002-4737-9068>

<sup>5</sup> Geografia/URCA, Fortaleza - CE, Brasil. E-mail: alvestomazp@gmail.com

 <https://orcid.org/0000-0001-9552-818X>

Recebido: 21/01/2025; Aceito: 14/03/2025; Publicado: 18/03/2025

**Resumo:** Este estudo adotou uma abordagem analítica espacial para examinar a distribuição do Índice de Criminalidade Violenta Letal e Intencional (CVLI) na área urbana de Caucaia, utilizando a linguagem de programação R e bibliotecas especializadas. Os testes de Moran's I, Geary's C e Monte-Carlo destacaram fortes padrões de autocorrelação espacial, indicando a presença de clusters espaciais nos índices de criminalidade. A análise local com Mapa de Clusters LISA identificou áreas de alta concentração ('Alto-Alto') e adjacências com áreas classificadas como ('Alto-Baixo'). A interseção espacial dessas áreas revelou que 31,9% dos 897 casos de CVLI ocorreram nos clusters identificados, representando apenas 3,93% da área total. Isso enfatiza a necessidade de estratégias específicas nessas regiões. Os resultados têm potencial para contribuir para políticas públicas, permitindo a alocação eficaz de recursos e a implementação de medidas preventivas. A continuidade do estudo é crucial para uma compreensão mais abrangente, envolvendo análises temporais e consideração de fatores socioeconômicos, contribuindo para o desenvolvimento de estratégias informadas e abrangentes no enfrentamento das raízes estruturais da criminalidade na região.

**Palavras-chave:** Geoestatística; Geografia do crime; Geoprocessamento; Indicador de associação espacial local; Padrões espaciais de criminalidade.

**Abstract:** This study adopted a spatial analytical approach to examine the distribution of the Violent Lethal Intentional Crimes (CVLI) in the urban area of Caucaia, using the R programming language and specialized libraries. The Moran's I, Geary's C and Monte-Carlo tests highlighted strong patterns of spatial autocorrelation, indicating the presence of spatial clusters in crime rates. Local analysis with LISA Cluster Map identified areas of high concentration ('High-High') and adjacencies with areas classified as ('High-Low'). The spatial intersection of these areas revealed that 31.9% of the 897 CVLI cases occurred in the identified clusters, representing only 3.93% of the total area. This emphasizes the need for specific strategies in these regions. The results have the potential to contribute to public policies, allowing for the effective allocation of resources and

the implementation of preventive measures. Continuing the study is crucial for a more comprehensive understanding, involving temporal analyzes and consideration of socioeconomic factors, contributing to the development of informed and comprehensive strategies to tackle the structural roots of crime in the region.

**Keywords:** Geostatistics; Geography of crime; Geoprocessing; Local spatial association indicator; Spatial patterns of crime.

**Resumen:** Este estudio adoptó un enfoque analítico espacial para examinar la distribución de los Delitos Intencionales Letales Violentos (CVI) en el área urbana de Caucaia, utilizando el lenguaje de programación R y bibliotecas especializadas. Las pruebas I de Moran, C de Geary y Monte-Carlo destacaron fuertes patrones de autocorrelación espacial, indicando la presencia de conglomerados espaciales en las tasas de criminalidad. El análisis local con LISA Cluster Map identificó áreas de alta concentración ('Alta-Alta') y adyacencias con áreas clasificadas como ('Alta-Baja'). La intersección espacial de estas áreas reveló que el 31,9% de los 897 casos de CVI ocurrieron en los conglomerados identificados, lo que representa solo el 3,93% del área total. Esto enfatiza la necesidad de estrategias específicas en estas regiones. Los resultados tienen el potencial de contribuir a las políticas públicas, permitiendo la asignación efectiva de recursos y la implementación de medidas preventivas. Continuar con el estudio es crucial para una comprensión más integral, que involucre análisis temporales y consideración de factores socioeconómicos, contribuyendo al desarrollo de estrategias informadas e integrales para abordar las raíces estructurales del crimen en la región.

**Palabras clave:** Geoestadística; Geografía del crimen; Geoprocésamiento; Indicador de asociación espacial local; Patrones espaciales del crimen.

---

## 1. Introdução

As categorias espaço e lugar desempenham papéis cruciais na compreensão e prevenção do crime como fenômeno geográfico. A 'Geografia do Crime' explora a intrincada relação entre espaço geográfico, território, lugar e a incidência criminal (Melo; Matias, 2016). Vários estudos têm evidenciado que a distribuição do crime é fortemente influenciada pelas características espaciais de uma determinada área (Gupta; Ferguson, 1997; Oliveira; Medeiros; Carvalho, 2017).

A análise do crime em escalas mais detalhadas concentra-se em áreas geográficas específicas dentro das cidades, como endereços, segmentos de ruas e quadras, direcionando seu enfoque para a microgeografia/microescalas, como no caso das pesquisas de Oliveira, Medeiros e Carvalho (2017) que usaram dados dos setores censitários e Magalhães (2024) que usaram dados a nível de bairro. Essa abordagem é fundamental para contribuir à compreensão e possível mitigação das variáveis que influenciam eventos criminais específicos (Weisburd; Eck; Braga, 2016). Ao analisar o crime em diversas unidades espaciais, como bairros e ruas urbanas, é possível identificar padrões espaço-temporais e prever pontos críticos (Harkness; Harris; Baker, 2016). Essa abordagem proporciona uma compreensão abrangente dos padrões de crime, abrindo oportunidades para a formulação de políticas públicas e intervenções eficazes no espaço urbano (Furtado; Renski, 2021; Weisburd; Bernasco; Bruinsma, 2008).

Técnicas avançadas, como análise espacial (Câmara et al., 2004; Fotheringham; Brunsdon; Charlton, 2000; Getis, 1992; Lopes; Pereira, 2022) e geoestatística (Arlinghaus, 2020; Cressie, 1991; Cressie, 2015; De Smith; Goodchild; Longley, 2007; Santos; Raia Junior, 2006), podem contribuir para o mapeamento de crimes e seus fatores condicionadores, desempenhando um papel significativo na visualização e interpretação de dados criminais (Anselin et al., 2000; Paulsen; Robinson, 2009).

O sociólogo Robert E. Park, citado por Entrikin (1980), destacou em seus estudos sobre ecologia urbana como a proximidade física em áreas urbanas pode intensificar as tensões e aumentar a probabilidade de comportamentos violentos. Nas áreas urbanas, a desigualdade econômica frequentemente atinge níveis mais acentuados. O sociólogo Richard Wilkinson (2010), em seu livro "The Spirit Level: Why Equality is Better for Everyone", argumenta que a desigualdade de renda está correlacionada com níveis mais elevados de violência. Além disso, as cidades, por concentrarem tanto a riqueza quanto a pobreza, podem gerar conflitos entre diferentes atores sociais, além da cooptação de membros de algumas classes sociais para grupos criminosos.

A presença de grupos e atividades criminosas é mais comum em áreas urbanas. Edwin Sutherland introduziu a teoria da "associação diferencial", sugerindo que as pessoas são influenciadas por seus grupos de pares e podem se envolver em comportamentos criminosos quando expostas a padrões de comportamento criminoso em seus

ambientes (Sutherland; Cressey; Luckenbill, 1992). Essas perspectivas fornecem insights importantes sobre os desafios associados à vida urbana e destacam a complexa interação entre fatores espaciais, sociais, econômicos e criminais.

A análise espacial, ancorada na "Primeira Lei de Tobler: a Lei do Decaimento da Similaridade", postula que a semelhança entre dois lugares diminui à medida que a distância entre eles aumenta. Em outras palavras, a proximidade geográfica está diretamente relacionada à maior similaridade entre lugares. Esta abordagem, formulada por Waldo R. Tobler (1970), é uma ferramenta inestimável para compreender as intrincadas interações dentro dos espaços urbanos. A essência do princípio reside na concepção de que "tudo está relacionado a tudo, mas coisas mais próximas estão mais relacionadas do que coisas mais distantes". Este conceito, intrinsecamente associado à distância geográfica, desempenha um papel crítico na análise das relações entre fenômenos criminosos e o espaço geográfico. Sua aplicação em estudos da conjuntura nas cidades brasileiras já foi evidenciada em diversas ocasiões (Armstrong, 2022; De Lima et al., 2005a, 2005b; Plassa; Parré, 2019), consolidando-se como um pilar teórico valioso para a compreensão da dinâmica criminal em contextos urbanos.

Neste contexto, o presente estudo realizou uma análise de autocorrelação espacial, utilizando o método do índice de Moran global e local. O objetivo é alcançar uma compreensão mais aprofundada das tendências espaciais do Crime Violento Letal Intencional (CVLI) no período de 2015 a 2018 na área urbana contínua de Caucaia. A análise será conduzida com base em 356 setores censitários do censo de 2010, abrangendo tanto a sede quanto o distrito de Jurema. Esta abordagem visa examinar a autocorrelação espacial do indicador CVLI por meio da geração do diagrama de dispersão de Moran para contextualizar as ocorrências de homicídios. Além disso, os resultados serão materializados por meio da criação de um mapa de clusters LISA, destacando padrões espaciais significativos.

## 2. Área de Estudo

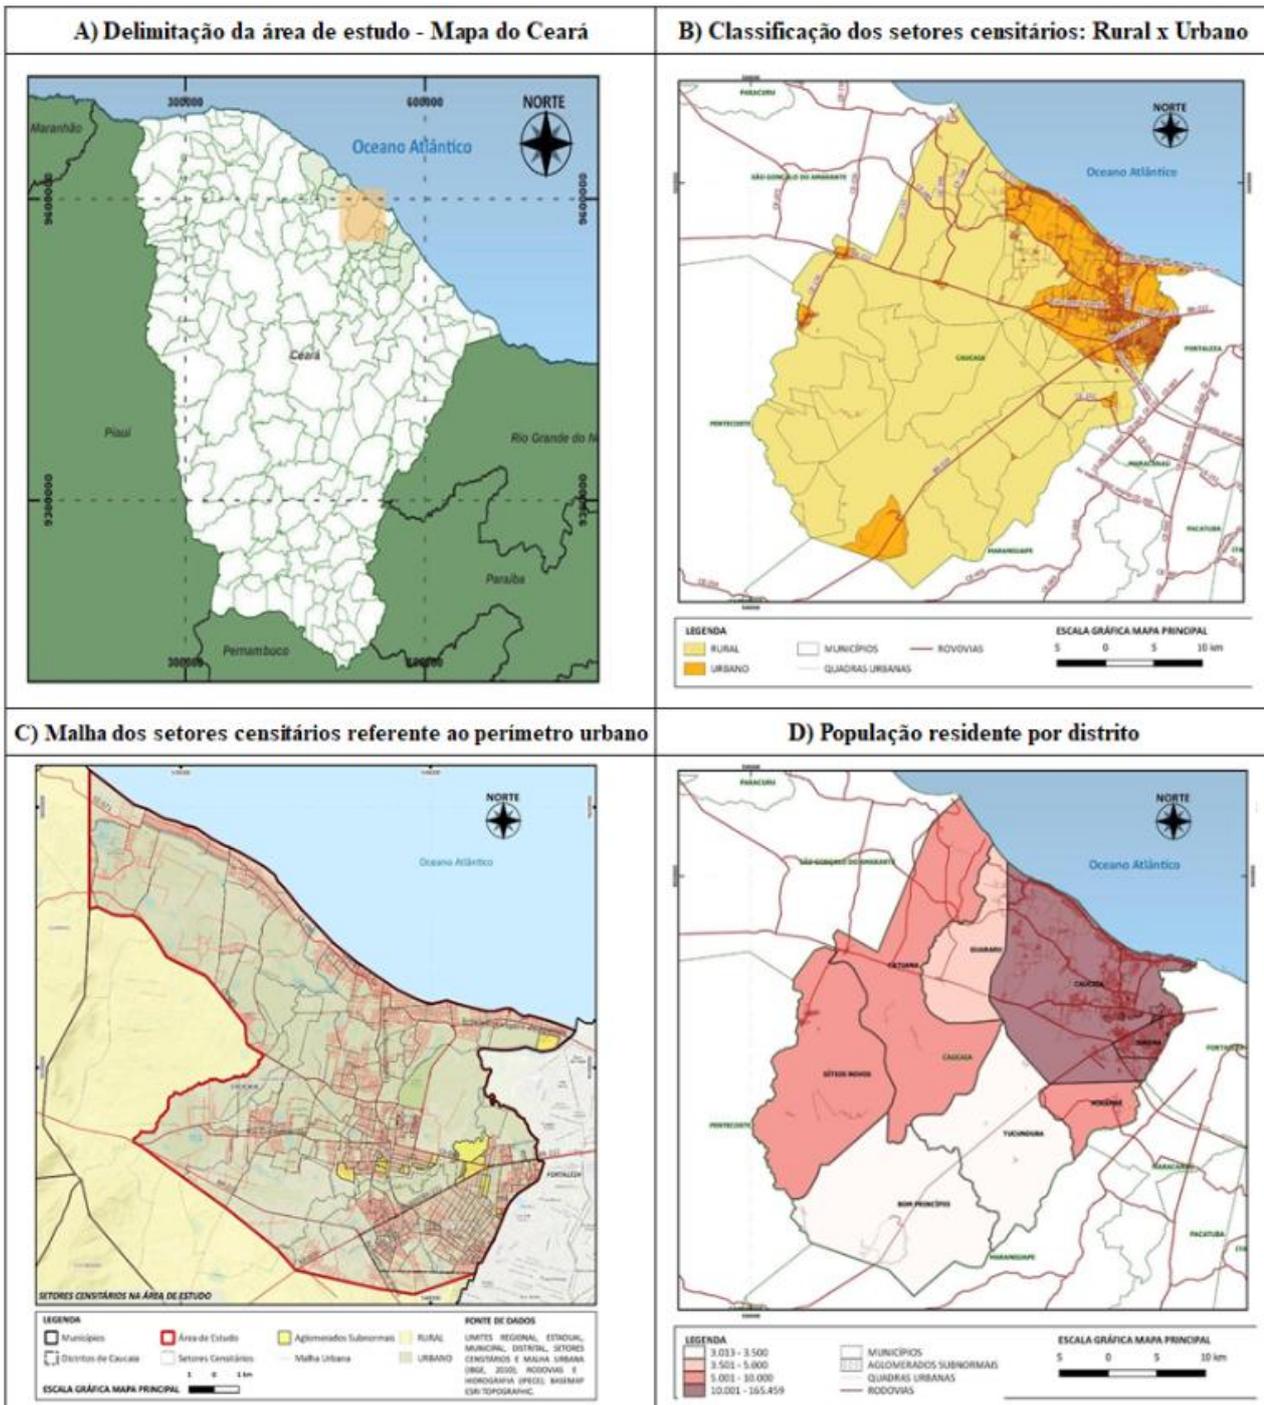
O Ceará é o estado que tem excelentes condições geográficas de fluxo, pois é o estado do nordeste brasileiro mais próximo da Europa, está na orla dos circuitos internacionais de turismo e tem uma infraestrutura de escoamento muito boa. O complexo logístico do Ceará proporciona o aproveitamento das mesmas rotas tanto para o fluxo de mercado lícito quanto para o ilícito, e Caucaia, por exemplo, é passagem obrigatória para quem quer chegar ao porto de Pecém a partir da capital. O acesso ao município de Caucaia é realizado principalmente pelas rodovias BR-020 e CE-085, além de estradas secundárias. O município de Caucaia, área de estudo desta pesquisa, está distante 16 Km rodoviários de Fortaleza (Figuras 1A, 1B, 1C, 1D), no estado do Ceará, Nordeste do Brasil, e integra a Região Metropolitana de Fortaleza (RMF), capital do estado.

O objeto de estudo é o indicador criminal CVLI, que se refere ao Crime Violento Letal Intencional, um termo utilizado no contexto de segurança pública e estatísticas criminais para se referir a uma categoria de crimes violentos intencionais que resultam na morte da vítima. Geralmente, inclui crimes como homicídios dolosos (quando alguém tira a vida de outra pessoa com a intenção de matar), latrocínios (roubos seguidos de morte), lesões corporais seguidas de morte e outros tipos de crimes violentos que têm como desfecho fatal.

Os dados oficiais da Superintendência de Pesquisa e Estratégia de Segurança Pública (Supesp), órgão vinculado à Secretaria de Segurança Pública e Defesa Social do Estado do Ceará (SSPDS), foram consolidados para o período de 01 de janeiro de 2015 a 31 de dezembro de 2018, trazem que no município de Caucaia foram registrados 1.089 CVLI, com isso, para este universo foi utilizada uma amostra de 92,93%, que se refere às ocorrências georreferenciadas.

Vale o destaque que no ano de 2015 iniciaram-se os primeiros registros midiáticos da presença de organizações criminosas no estado, ratificado pelo período no qual o sistema penitenciário cearense passou por um processo de diferenciação da massa carcerária entre os integrantes, velhos e recém recrutados, das organizações criminosas PCC e CV, e o quanto isso influenciou dentro e fora das penitenciárias.

No quadro a seguir é construído um panorama comparativo das ocorrências de CVLI, a partir dos dados do período analisado, para as áreas urbanas e rurais do município de Caucaia. Considerando para tal, a definição de situação urbana para "áreas urbanizadas ou não, internas ao perímetro urbano das cidades (sedes municipais) ou vilas (sedes distritais) ou às áreas urbanas isoladas, conforme Lei Municipal vigente de 2010." (Base de informações do Censo Demográfico 2010: Resultados do Universo por setor censitário, pg. 18).



**Figura 1.** Espacialização da área de estudo considerando a classificação da malha do perímetro urbano segundo os setores censitários do município de Caucaia, Ceará, Censo IBGE 2010. **Fonte:** Elaboração própria (2023), com base nos resultados extraídos do software QGIS Desktop 3.32.0.

Assim é possível entender que para esta escala de observação o quanto e onde realmente há alta concentração de ocorrências de CVLI, e que em Caucaia predominantemente ocorrem na área urbana contínua do município, onde foram contabilizadas uma média de 88,20% das ocorrências de CVLI georreferenciadas no período.

Assim, esta é a área de estudo, área urbana que abrange parte da sede municipal e mais o distrito de Jurema completo e impacta cerca de 90,56% da população caucaiana, segundo números do censo supracitado.

**Quadro 1:** Distribuição espacial do nº de vítimas de crimes de CVLI georreferenciado por setor censitário, urbano e rural, Caucaia, 2015 a 2018.

ANO	ÁREA RURAL		ÁREA URBANA					TOTAL
	Área Rural	Área Rural (%)	Outras Sedes Distritais	Outras Sedes Distritais (%)	Área de Estudo	Área de Estudo (%)	Área Urbana (%)	
2015	27	15,17	4	2,25	147	82,58	84,83	178
2016	13	7,43	4	2,29	158	90,29	92,57	175
2017	23	7,42	1	0,32	286	92,26	92,58	310
2018	36	10,32	7	2,01	306	87,68	89,68	349

Fonte: Elaboração própria com base na Malha dos Setores Censitários (IBGE, 2010) e dados CVLI (SUPESP).

### 3. Fundamentação Teórica

A justificação para a aplicação de técnicas geoestatísticas reside na singular capacidade de modelar fenômenos espaciais, revelando padrões e correlações no contexto geográfico. Nesse cenário, a análise espacial destaca-se como uma ferramenta crucial. Essa afirmação é respaldada por diversos autores que desempenharam trabalhos na aplicação de tais técnicas avançadas em diversas áreas do conhecimento (Arlinghaus, 2020; Burt; Barber; Rigby, 2009; Chun; Griffith, 2013; De Smith; Gatrell; Bailey, 1996; Goodchild; Longley, 2007; Fotheringham; Brunson; Charlton, 2000). Os referidos autores enfatizam a relevância dessas abordagens na análise e modelagem da complexidade espacial em diversos campos do conhecimento.

No campo da análise espacial, Anselin, Sridharan e Gholston (2007) enfatizaram a utilidade da Exploratory Spatial Data Analysis (ESDA) para revelar padrões em bancos de dados de indicadores sociais, oferecendo uma compreensão mais profunda das dinâmicas espaciais em contextos sociais. Carvalho e Nascimento (2014), Da Costa et al. (2022), Gatrell e Bailey (1996), e Imro'ah et al. (2023) exploraram padrões espaciais em dados relacionados à saúde por meio da aplicação de técnicas de análise espacial em estudos de geografia médica (geografia da saúde). Por sua vez, Sparks (2013) propôs abordagens práticas utilizando a linguagem 'R' para investigar padrões e relações em dados geoespaciais, demográficos e socioeconômicos.

Além disso, no contexto da análise espacial, destaca-se a contribuição de Câmara et al. (2004), que abordaram a Análise espacial de áreas, oferecendo insights valiosos sobre técnicas e métodos para compreensão de padrões espaciais em dados geográficos. Quanto as pesquisas brasileiras que aplicaram a análise espacial em dados de criminalidade, pode-se citar os trabalhos de Oliveira, Medeiros e Carvalho (2017) que verificaram correlações e regressões espaciais entre criminalidade e dados sociais e de renda para a cidade de Fortaleza, e a pesquisa de Magalhães (2024) também para Fortaleza, onde os autores identificaram cinturões de insegurança urbana prevalentes em bairros vizinhos.

Em uma perspectiva de desenvolvimento regional, Marconato, Brambilla e do Nascimento (2015) conduziram uma análise espacial do desenvolvimento municipal no Paraná, buscando compreender os padrões socioeconômicos regionais. Por outro lado, Salima e Bellefon (2018) exploraram índices de autocorrelação espacial, analisando detalhadamente a dependência espacial em dados e identificando padrões de similaridade e dissimilaridade. Cheruiyot (2022), por sua vez, explorou o uso de técnicas como densidade de kernel e análise de Moran's I global e local para identificar padrões espaciais de atividades econômicas regionais, buscando produzir insights que pudessem corroborar com o planejamento e desenvolvimento econômico local.

Esses trabalhos ressaltam como diferentes autores aplicaram métodos de análise espacial em contextos específicos, contribuindo para o avanço contínuo do campo e oferecendo insights em diversas áreas do conhecimento.

No âmbito da análise espacial de homicídios e violência, De Lima et al. (2005a, 2005b), Silva (2015), Plassa e Parré (2019) e Armstrong (2022) investigam o fenômeno da violência no contexto do Brasil. De Lima et al. (2005a, 2005b) exploraram determinantes socioeconômicos e conglomerados de violência em Pernambuco, oferecendo observações para entender os padrões desses fenômenos. Silva (2015) aplicou uma análise espacial e avaliação de vulnerabilidade socioeconômica para o indicador CVLI (Crimes Violentos Letais Intencionais) no Estado de

Pernambuco. Por sua vez, Plassa e Parré (2019) analisaram espacialmente as taxas de homicídios e fatores socioeconômicos no Paraná. Finalmente, Armstrong (2022) concentrou-se especificamente no estado do Rio de Janeiro durante os anos de 2010, 2014 e 2018, estudando padrões espaciais de violência por meio do estimador de densidade de Kernel e autocorrelação espacial de Moran.

### 3.1. Crime Violento Intencional

CVLI, ou Crime Violento Letal Intencional, é uma categoria que abrange crimes violentos que resultam intencionalmente em morte, incluindo homicídios, latrocínios e lesões corporais seguidas de morte. Caracterizada por sua violência extrema, essa categoria é frequentemente utilizada em análises criminais para compreender a gravidade e a incidência de crimes violentos fatais. O estudo do CVLI desempenha um papel crucial na compreensão de padrões criminais, no desenvolvimento de estratégias de prevenção e na formulação de políticas públicas para a redução desses crimes (Silva, 2015).

### 3.2. Matriz de Vizinhaça

A Matriz de Vizinhaça, também conhecida como Matriz de Proximidade Espacial (W), é uma componente essencial em análises espaciais, desempenhando um papel fundamental na representação das relações espaciais entre unidades geográficas. Conforme os autores Anselin (1995), Câmara et al. (2004), Chun e Griffith (2013), Luzardo, Castañeda Filho e Rubim (2017), a construção e utilização adequada da Matriz de Vizinhaça são cruciais para a aplicação eficiente de técnicas geoestatísticas, como a Exploratory Spatial Data Analysis (ESDA) e a autocorrelação espacial de Moran.

### 3.3. Índice de Moran Global

O Índice de Moran Global, proposto por Moran (1950), é uma medida de autocorrelação espacial que avalia se as observações em uma determinada área estão espacialmente correlacionadas (Anselin, 1995; Câmara et al., 2004; Luzardo; Castañeda Filho; Rubim, 2017; Jung; Thill; Issel, 2019; Moran, 1950). A fórmula para o Índice de Moran Global é dada por:

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

Onde:

- $[n]$  é o número de unidades espaciais;
- $[w_{ij}]$  são os pesos espaciais entre as observações  $[i]$  e  $[j]$ ;
- $[x_i]$  e  $[x_j]$  são os valores das observações;
- $[\bar{x}]$  é a média dos valores das observações

Este índice pode ser usado para verificar se os dados amostrais apresentam autocorrelação espacial na área toda, ou seja, em termos globais.

### 3.4. Teste Global de Autocorrelação Espacial de Geary (Geary's C) e Monte Carlo

#### 3.4.1 Teste Global de Autocorrelação Espacial de Geary (Geary's C)

O Teste Global de Autocorrelação Espacial de Geary, também conhecido como Geary's C, é uma estatística utilizada na análise espacial para avaliar a presença de autocorrelação espacial em conjuntos de dados geográficos (Anselin, 1995; Câmara et al., 2004; Luzardo; Castañeda Filho; Rubim, 2017; Jung; Thill; Issel, 2019). No contexto do Geary's C, a estatística é calculada como uma razão de somas de quadrados das diferenças entre valores observados em diferentes locais, indicando se os valores estão mais ou menos dispersos do que seria esperado ao acaso.

A fórmula para o Geary's C é a seguinte:

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

Onde:

- $[n]$  é o número de observações;
- $[w_{ij}]$  são os pesos espaciais entre as observações  $[i]$  e  $[j]$ ;
- $[x_i]$  e  $[x_j]$  são os valores das observações;
- $[\bar{x}]$  é a média dos valores das observações;
- $[W]$  é a soma total dos pesos  $[w_{ij}]$ ;

Valores baixos de Geary's C indicam alta autocorrelação espacial, refletindo homogeneidade nos dados, enquanto valores altos sugerem baixa autocorrelação espacial, indicando heterogeneidade na distribuição dos valores.

### 3.4.2 Estatística Monte Carlo

A Estatística Monte Carlo é uma técnica que emprega simulações computacionais para a estimativa de distribuições de probabilidade e a condução de testes estatísticos. Em outras palavras, consiste na simulação de múltiplas realizações aleatórias de um processo, permitindo a obtenção de estimativas robustas e a realização de testes de hipóteses (Casella; Robert, 2008; Liu; Liu, 2001; Rubinstein; Kroese, 2016).

Conforme os autores Anselin (1995), Câmara et al. (2004), Luzardo, Castañeda Filho e Rubim (2017), Jung, Thill e Issel (2019), no contexto do Teste de Geary, o método de Monte Carlo é frequentemente utilizado para avaliar a significância estatística do resultado.

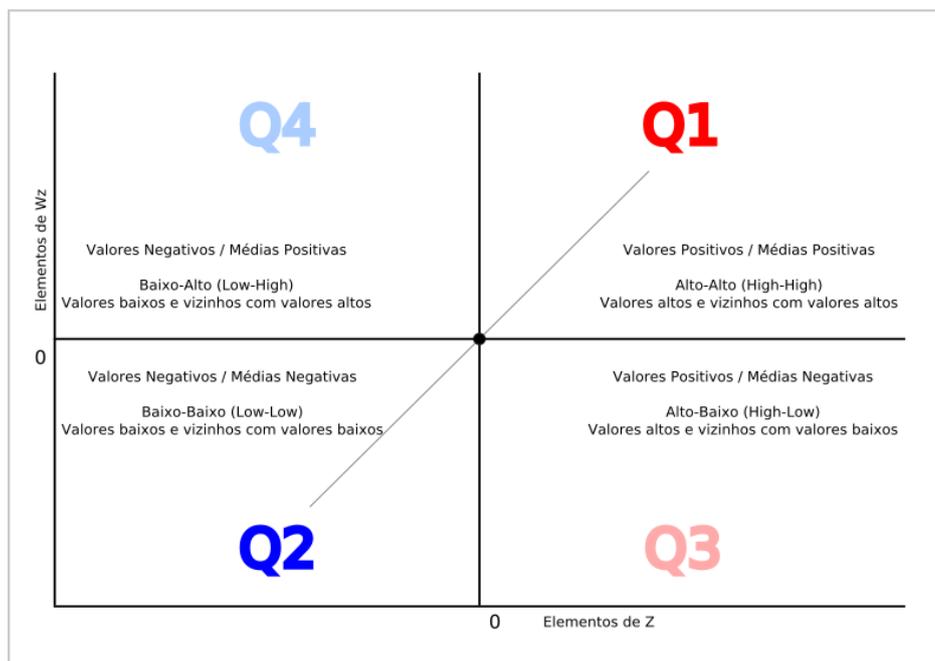
Ao realizar o Teste Global de Autocorrelação Espacial de Geary, a estatística calculada (Geary's C) é comparada com uma distribuição de valores que seria esperada ao acaso. O Monte Carlo é empregado gerando repetidamente conjuntos de dados simulados (mantendo a estrutura espacial original) e recalculando a estatística de interesse para construir uma distribuição de referência. A comparação entre a estatística observada e a distribuição simulada permite determinar se a autocorrelação espacial é estatisticamente significativa.

Em resumo, o método de Monte Carlo é utilizado para validar estatisticamente os resultados do Teste de Geary, fornecendo uma abordagem robusta para inferir a presença de autocorrelação espacial nos dados analisados.

### 3.4.3 Diagrama de Espalhamento do Índice de Moran e Mapa de Clusters LISA

O Diagrama de Espalhamento do Índice de Moran – também referenciado como Moran Scatterplot – é uma representação gráfica que mostra a relação entre os valores de uma variável em diferentes locais e seus respectivos valores médios ponderados pela estrutura espacial dos dados. Essa visualização ajuda a identificar padrões de autocorrelação espacial, indicando se os valores estão agrupados em clusters ou distribuídos de forma aleatória. A Figura 2 exemplifica o Diagrama de Espalhamento do Índice de Moran, conforme apresentado pelos autores Anselin (1995), Câmara et al. (2004), dos Santos e Raia Junior (2006), e Luzardo, Castañeda Filho e Rubim (2017).

O diagrama é dividido em quatro quadrantes. Cada ponto no gráfico representa uma unidade espacial (por exemplo um local geográfico ou um setor censitário) e está posicionado de acordo com seu valor na variável de interesse e o valor médio ponderado dos seus vizinhos.



**Figura 2.** Diagrama de Espalhamento do Índice de Moran Local. Fonte: Elaboração própria com base em Dos Santos e Raia Junior (2006).

#### 3.4.4 Quadrantes de Autocorrelação Espacial:

- Quadrante Superior Direito (Alto-Alto): Indica áreas com valores altos cercadas por áreas com valores altos, sugerindo autocorrelação espacial positiva. Isso significa que locais com altos valores tendem a estar próximos a outros locais com altos valores.
- Quadrante Inferior Esquerdo (Baixo-Baixo): Indica áreas com valores baixos cercadas por áreas com valores baixos, também sugerindo autocorrelação espacial positiva, mas para valores baixos.
- Quadrante Superior Esquerdo (Alto-Baixo): Indica áreas com valores altos cercadas por áreas com valores baixos, sugerindo autocorrelação espacial negativa. Locais com altos valores estão próximos a locais com baixos valores.
- Quadrante Inferior Direito (Baixo-Alto): Indica áreas com valores baixos cercadas por áreas com valores altos, sugerindo autocorrelação espacial negativa para valores baixos.

Padrões espaciais de agrupamentos e dispersões observados por pontos no diagrama ajuda na interpretação dos resultados. Padrões semelhantes em um quadrante indicam a presença de autocorrelação espacial. A interpretação final deve levar em consideração o contexto específico da análise e do fenômeno estudado, considerando aspectos geográficos e características locais.

Em resumo, a leitura do Diagrama de Espalhamento do Índice de Moran envolve a identificação de padrões e tendências espaciais, fornecendo insights sobre a autocorrelação espacial nos dados analisados.

#### 3.4.5 Mapa de Clusters LISA

O Mapa de Clusters LISA (Local Indicators of Spatial Association) é uma ferramenta cartográfica utilizada para identificar padrões significativos de agrupamento espacial em dados geográficos. Conforme os autores Anselin (1995), Câmara et al. (2004), dos Santos e Raia Junior (2006), e Luzardo, Castañeda Filho e Rubim (2017) para interpretar corretamente um Mapa de Clusters LISA há certas orientações:

- **Cores e Símbolos:** Diferentes cores ou símbolos são usados para representar diferentes tipos de clusters espaciais. Geralmente, áreas com valores altos e estatisticamente significativos são destacadas com cores distintas das áreas com valores baixos ou não significativos.

- **Hotspots e Coldspots:** Os clusters identificados podem ser classificados em hotspots (pontos quentes) e coldspots (pontos frios). Hotspots representam áreas onde os valores da variável são significativamente altos e estão cercados por valores altos semelhantes, indicando uma concentração de valores elevados. Coldspots, por outro lado, representam áreas com valores significativamente baixos em comparação com seus vizinhos.
- **Padrões Espaciais:** Permite identificar padrões espaciais relevantes, como áreas de concentração, dispersão ou aleatoriedade dos valores da variável em estudo. A identificação desses padrões ajuda a compreender a distribuição geográfica dos fenômenos analisados e a destacar áreas de interesse para investigações adicionais.
- **Significância Estatística:** Além das cores ou símbolos que representam os clusters, é importante considerar a significância estatística dos padrões identificados. Os clusters destacados no mapa devem ser estatisticamente significativos para garantir que não sejam resultado de variações aleatórias nos dados.
- **Interpretação Contextual:** A interpretação deve ser feita considerando o contexto do estudo e o conhecimento prévio sobre o fenômeno em análise. É essencial entender o significado dos clusters identificados e como essas áreas podem influenciar ou ser influenciadas por processos espaciais.

Em resumo, a leitura do Mapa de Clusters LISA envolve a análise das cores, símbolos e padrões espaciais representados no mapa, a identificação de hotspots e coldspots, a consideração da significância estatística dos clusters e a interpretação contextual dos resultados.

#### 3.4.6 Integração do Diagrama de Espalhamento e Mapa de Clusters LISA

Ao combinar o Diagrama de Espalhamento do Índice de Moran com o Mapa de Clusters LISA, os analistas podem obter uma compreensão mais abrangente dos padrões espaciais em seus dados. O diagrama proporciona uma visão global da autocorrelação espacial, enquanto o mapa destaca áreas específicas com clusters significativos, permitindo uma análise mais detalhada e identificação de padrões locais. Essas ferramentas são valiosas para pesquisadores e profissionais que buscam entender a distribuição espacial de fenômenos, identificar áreas de concentração e apoiar a tomada de decisões em diferentes campos.

Mais detalhes metodológicos de como aprofundaremos nossa compreensão do indicador de violência CVLI serão abordados neste estudo. Exploraremos a transformação de dados por meio do estimador de densidade de Kernel e a aplicação da autocorrelação espacial de Moran, detalhando minuciosamente o processo adotado para enriquecer nossa análise do indicador de violência CVLI.

## 4. Materiais e Métodos

### 4.1 Procedimentos e Ferramentas

Todos os procedimentos foram realizados na linguagem de programação R (versão 4.3) utilizando o ambiente RStudio. Para análises espaciais e estatísticas, foram empregadas diversas bibliotecas, tais como "ggplot2", "ggspatial", "lattice", "patchwork", "RColorBrewer", "raster", "rasterVis", "sf", "sp", "spdep", "stars", "terra", "tidyterra", "tidyverse" e "viridis". Estas bibliotecas proporcionam funcionalidades abrangentes para a manipulação de dados espaciais, análises estatísticas e visualização, contribuindo assim para a condução eficiente e robusta das análises propostas neste estudo (Brunsdon, 2014; Chun; Griffith, 2013; Duong, 2007; Mendez, 2020).

### 4.2 Análise de Autocorrelação Espacial

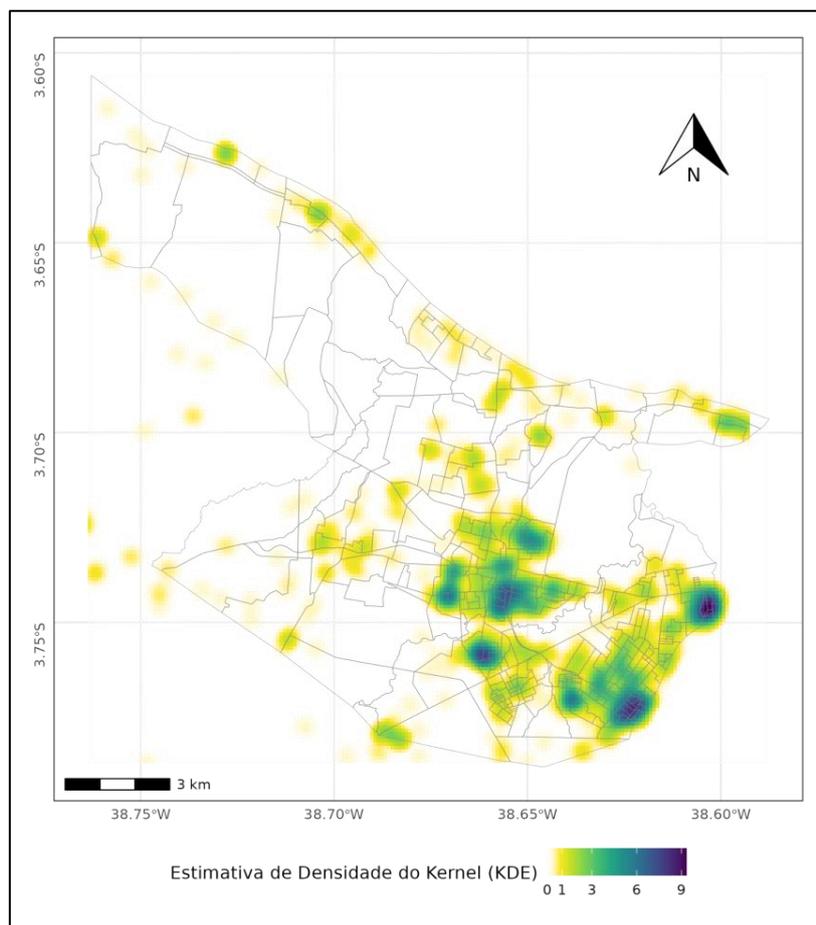
A realização de uma análise de autocorrelação espacial, abordando tanto a perspectiva global quanto a local, demanda a observância de uma sequência de etapas delineadas por autores renomados, como Moran (1950), Anselin (1995) e Anselin (2004), e aplicadas por estudiosos como Imro'ah et al. (2023), Luzardo, Castañeda Filho e Rubim (2017), Sparks (2013), Oliveira, Medeiros e Carvalho (2017), dentre outros citados neste estudo. Essas etapas representam um arcabouço essencial para compreender os padrões espaciais nos dados analisados. No presente trabalho, adotaram-se as seguintes etapas:

#### 4.3 Definição do objeto de estudo e aquisição e preparação dos dados

Antes de iniciar a análise da autocorrelação espacial do Índice CVLI, foi realizada a transformação dos dados para a unidade territorial da Malha dos Setores Censitários do IBGE (2010), com o recorte da área urbana do município de Caucaia. Esse procedimento envolveu a conversão dos dados para corresponder à delimitação geográfica dos Setores Censitários estabelecidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE) em 2010.

A criação de uma matriz de densidade revelou-se crucial diante da natureza pontual dos dados do índice CVLI, que se manifestam de maneira discreta no espaço. Essa abordagem visa aprimorar a robustez e precisão da análise (Armstrong, 2022; Cheruiyot, 2022). A elaboração da Matriz de Estimativa de Densidade do Kernel (raster KDE), com um raio de 500 metros, fundamentou-se na necessidade de suavizar a representação espacial, proporcionando a visualização e interpretação de padrões mais refinados e informativos relacionados ao fenômeno em estudo (Carvalho; Nascimento, 2014 Queiroz et al., 2010)

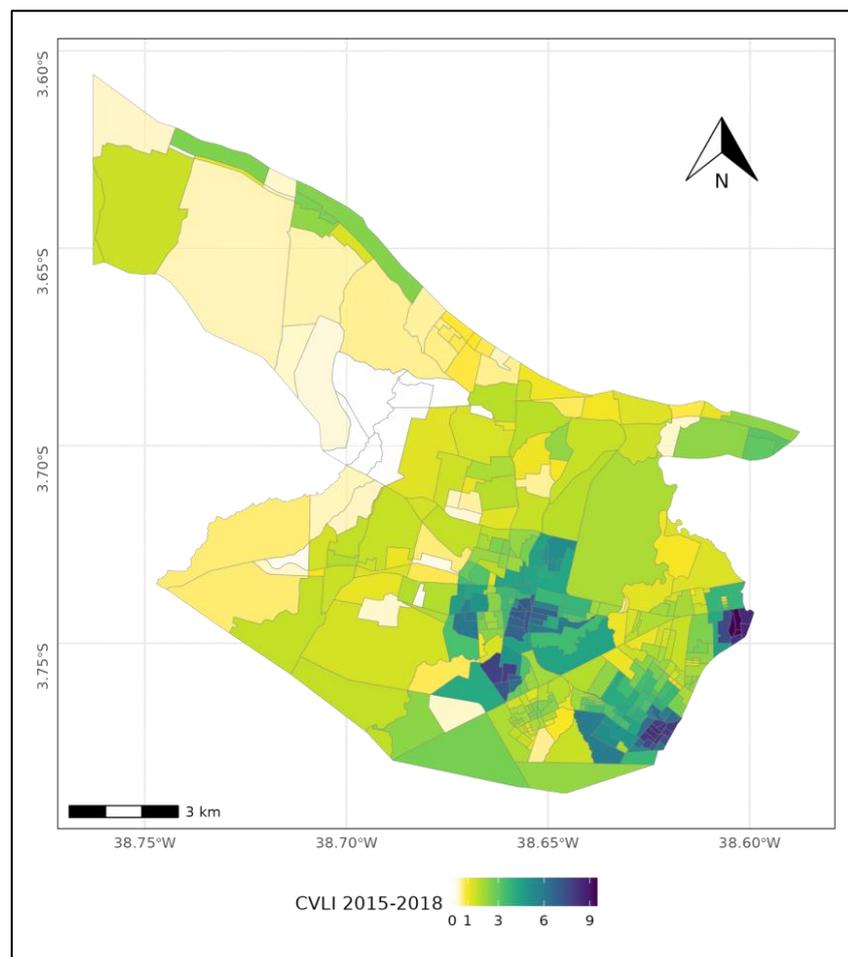
Ao optar por uma largura de banda ajustada de 500 metros, procurou-se capturar a influência espacial em uma escala que reflete de forma mais precisa a dinâmica do fenômeno em análise. A seleção criteriosa desse parâmetro específico está alinhada com a imperativa consideração da proximidade geográfica entre os eventos, promovendo uma representação mais fidedigna da distribuição espacial do fenômeno na área de estudo (Figura 3).



**Figura 3.** Mapa de Estimativa de Densidade do Kernel - CVLI acumulado (2015-2018). **Fonte:** Elaboração própria com base nos dados CVLI (SUPESP).

O mapa da Figura 3, que abrange densidades de 0 a 9, fornece uma visão abrangente da distribuição espacial, destacando áreas de concentração e dispersão. Os valores mais elevados predominam na parte central da área urbana e na porção sudeste (limite entre a área urbana de Caucaia e o município de Fortaleza). A abordagem passiva do KDE suaviza variações locais, proporcionando uma compreensão refinada da distribuição de densidade em todo o espaço geográfico analisado.

Posteriormente, o raster foi submetido a técnicas específicas de geoprocessamento, culminando na realização do geoprocesso de estatísticas zonais, concentrado na extração passiva do valor máximo do raster para uma área demarcada por um polígono. Ao efetuar essa adaptação, os pesquisadores tornam os dados do fenômeno compatíveis com a estrutura espacial dos Setores Censitários, possibilitando, assim, uma análise mais precisa da autocorrelação espacial (Carvalho; Nascimento, 2014; Da Costa et al., 2022). A Figura 4 ilustra o Mapa do CVLI acumulado (2015-2018), no qual os valores do produto matricial (KDE) foram extraídos e atribuídos aos Setores Censitários.



**Figura 4.** Mapa do CVLI acumulado (2015-2018) para os setores censitários. **Fonte:** Elaboração própria com base na Malha dos Setores Censitários (IBGE, 2010) e dados CVLI (SUPESP).

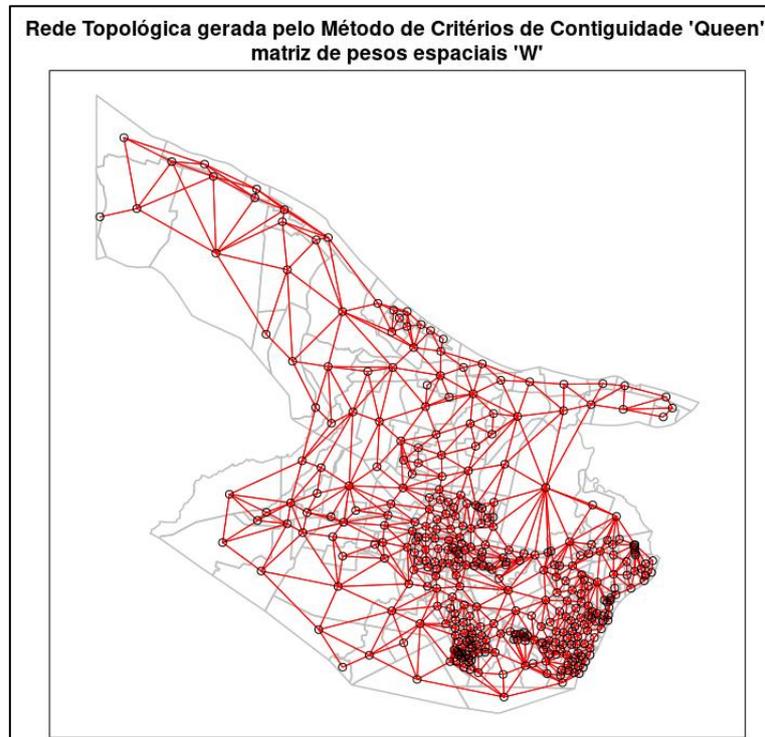
#### 4.4 Construção da Matriz de Vizinhança

##### 4.4.1 Matriz de Pesos Espaciais (W) e Método de Contiguidade Queen

A conectividade espacial entre unidades geográficas, como municípios, setores censitários ou outros polígonos geográficos, é representada pela matriz de pesos espaciais (W). Os autores Anselin (1995), Chun e Griffith (2013) bem como Mendez (2020) apontam que a relação de proximidade ou contiguidade entre essas unidades é expressa por esta matriz. A definição desta matriz pode variar e a escolha do método pode ter impacto nas análises espaciais. No âmbito do estudo em questão, o método "Queen" foi empregado. No Método de Contiguidade Queen, cada unidade geográfica (neste exemplo, setor censitário) é considerada conectada às suas vizinhas, aquelas que compartilham uma fronteira ou um vértice. Os valores binários (1 se conectado, 0 se não) na matriz resultante refletem essa conectividade espacial.

##### 4.4.2 Mapa de Conectividade Espacial

Uma visualização das conexões espaciais entre setores censitários foi possibilitada pelo Mapa de Conectividade Espacial, utilizando o método de “Contiguidade Queen”. Os setores censitários conectados foram destacados em vermelho, proporcionando insights visuais sobre a estrutura de conectividade espacial na área de estudo (Figura 5). A compreensão da estrutura da conectividade espacial foi facilitada por esse tipo de visualização.



**Figura 5.** Mapa de Conectividade Espacial. **Fonte:** Elaboração própria.

#### 4.5 Cálculo do Índice de Moran Global

Nesta etapa, uma vez determinada a estrutura espacial de análise, expressa pela Matriz de Vizinhança (W), realiza-se o cálculo do Índice de Moran Global, que proporciona uma visão geral da distribuição espacial da variável em estudo (Luzardo; Castañeda Filho; Rubim, 2017; Moran, 1950), descrevendo modelos de dependência espacial de alcance global que se caracterizam pela dependência espacial que possui transbordamento global, ou seja, o multiplicador espacial possui um impacto sobre a variável dependente que é refletido para todas as regiões incluídas no modelo (Almeida, 2012).

#### 4.6 Identificação de Padrões Locais

Após o cálculo do índice global, a atenção se volta para a identificação de padrões locais por meio do Índice de Moran Local. Esta análise permite a detecção de clusters espaciais de alta ou baixa concentração dos valores da variável, contribuindo para uma compreensão mais detalhada da autocorrelação (Anselin, 1995). Nos modelos de dependência local, o alcance da dependência espacial é observado apenas em algumas áreas, especialmente vizinhos diretos e indiretos (Almeida, 2012).

## 5. Resultados

Nesta seção, apresentamos os resultados da análise de autocorrelação espacial global (Moran's I, Geary's C, Monte-Carlo) e da análise de autocorrelação espacial local (Moran's I local, com o emprego do Mapa de Clusters LISA). Os trabalhos abordam:

### 5.1. Testes de Autocorrelação Espacial Global

Foram conduzidos três testes para avaliar a autocorrelação espacial global dos índices de criminalidade.

O teste de Moran's I foi conduzido para avaliar a autocorrelação espacial global nos valores de CVLI. Os resultados apontam para uma forte autocorrelação espacial, evidenciada pelo Moran I statistic de 0,790897102. O p-value associado a este teste é extremamente baixo ( $p\text{-value} < 2,2e-16$ ), indicando uma rejeição significativa da hipótese nula de ausência de autocorrelação espacial. Os valores da expectativa (Expectation) e variância (Variance) do Moran I statistic são -0,002816901 e 0,001015713, respectivamente.

O teste de Geary's C também foi empregado para analisar a autocorrelação espacial global. Os resultados revelam um Geary C statistic de 0,201921311. Similar ao teste de Moran's I, o p-value é muito baixo ( $p\text{-value} < 2,2e-16$ ), indicando forte evidência contra a hipótese nula. A expectativa e variância associadas ao Geary C statistic são 1,000000000 e 0,001362475, respectivamente.

Uma abordagem de Monte-Carlo foi adotada para complementar os resultados dos testes anteriores. Os resultados da simulação de Monte-Carlo indicam um valor de estatística de 0,7909, com um rank observado de 1.000 e um p-value de 0,001. Esses resultados sustentam as conclusões dos testes de Moran's I e Geary's C, reforçando a presença de uma significativa autocorrelação espacial global nos índices de criminalidade.

## 5.2. Autocorrelação Espacial Local (Moran's I local com Mapa de Clusters LISA)

A Figura 6 destaca os resultados da análise de autocorrelação espacial local. Padrões locais de autocorrelação são revelados pelo mapa de clusters LISA, identificando áreas com uma alta concentração de valores similares (clusters espaciais). Os clusters persistentes nesse nível merecem atenção especial, com um nível de significância de 5%.

Observa-se que o padrão nas áreas classificadas como 'Alto-Alto' é focalizado na porção central e leste da área de estudo, sugerindo que valores elevados do indicador CVLI são exibidos por essas regiões. Valores altos também são apresentados por seus vizinhos, indicando uma concentração espacial de características semelhantes nos setores censitários referidos.

A distribuição das áreas classificadas como 'Baixo-Baixo' é dividida em dois núcleos distintos. Um desses núcleos está situado ao norte do centro da área de estudo, enquanto o outro está localizado no extremo norte. Setores censitários com valores 'Baixo-Alto' intercalam esses núcleos, indicando padrões específicos de baixa concentração de valores similares nessas regiões. Características distintas para esses setores censitários são sugeridas, destacando a complexidade na distribuição espacial dos indicadores.

Além disso, é relevante notar que os setores censitários com valores 'Alto-Baixo' estão concentrados nas cercanias dos setores classificados como 'Alto-Alto', sugerindo uma influência ou relação espacial entre as áreas de alta e baixa concentração de indicadores. Uma visão mais abrangente da dinâmica espacial na área de estudo é proporcionada por essa observação. Insights adicionais sobre a distribuição espacial dos índices de criminalidade na área de estudo foram fornecidos por meio dessa análise aprimorada. Além de evidenciar áreas de dissimilaridade espacial (outliers), essas informações proporcionam uma compreensão da dependência espacial (Figura 6).

As áreas destacadas em cinza no mapa (Figura 6) representam regiões de insignificância estatística, indicando que os padrões encontrados nesses locais não são estatisticamente relevantes. Em contraste com as áreas coloridas que denotam padrões de alta concentração ('Alto-Alto' e 'Baixo-Baixo'), as áreas em cinza sugerem que as variações nos índices de criminalidade observadas nessas regiões não são estatisticamente distintas do que seria esperado ao acaso.

Essas áreas de insignificância estatística podem resultar de diversos fatores, como a distribuição heterogênea dos dados ou a falta de consistência nos padrões espaciais. Em termos práticos, isso significa que, do ponto de vista estatístico, não há evidências sólidas de que essas regiões exibam comportamentos significativamente diferentes do que seria esperado de uma distribuição aleatória.

Essa diferenciação visual entre áreas significativas e insignificantes é crucial para uma interpretação mais precisa dos resultados. Enquanto as áreas coloridas podem representar concentrações reais de padrões de criminalidade, as áreas em cinza indicam que as variações nesses locais podem ser simples flutuações aleatórias. Portanto, a ênfase na análise deve ser direcionada para as áreas coloridas, onde padrões estatisticamente relevantes e dignos de atenção estão concentrados.

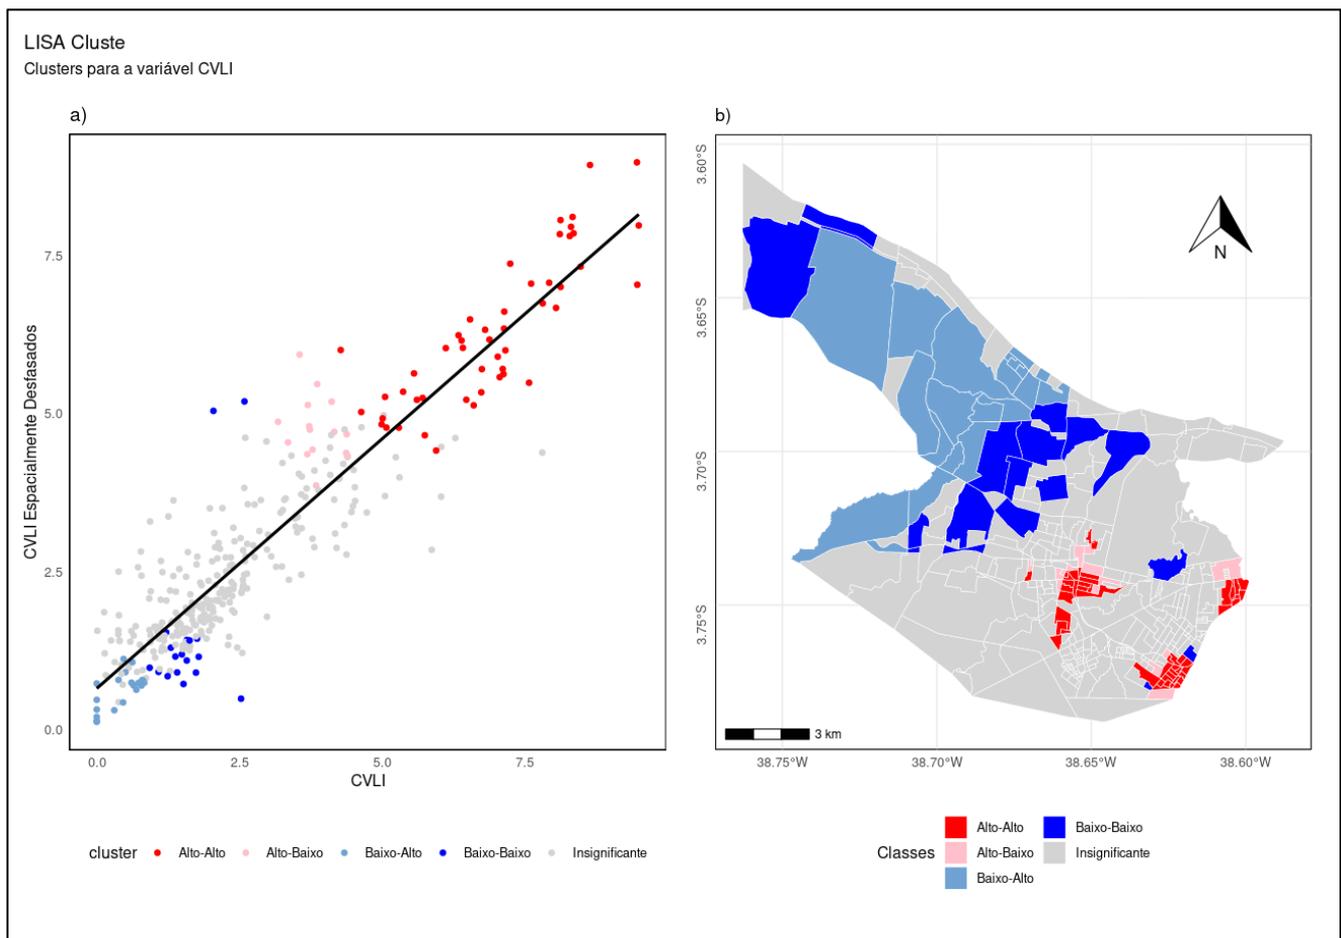


Figura 6. Mapa de clusters LISA. Fonte: Elaboração própria

## 6. Discussão e Considerações Finais

Este estudo, que emprega uma abordagem robusta de análise espacial do Índice de Criminalidade Violenta Letal e Intencional (CVLI) na área urbana de Caucaia, proporcionou insights significativos sobre a distribuição espacial desses índices. Os resultados encontrados para o município de Caucaia, corroboram com trabalhos semelhantes que também se utilizaram de técnicas geoestatísticas de análise espacial, aplicados em dados de criminalidade e informações sociais para a cidade de Fortaleza, como no exemplo dos trabalhos de Magalhães et al., (2024) e Oliveira, Medeiros e Carvalho (2017). Este último destacou que pequenas áreas urbanas com altas (baixas) taxas de crimes violentos têm vizinhos, em média, com padrão semelhante de taxas de crimes violentos. O mesmo encontrado para Caucaia nesta pesquisa.

Outro trabalho que também encontrou padrões de correlação espacial parecido foi desenvolvido para os municípios de Minas Gerais, onde os autores, utilizando as técnicas de autocorrelação espacial global e local (Moran's I), identificaram que, municípios com altos valores de cada tipo de crime tendem a estar próximos de municípios também com os mesmos índices em níveis similares de modalidade de criminalidade, e/ou municípios com baixos valores tendem a estar próximos de municípios que também apresentam baixos valores, efeito que os autores chamaram de "padrão de Transbordamento". (GOMES et al., 2017).

Já a metodologia detalhada, baseada na linguagem de programação R e em bibliotecas especializadas como "ggplot2", "sf", "spdep", entre outras, revelou-se instrumental para a manipulação eficiente e análise estatística dos dados espaciais.

### 6.1. Padrões de Autocorrelação

A análise de autocorrelação espacial global indicou fortes padrões espaciais nos índices de CVLI, conforme evidenciado pelos resultados dos testes de Moran's I, Geary's C e Monte-Carlo. A significativa autocorrelação

espacial global sugere a presença de clusters espaciais e a influência de fatores locais na ocorrência desses eventos criminais.

### 6.2. Clusters Espaciais Identificados por LISA

Os resultados da análise de autocorrelação espacial local, apresentados no Mapa de Clusters LISA (FIGURA 7), oferecem uma visão mais aprofundada da distribuição espacial. O padrão identificado nas áreas classificadas como 'Alto-Alto', localizado principalmente na porção central, leste e sudeste da área de estudo, aponta para a presença de locais com valores elevados do indicador CVLI e a proximidade dessas áreas com valores similares. Vale a pena destacar que nos trabalhos de Magalhães et al., (2024) desenvolvido para Fortaleza, cidade que faz fronteira com Caucaia, foi verificado clusters que concentravam dados de maiores criminalidades justamente em áreas vizinhas aos clusters do setor sudeste da área de estudo, revelando que mesmo se tratando de cidades diferentes, a influência permanece devido ao fator de proximidade e influência entre as áreas que possuem características semelhantes.

Adicionalmente, observamos a existência de áreas classificadas como 'Baixo-Baixo' em dois núcleos distintos, situados ao norte do centro e no extremo norte, intercalados por setores censitários 'Baixo-Alto', destacando a complexidade na distribuição espacial dos índices de criminalidade. Notavelmente, as áreas classificadas como 'Alto-Baixo' circundam as áreas classificadas como 'Alto-Alto', apresentando uma dinâmica espacial intrincada entre essas duas categorias de setores.

Como já mencionado, na área urbana de Caucaia, foram registrados 897 casos de CVLI. Ao analisar a interseção espacial desses casos com os setores censitários classificados como 'Alto-Alto' e 'Alto-Baixo', identificamos que 287 casos ocorreram nesses 'clusters', representando 31,9% do total. Embora essas áreas representem apenas 3,93% (6,95 km<sup>2</sup>) da extensão total da área urbana de Caucaia, que é de 176,93 km<sup>2</sup>, elas concentram uma significativa proporção das ocorrências. Essa discrepância destaca a necessidade de abordagens específicas nessas áreas, considerando não apenas os números absolutos, mas também a relação com a área total em km<sup>2</sup>.

### 6.3. Implicações para Políticas Públicas e Segurança

Os resultados obtidos podem ser usados em possíveis implicações práticas para a tomada de decisões em políticas públicas e estratégias de segurança. A identificação de padrões espaciais permite uma abordagem mais direcionada na alocação de recursos e implementação de medidas preventivas. A compreensão da dinâmica espacial da criminalidade é fundamental para o desenvolvimento de estratégias eficazes e intervenções específicas em áreas de maior vulnerabilidade.

Ao que se entende como a atual conjuntura criminosa no nosso estado, e não estar mais correlacionada, em sua quase totalidade às desigualdades sociais, em virtude da forte atuação das organizações criminosas e suas dinâmicas; a solução para esse desafio associado às áreas urbanas de todas as escalas geográficas ainda perpassa pela promoção da qualidade de vida ao cidadão cearense.

### 6.4. Continuidade e Limitações da Pesquisa

A continuidade deste estudo é essencial para uma compreensão mais abrangente do fenômeno criminal em Caucaia. Além da análise espacial, a exploração de dinâmicas temporais e fatores socioeconômicos pode oferecer insights adicionais. Investigar padrões ao longo do tempo e examinar influências socioeconômicas contribuirá para o desenvolvimento de estratégias mais eficazes e políticas direcionadas às raízes estruturais do problema. A pesquisa contínua é crucial para uma abordagem holística e informada na compreensão e enfrentamento da criminalidade na região. Por outro lado, como limitação dessa pesquisa, pode-se indicar a não inserção de dados sociais e de renda para verificar padrões de correlação e efeito de influência nos dados criminais, como realizado nos trabalhos de Oliveira, Medeiros e Carvalho (2017), Gomes et al., (2017) e Magalhães et al. (2024). A inserção dessas variáveis contribui com uma melhor discussão do fenômeno da criminalidade, pois a literatura tem defendido que fenômenos sociais (renda, desigualdade social, densidade demográfica, educação etc.) são fatores que podem contribuir ou diminuir eventos violentos e de criminalidade.

Aliado a inserção de outras variáveis afim de verificar o efeito delas sobre o crime, os autores acima ainda aplicaram técnicas mais robustas, como no caso das técnicas de regressão e regressão geograficamente ponderada. Esse processo seguinte de aplicação de outras técnicas, poderia ampliar mais o conhecimento da dinâmica do crime no município de Caucaia, além de dar mais subsídios para a discussão de políticas públicas.

**Contribuições dos Autores:** Concepção, Flávio Moreira Jr e Aryberg de Souza Duarte; metodologia, Flávio Moreira Jr, Aryberg de Souza Duarte e Marcelo Davi Santos; software, Flávio Moreira Jr e Aryberg de Souza Duarte; validação, todos os autores; análise formal, Flávio Moreira Jr, Aryberg de Souza Duarte e Marcelo Davi Santos; pesquisa, todos os autores; recursos, RStudio; preparação de dados, Flávio Moreira Jr e Aryberg de Souza Duarte; escrita do artigo, todos os autores; revisão, Marcelo Davi Santos, Paula Alves Tomaz e Wagner Vinicius Amorin; supervisão, Wagner Vinicius Amorin; sem aquisição de financiamento. Todos os autores leram e concordaram com a versão publicada do manuscrito.

**Financiamento:** Esta pesquisa não recebeu nenhum financiamento externo.

**Agradecimentos:** Para a elaboração desse estudo foi relevante o apoio de pessoas que acreditaram na importância do estudo, e de fato fizeram diferença para a consolidação dos dados analisados. O trabalho de cada um dos envolvidos foi fundamental para a construção deste estudo de extrema relevância, e possibilitou a realização de mais um estudo publicado pelo Programa de Pós-Graduação em Geografia da Universidade Estadual do Ceará, ProPGeo/UECE; Laboratório de Estudos Urbanos e Geografia das Cidades, LEURC/UECE; Programa de Pós-Graduação em Economia da Universidade Federal do Ceará, CAEN/UFC; Universidade Regional do Cariri, URCA; e pela Superintendência de Pesquisa e Estratégia de Segurança Pública (SUPESP/SSPDS-CE). Os dados apresentados sob uma perspectiva dos indicadores criminais servirão como base de consulta para estudantes, pesquisadores, especialistas, legisladores, dentre outros interessados na temática auferida. Ademais, nossa gratidão e agradecimentos, aos amigos e servidores públicos das entidades aqui supracitadas, que foram essenciais nos debates e considerações referentes à temática da Violência e Criminalidade (V&C) e a produção final deste estudo.

**Conflito de Interesse:** Os autores declaram não haver conflito de interesse.

## Referências

1. ALMEIDA, E. **Econometria Espacial Aplicada**. Alínea: Campinas: SP, 2012.
2. ANSELIN, Luc. **GeoDa™ 0.9 User's Guide**. Spatial Analysis Laboratory, Department of Agricultural and Consumer Economics, University of Illinois, Urbana-Champaign, 2004.
3. ANSELIN, Luc. **Local indicators of spatial association – LISA**. *Geographical analysis*, v. 27, n. 2, p. 93-115, 1995.
4. ANSELIN, Luc et al. Spatial analyses of crime. *Criminal justice*, v. 4, n. 2, p. 213-262, 2000.
5. ANSELIN, Luc; SRIDHARAN, Sanjeev; GHOLSTON, Susan. Using exploratory spatial data analysis to leverage social indicator databases: the discovery of interesting patterns. *Social Indicators Research*, v. 82, p. 287-309, 2007.
6. ARLINGHAUS, Sandra (Ed.). **Practical handbook of spatial statistics**. CRC press, 2020.
7. ARMSTRONG, Karolina Chacon. Análise espacial da violência no estado do Rio de Janeiro nos anos de 2010, 2014 e 2018 através do estimador de densidade de Kernel e autocorrelação espacial de Moran. **Trabalho de Conclusão de Curso (Bacharelado em Geografia)–Departamento de Geografia, Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro**, 2022.
8. BRUNSDON, Chris; COMBER, Lex. **An introduction to R for spatial analysis and mapping**. Sage, 2014.
9. BURT, James E.; BARBER, Gerald M.; RIGBY, David L. **Elementary statistics for geographers**. Guilford Press, 2009.
10. CARVALHO, Renata Marzzano de; NASCIMENTO, Luiz Fernando Costa. Space-time description of dengue outbreaks in Cruzeiro, Sao Paulo, in 2006 and 2011. *Revista da Associação Médica Brasileira*, v. 60, p. 565-570, 2014.
11. CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V.2 (2004) Análise espacial de áreas. In: FUKS, S.D.; CARVALHO, M.S.; CÂMARA, G. (Orgs.) Análise espacial de dados geográficos. Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/analise/cap5-areas.pdf>>. Acesso em: 15 out. 2023.
12. CASELLA, George; ROBERT, C. **Monte Carlo statistical methods**. University of Florida, 2008.
13. CHERUIYOT, Koech. Detecting spatial economic clusters using kernel density and global and local Moran's I analysis in Ekurhuleni metropolitan municipality, South Africa. *Regional Science Policy & Practice*, v. 14, n. 2, p. 307-327, 2022.
14. CHUN, Yongwan; GRIFFITH, Daniel A. **Spatial statistics and geostatistics: theory and applications for geographic information science and technology**. Sage, 2013.
15. CRESSIE, Noel. Geostatistical analysis of spatial data. *Spatial statistics and digital image analysis*, v. 1991, p. 87-108, 1991.
16. CRESSIE, Noel. **Statistics for spatial data**. John Wiley & Sons, 2015.

17. DA COSTA, Flávia Regina Vieira et al. Análise espacial de casos prováveis de dengue no município de São Luís, Maranhão, Brasil. **Arquivos de Ciências da Saúde da UNIPAR**, v. 26, n. 3, 2022.
18. DE LIMA, Maria Luiza C. et al. Conglomerados de violência em Pernambuco, Brasil. **Revista Panamericana de Saúde Pública**, v. 18, p. 122-128, 2005.
19. DE LIMA, Maria Luiza C. et al. Spatial analysis of socioeconomic determinants of homicide in Brazil. **Revista de saúde pública**, v. 39, p. 176-182, 2005.
20. DE MELO, Silas Nogueira; MATIAS, Lindon Fonseca. Geografia do Crime e da Violência no Brasil entre 2007 a 2015. **Revista da ANPEGE**, v. 12, n. 19, p. 146-165, 2016.
21. DE SMITH, Michael John; GOODCHILD, Michael F.; LONGLEY, Paul. **Geospatial analysis: a comprehensive guide to principles, techniques and software tools**. Troubador publishing ltd, 2007.
22. DOS SANTOS, Luciano; RAIÁ JUNIOR, Archimedes Azevedo. Análise espacial de dados geográficos: a utilização da Exploratory Spatial Data Analysis-ESDA para identificação de áreas críticas de acidentes de trânsito no município de São Carlos (SP). **Sociedade & Natureza**, v. 18, n. 35, p. 97-107, 2006.
23. DUONG, Tarn. ks: Kernel density estimation and kernel discriminant analysis for multivariate data in R. **Journal of statistical software**, v. 21, p. 1-16, 2007.
24. ENTRIKIN, J. Nicholas. Robert park's human ecology and human geogrpny. **Annals of the Association of American Geographers**, v. 70, n. 1, p. 43-58, 1980.
25. FOTHERINGHAM, A. Stewart; BRUNSDON, Chris; CHARLTON, Martin. **Quantitative geography: perspectives on spatial data analysis**. Sage, 2000.
26. FURTADO, Lara; RENSKI, Henry. Place attachment in self-built informal housing: improving spaces of crime. **Journal of Housing and the Built Environment**, v. 36, p. 283-301, 2021.
27. GATRELL, Anthony C.; BAILEY, T. C. Interactive spatial data analysis in medical geography. **Social science & medicine**, v. 42, n. 6, p. 843-855, 1996.
28. GETIS, Arthur; ORD, J. Keith. The analysis of spatial association by use of distance statistics. **Geographical analysis**, v. 24, n. 3, p. 189-206, 1992.
29. GOMES, Carlos Eduardo; EVANGELISTA, Thamirys Figueredo; LIMA, Renata Lemos; PARRÉ, José Luiz. Determinantes do crime nos municípios de Minas Gerais e seus possíveis spillovers espaciais. *Economia-Ensaios, Uberlândia*, 31 ( 2 ): 201-228, Jan./Jun. 2017.
30. GUPTA, Akhil; FERGUSON, James (Ed.). **Culture, power, place: Explorations in critical anthropology**. duke University press, 1997.
31. HARKNESS, Alistair; HARRIS, Bridget; BAKER, David. **Locating crime in context and place: Perspectives on regional, rural and remote Australia**. Federation Press, 2016.
32. IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Brasileiro de 2010**. Setor Censitário 2010. Mapas, bases e referenciais, bases cartográficas, malhas digitais. 2010.
33. IMRO'AH, Nurfitri et al. Hybrid ARIMA-Spatial Autocorrelation (Moran Index and LISA) for Covid-19 Vaccination in All Indonesian Provinces. **Jambura Journal of Biomathematics (JJBM)**, v. 4, n. 2, p. 126-137, 2023.
34. JUNG, Paul H.; THILL, Jean-Claude; ISSEL, Michele. Spatial autocorrelation statistics of areal prevalence rates under high uncertainty in denominator data. **Geographical Analysis**, v. 51, n. 3, p. 354-380, 2019.
35. LIU, Jun S.; LIU, Jun S. **Monte Carlo strategies in scientific computing**. New York: springer, 2001.
36. LOPES, Paulo Cícero Borges; PEREIRA, Luiz Andrei Gonçalves. Análise espacial do índice de vulnerabilidade social nas novas divisões regionais do Estado de Minas Gerais-Brasil. **Revista Ateliê Geográfico**, v. 16, n. 3, 2022.
37. LUZARDO, Antonio José Rocha; CASTAÑEDA FILHO, Rafael March; RUBIM, Igor Brum. Análise espacial exploratória com o emprego do Índice de Moran. **GEOgraphia**, v. 19, n. 40, p. 161-179, 2017.
38. MAGALHÃES, Marcos Renan Vasconcelos; SILVA, Felipe Pinto da; MENDONÇA NETO, Aguiamar; SANTOS, Marcelo Davi; PENNA, Christiano Modesto. A criminalidade tomou conta da cidade: o cinturão de insegurança em Fortaleza, Ceará. *Revista Brasileira de Estudos Regionais e Urbanos*. V. 18, n. 1, p. 118-149, 2024.
39. MARCONATO, Marcio; BRAMBILLA, Marcos Aurélio; DO NASCIMENTO, Sidnei Pereira. Análise espacial do nível de desenvolvimento dos municípios do estado do Paraná. **Economia & Região**, v. 3, n. 1, p. 81-102, 2015.
40. MENDEZ, C. Spatial autocorrelation analysis in R. **R Studio/RPubs**. 2020. Disponível em: <<https://rpubs.com/quarcs-lab/spatial-autocorrelation>>. Acessado em: 10 mai. 2023.
41. MORAN, Patrick AP. Notes on continuous stochastic phenomena. **Biometrika**, v. 37, n. 1/2, p. 17-23, 1950.
42. OLIVEIRA, Victor Hugo de; MEDEIROS, Cleyber Nascimento de; CARVALHO, José Raimundo. Violence and Local Development in Fortaleza, Brazil: A Spatial Regression Analysis. *Appl. Spatial Analysis* 12, 147–166 (2019). <https://doi.org/10.1007/s12061-017-9236-4>.

43. PAULSEN, Derek J.; ROBINSON, Matthew B. **Crime mapping and spatial aspects of crime**. Prentice Hall, 2 edição, 2009.
44. PLASSA, Wander; PARRÉ, José Luiz. A violência no estado do Paraná: uma análise espacial das taxas de homicídios e de fatores socioeconômicos. **Economia e Desenvolvimento**, v. 31, n. 1, p. 01-16, 2019.
45. QUEIROZ, José Wilton et al. Geographic information systems and applied spatial statistics are efficient tools to study Hansen's disease (leprosy) and to determine areas of greater risk of disease. **The American journal of tropical medicine and hygiene**, v. 82, n. 2, p. 306, 2010.
46. RUBINSTEIN, Reuven Y.; KROESE, Dirk P. **Simulation and the Monte Carlo method**. John Wiley & Sons, 2016.
47. SALIMA, BOUAYAD AGHA; BELLEFON, M. D. Spatial autocorrelation indices. **Handbook of Spatial Analysis: Theory Application with R**, p. 51-68, 2018.
48. SPARKS, Corey. Spatial Analysis in R: Part 1: Getting data from the ACS into R and Exploratory Spatial Data Analysis. **Spatial Demography**, v. 1, n. 1, p. 131-139, 2013.
49. SILVA, Tamires Pereira. Análise espacial e avaliação de vulnerabilidade socioeconômica para os Crimes Violentos Letais Intencionais (CVLI) no Estado de Pernambuco. **Geoiंगा: Revista do Programa de Pós-Graduação em Geografia (PGE/UEM)**, v. 7, n. 2, p. 60-77, 2015.
50. SUTHERLAND, Edwin H.; CRESSEY, Donald R.; LUCKENBILL, David F. **Principles of criminology**. Altamira Press, 1992.
51. TOBLER, Waldo R. A computer movie simulating urban growth in the Detroit region. **Economic geography**, v. 46, n. sup1, p. 234-240, 1970.
52. WEISBURD, David; BERNASCO, Wim; BRUINSMA, Gerben (Ed.). **Putting crime in its place**. Springer New York, 2008.
53. WEISBURD, David; ECK, John E.; BRAGA, Anthony A. **Place matters**. Cambridge University Press, 2016.
54. WILKINSON, Richard; PICKETT, Kate. **The spirit level**. Why equality is better for everyone, 2010.
55. QGIS Development Team. **QGIS Geographic Information System (versão 3.32)**. 2023. Disponível em: <<http://qgis.osgeo.org>>.
56. Esri Inc. **ArcMap (versão 10.5.1)**. Redlands, Estados Unidos, 2016.
57. R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Áustria, 2020. Disponível em: <<http://www.R-project.org/>>.