



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Câmpus de Presidente Prudente

RAQUEL RIBEIRO ROCHA

**DENGUE EM PRESIDENTE PRUDENTE E SUAS CORRELAÇÕES
SOCIOECONÔMICAS**

Revisado pelo Orientador

Assinatura do Orientador

Data ____ / ____ / 2024

PRESIDENTE PRUDENTE

2024

RAQUEL RIBEIRO ROCHA

**DENGUE EM PRESIDENTE PRUDENTE E SUAS CORRELAÇÕES
SOCIOECONÔMICAS**

Relatório Final para Trabalho de Conclusão
de Curso apresentado ao Curso de
Graduação em Estatística da FCT/Unesp para
aproveitamento na disciplina TCC 2.

Orientador(a): Prof. Dr. Edilson Ferreira
Flores

PRESIDENTE PRUDENTE

2024

R672d	Rocha, Raquel Ribeiro Dengue em Presidente Prudente e suas correlações socioeconômicas / Raquel Ribeiro Rocha. -- Presidente Prudente, 2024 76 f. Trabalho de conclusão de curso (Bacharelado - Estatística) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente Orientador: Edilson Ferreira Flores 1. Estatística. 2. Dengue. 3. Vigilância epidemiológica. I. Título.
-------	--

TERMO DE APROVAÇÃO

Raquel Ribeiro Rocha

DENGUE EM PRESIDENTE PRUDENTE E SUAS CORRELAÇÕES SOCIOECONÔMICAS

Relatório de Final de Trabalho de Conclusão de Curso aprovado como requisito para obtenção de créditos na disciplina Trabalho de Conclusão do curso de graduação em Estatística da Faculdade de Ciências e Tecnologia da Unesp, pela seguinte banca examinadora:

**Edilson
Ferreira Flores**

Orientador: _____

Prof. Dr. Edilson Ferreira Flores
Departamento de Estatística

Assinado de forma digital
por Edilson Ferreira Flores
Dados: 2024.12.16 16:19:34
-03'00'

 Documento assinado digitalmente
JOSE GILBERTO SPASIANI RINALDI
Data: 18/12/2024 15:48:20-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. José Gilberto Spasiani Rinaldi
Departamento de

Presidente Prudente, 5 de dezembro de 2024.

RESUMO

A dengue representa um dos maiores problemas de saúde pública atualmente, especialmente no município de Presidente Prudente – SP, onde há uma significativa incidência da doença. Dado o histórico de surtos do município, torna-se essencial compreender como a doença se distribui espacialmente e quais fatores influenciam essa distribuição, especialmente os socioeconômicos, para embasar estratégias eficazes de prevenção e controle.

Este estudo teve como objetivo investigar a relação entre a distribuição espacial da dengue e o perfil econômico dos residentes das áreas mais afetadas. Para isso, foram utilizadas técnicas de análise espacial, como o estimador de Kernel, para identificar áreas com maior concentração de casos, e o Índice de Moran, para avaliar padrões de autocorrelação espacial. Além disso, foram aplicados métodos de correlação para verificar associações entre a incidência de dengue e a presença de domicílios com rendimentos mensais nas faixas de mais de 1 até 2 salários-mínimos e mais de 5 até 10 salários-mínimos.

Os resultados mostraram correlação significativa entre áreas de baixa renda e maior concentração de casos de dengue, evidenciando a vulnerabilidade socioeconômica como fator na propagação da doença. Observou-se que as regiões periféricas, onde há maior densidade de domicílios com rendimentos mais baixos, apresentaram maior incidência da dengue, enquanto as áreas centrais, com maior concentração de domicílios de alta renda, registraram menor impacto.

Conclui-se que a análise espacial e socioeconômica contribuiu significativamente para o entendimento da dinâmica da dengue em Presidente Prudente, oferecendo subsídios valiosos para a formulação de estratégias mais equitativas e eficazes de enfrentamento da doença.

Palavras-chave: Dengue, análise espacial, segregação socioeconômica, estimador de Kernel, Índice de Moran, correlação de Pearson.

ABSTRACT

Dengue is one of the most significant public health challenges today, particularly in Presidente Prudente – SP, which faces a high incidence of the disease. Given the municipality's history of outbreaks, it is essential to understand how the disease is spatially distributed and what factors influence this distribution, especially socioeconomic ones, to inform effective prevention and control strategies.

This study aimed to investigate the relationship between dengue's spatial distribution and the economic profile of residents in the most affected areas. Spatial analysis techniques, such as the Kernel density estimator, were used to identify areas with higher case concentrations, and the Moran's Index to assess spatial autocorrelation patterns. Additionally, correlation methods were applied to explore associations between dengue incidence and the presence of households with monthly incomes ranging from more than 1 to 2 minimum wages and from more than 5 to 10 minimum wages.

The results revealed a significant correlation between low-income areas and higher concentrations of dengue cases, highlighting socioeconomic vulnerability as a factor in disease propagation. Peripheral regions, where low-income households are denser, showed higher dengue incidence, while central areas with a higher concentration of high-income households were less affected.

It is concluded that spatial and socioeconomic analysis significantly contributed to understanding dengue dynamics in Presidente Prudente, offering valuable insights for the formulation of more equitable and effective strategies to combat the disease.

Keywords: Dengue, spatial analysis, socioeconomic segregation, Kernel density estimator, Moran's Index, Pearson correlation.

Lista de Figuras

Figura 1 - Exemplo de saída da ferramenta Band Collection Statistics	15
Figura 2 – Classificação do estimador do vizinho mais próximo	16
Figura 3 – Saída de software para análise do vizinho mais próximo.....	17
Figura 4 - Exemplo de saída da ferramenta Univariate Local Moran's I (Moran Scatter Plot).....	20
Figura 5 - Exemplo de saída da ferramenta Univariate Local Moran's I (LISA Map) .	21
Figura 6 - Exemplo de saída da ferramenta Univariate Local Moran's I (Significance Map)	21
Figura 7 - Mapa de concentração populacional de Presidente – Censo de 2022	24
Figura 8– Setores Censitários de Presidente Prudente – Censo de 2022, sem recorte	26
Figura 9– Setores Censitários de Presidente Prudente – Censo de 2022, com recorte	27
Figura 10 – Distribuição dos casos positivos de dengue no ano de 2022 sobre a malha do setor censitário de Presidente Prudente.....	28
Figura 11 – Distribuição dos casos positivos de dengue no ano de 2023 sobre a malha do setor censitário de Presidente Prudente.....	29
Figura 12 - Resumo do Vizinho mais próximo para os dados da dengue no ano de 2022	31
Figura 13 - Resumo do Vizinho mais próximo para os casos de dengue no ano de 2023	32
Figura 14 – Concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos nos setores censitários de Presidente Prudente – Censo 2010 .	34
Figura 15 – Concentração de domicílios com rendimento igual a 5 salários-mínimos até 10 salários-mínimos nos setores censitários de Presidente Prudente – Censo 2010	35
Figura 16 – Mapa de Kernel para os casos de dengue em Presidente Prudente no ano de 2022	37
Figura 17 – Mapa de Kernel para os casos de dengue em Presidente Prudente no ano de 2023	38

Figura 18 - Figura 10 – Mapa de Kernel para os domicílios com rendimento mensal de 1 até 2 salários-mínimos	40
Figura 19 – Mapa de Kernel para os domicílios com rendimento mensal de 5 até 10 salários-mínimos	41
Figura 20 Mapa de Kernel para os infectados com níveis 1 e 2 de escolaridade no ano de 2022	44
Figura 21 - Mapa de Kernel para os infectados com níveis 7 e 8 de escolaridade no ano de 2022	45
Figura 22 - Mapa de Kernel para os infectados com níveis 1 e 2 de escolaridade no ano de 2023	46
Figura 23 - Mapa de Kernel para os infectados com níveis 7 e 8 de escolaridade no ano de 2023	47
Figura 24 - Significance map para a concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos	49
Figura 25 - LISA map para a concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos	50
Figura 26 - Moran scatter plot para a concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos	51
Figura 27 - Significance map para a concentração de domicílios com rendimento igual a 5 até 10 salários-mínimos	53
Figura 28 - LISA map para a concentração de domicílios com rendimento igual a 5 até 10 salários-mínimos	54
Figura 29 - Moran scatter plot para a concentração de domicílios com rendimento igual a 5 até 10 salários-mínimos	55
Figura 30 - Regiões hipotéticas para exercício I de Moran	61
Figura 31 - Grade de eventos para exercícios de Kernel pontual	63
Figura 32 - Grade de eventos para exercícios de Kernel em área	65
Figura 33 - Exemplo de entrada para a ferramenta Incremental Spatial Autocorrelation	69
Figura 34 - Resultado da Incremental Spatial Autocorrelation para incremento de 200 metros	70
Figura 35 - Resultado da Incremental Spatial Autocorrelation para incremento de 1000 metros	70

Figura 36 - Resultado da Incremental Spatial Autocorrelation para incremento de 2000 metros	71
Figura 37 - Moran's I Summary by Distance para incremento de 1000 metros	72
Figura 38 - Moran's I Summary by Distance para incremento de 2000 metros	72
Figura 39 - Mapa de Kernel com raio de 6200 metros	74

Sumário

LISTA DE FIGURAS.....	4
1 INTRODUÇÃO.....	8
OBJETIVOS	9
JUSTIFICATIVA.....	9
2 REVISÃO BIBLIOGRÁFICA	10
3 REFERENCIAL TEÓRICO.....	11
3.1 SISTEMAS DE INFORMAÇÃO GEOGRÁFICA	11
3.2 ESTATÍSTICA ESPACIAL	11
3.3 ANÁLISE ESPACIAL.....	11
3.4 ESTIMATIVA DE KERNEL.....	12
3.5 COEFICIENTE DE CORRELAÇÃO DE PEARSON.....	14
3.6 ESTIMADOR DO VIZINHO MAIS PRÓXIMO.....	15
3.7 GEOCODIFICAÇÃO POR ENDEREÇOS	18
3.8 ÍNDICE DE MORAN E LISA.....	19
4 METODOLOGIA.....	23
5 APRESENTAÇÃO DOS DADOS	24
5.1 CONCENTRAÇÃO POPULACIONAL E SETORES CENSITÁRIOS	24
5.2 CASOS DE DENGUE	27
5.3 CLASSES DE RENDA	33
6 DESENVOLVIMENTO	37
7 CONSIDERAÇÕES FINAIS	57
REFERÊNCIAS	58
ANEXO A	61
ANEXO B	63
ANEXO C	68

1 INTRODUÇÃO

A dengue é uma infecção arboviral, transmitida pelos mosquitos do gênero *Aedes*, hiperendêmica nos países de clima tropical e subtropical como os da América do Sul, Ásia e Oceania, que abrigam quase metade da população mundial. Ela pode se manifestar de maneira assintomática, mas, em casos mais extremos, pode levar à falência múltipla de órgãos e morte.

Tornou-se um problema de saúde pública devido à sua letalidade e é uma das doenças transmitidas por mosquitos que mais cresce no mundo atualmente. Sem medidas efetivas para sua prevenção e controle, as consequências da dengue para a saúde serão cada vez mais intensas.

O primeiro registro da dengue em humanos data de 992 antes de Cristo (na China) e acredita-se que entre os séculos XIX e XX o vírus tenha se espalhado pelos trópicos e subtropicais. No Brasil, por sua vez, acredita-se que o vírus tenha chegado no século XIX, trazido pelo comércio de escravos, e se espalhado pelas áreas tropicais e subtropicais.

Entre 1958 e 1973 o mosquito chegou a ser erradicado do país, mas em 1976 notaram-se os sinais de uma reintrodução e, a partir da década de 1990, os países da América do Sul passaram a fazer parte do grupo dos mais atingidos pela doença, contribuindo com mais da metade dos casos mundiais. Foi nessa década em que o Brasil registrou mais de 700 mil casos de dengue em um único ano, 1998. Desde então, o mosquito transmissor da doença tem se mantido amplamente presente em todo o território nacional.

Já em Presidente Prudente - SP, os primeiros casos de dengue foram registrados no ano de 1996. Desde então, o município segue registrando muitos casos da doença, sendo as ocorrências mais expressivas nos anos de 2013, 2015, 2016, 2019, 2020 e 2023.

Dada a situação atual e o crescente número de casos de dengue, faz-se necessária uma política de conscientização e prevenção do problema no município, com participação tanto dos órgãos públicos quanto dos cidadãos.

Objetivos

O objetivo geral deste trabalho é mapear os casos positivos de dengue no município de Presidente Prudente nos anos de 2022 e 2023 e buscar uma correlação entre a contaminação e a situação socioeconômica dos infectados.

Os objetivos específicos a serem alcançados são:

- Mapear os casos positivos de dengue no município de Presidente Prudente nos anos de 2022 e 2023;
- Gerar os mapas de kernel das áreas afetadas pela doença no município;
- Mapear as residências de acordo com as classes de concentração de renda no município de Presidente Prudente segundo o CENSO do IBGE realizado em 2022;
- Gerar os mapas de kernel para as classes de concentração de renda;
- Buscar correlações entre as áreas de renda mapeadas e as regiões com maior incidência de dengue;

Justificativa

A região de Presidente Prudente apresenta muitos casos de dengue, logo, precisa de extensas políticas de combate e prevenção da doença. Analisar as áreas com maior incidência e delinear a população mais afetada auxiliaria na criação de políticas melhores e mais efetivas, focadas nas áreas e nas pessoas certas. Essas ações também estão alinhadas com o ODS (Objetivo de Desenvolvimento Sustentável) 3 da ONU (Bem-Estar), que busca promover a saúde e o bem-estar global. Em especial, o Objetivo 3.3, que visa acabar com epidemias de diversas doenças, incluindo as tropicais negligenciadas, como a dengue. Além disso, o Objetivo 3.d destaca a importância de fortalecer a capacidade dos países, especialmente os em desenvolvimento, no gerenciamento de riscos de saúde. Portanto, investir em estratégias direcionadas para combater a dengue no município de Presidente Prudente contribuiria para a saúde local e estaria alinhado com os esforços globais da ONU para combater doenças transmissíveis.

2 REVISÃO BIBLIOGRÁFICA

Para embasamento desse estudo, foram utilizados dois estudos relacionados à ocorrência da dengue no município de Presidente Prudente em anos anteriores: “Dengue outbreaks in a city with recent transmission in São Paulo State, Brazil” (Prestes-Carneiro, 2023) e “Análise Espacial e Fatores de Risco Ambiental da Dengue na Área Urbana de Presidente Prudente – SP” (Proença, 2023).

O primeiro dos estudos encontrou uma associação positiva entre a densidade de casos de dengue e os Site Waste Disposals (SWD) em 2015, 2020 e 2021. Foram coletadas amostras de sangue de pacientes infectados com dengue nos primeiros 5 dias de sintomas, as quais foram submetidas à detecção do genoma de RNA viral em microrregiões por RT-PCR (diagnóstico laboratorial, feito por biologia molecular, que permite identificar a presença do material genético do vírus Sars-Cov-2 em amostras de secreção respiratória). Os testes foram realizados pelo Instituto Adolfo Lutz (IAL), e os resultados, registrados no Sistema de Informação de Agravos de Notificação do Brasil (SINAN). Os pesquisadores também usaram a densidade de kernel para mostrar “pontos quentes” de dengue em Presidente Prudente, calculando a densidade de características pontuais e criando uma grade de saída raster para mapear a intensidade do fenômeno estudado.

Já o segundo buscou a correlação entre os casos de dengue em Presidente Prudente, no ano de 2021, com os vetores encontrados em bocas de lobo, por meio da análise espacial da área. Essa análise utilizou técnicas de estatística espacial, como a geração de mapas de Kernel (“pontos de calor”) para os casos positivos de dengue na cidade.

Além disso, foram correlacionados os dados dos casos positivos com os vetores encontrados nas bocas de lobo da cidade, a fim de identificar focos recorrentes da doença e realizar modelos preditivos para orientar ações de prevenção e controle da disseminação da doença.

3 REFERENCIAL TEÓRICO

3.1 Sistemas de Informação Geográfica

Os Sistemas de Informação Geográfica (SIG's) são sistemas de computador que permitem a captura, armazenamento, gerenciamento, análise e apresentação de informações geográficas, facilitando análises espaciais complexas e integração de dados de diversas fontes. Diferenciam-se dos Sistemas de Apoio a Projetos em Computador (CAD's), pois têm a capacidade de representar relacionamentos espaciais entre elementos geográficos, enquanto os CAD's focam na automação de tarefas cartográficas. Basicamente, os SIG's são compostos por procedimentos para aquisição e manipulação de dados, gerenciamento de banco de dados, visualização cartográfica, consulta e análise dos dados obtidos.

3.2 Estatística Espacial

Estatística Espacial é o ramo da estatística que analisa a localização dos eventos. Assim, além das tarefas que podem ser realizadas no SIG (identificação, visualização etc.), ela possibilita a modelagem dos eventos estudados, utilizando, por exemplo, a distribuição espacial ou a identificação de padrões.

A estatística espacial “descarta” o pressuposto estatístico da independência entre as observações, pois as ocorrências analisadas (pela estatística espacial) têm sua distribuição afetada pela localização geográfica e relação com os vizinhos.

A principal aplicação desse ramo da estatística na área da saúde é o mapeamento de doenças para a identificação de aglomerados espaciais (*clusters*).

3.3 Análise Espacial

A Análise Espacial pode ser definida como “o estudo quantitativo de fenômenos posicionados no espaço” (DINIZ, 2000). Este ramo possibilita visualizar, explorar e modelar dados espaciais.

São utilizadas técnicas que incorporam as localizações dos fenômenos estudados e lida com três tipos principais: discretos, contínuos e atributos. Aqui, o estudo é focado no fenômeno discreto, já que serão analisadas ocorrências pontuais, que serão representadas por pontos nos mapas.

As principais aplicações da análise espacial em saúde são:

- Mapeamento de doenças (construir mapas de indicadores epidemiológicos);
- Estudos ecológicos (medir associação entre indicadores agregados);
- Saúde e ambiente (relacionar camadas de dados sobre ambiente e saúde);
- Detecção de aglomerados (identificar áreas de maior incidência).

3.4 Estimativa de Kernel

A Estimativa Kernel é uma técnica utilizada para avaliar a distribuição espacial de eventos em relação à distribuição da população. É uma maneira gráfica de estimar a taxa de incidência de eventos em uma região. Ela envolve a comparação visual de mapas suavizados para diferentes processos e o cálculo da densidade de casos por área e a densidade demográfica, resultando em uma taxa de incidência. Sua unidade de medida é o número de casos por habitante. Uma desvantagem dela é que desconsidera a distribuição populacional, o que pode trazer problemas, pois ela varia pelo território.

Ela permite medir a distribuição de eventos, formando uma superfície com valores proporcionais à intensidade da amostra por unidade de área, ponderando os pontos pela distância até o local de interesse. É uma maneira de ilustrar a distribuição dos dados na área observada, estimando a densidade estatística espacial deles.

Essa técnica constitui-se de um estimador probabilístico através da função de Kernel, que usa como entrada as ocorrências de uma determinada variável.

Assim, seja s uma localização qualquer contida em R e $s_1, s_2, \dots, s_n$ as localizações de n eventos observados, o estimador de Kernel é dado por:

$$\hat{\lambda}_{\tau}(s) = \sum_{i=1}^n \frac{1}{\tau^2} k\left(\frac{s - s_i}{\tau}\right), \quad s - s_i \leq \tau$$

No qual τ é o raio de influência em volta de s que determina o grau de suavização e $k(i)$ é a função Kernel bivariada simétrica, chamada de função de interpolação. A técnica calcula a densidade para cada região da área de estudo (R), o que torna

possível a construção de uma superfície contínua composta pela variação espacial da variável observada.

É possível adicionar atributos para caracterizar o evento a ser analisado e, nesses casos, utilizamos a fórmula:

$$\hat{\lambda}_{\tau}(s) = \sum_{i=1}^n \frac{1}{\tau^2} k\left(\frac{d(u_i, u)}{\tau}\right) y_i, d(u_i, u) \leq \tau$$

Em que y_i representa o i -ésimo atributo referente a u_i . Nesse caso, para calcular a estimativa de intensidade média, é necessário dividir a intensidade dos pontos pela intensidade sem o atributo adicionado, levando-nos à seguinte fórmula:

$$\mu_{\tau}(s) = \frac{\sum_{i=1}^n k\left(\frac{(s - s_i)}{\tau}\right) y_i}{\sum_{i=1}^n k\left(\frac{(s - s_i)}{\tau}\right)}$$

Na qual, $(s - s_i)$ representa a distância entre o ponto com intensidade estimada e o i -ésimo ponto dentro do raio de influência. Assim, a definição da área vai depender da influência do raio com centro no ponto estimado, o que suaviza a superfície.

Para a suavização da área estudada, existem variações da função de interpolação $k()$, sendo as mais comuns:

Kernel Gaussiano (ou Normal): $K(h) = \frac{1}{2\pi\tau} e^{\left(-\frac{h^2}{2\tau^2}\right)}$;

Kernel Quártico: $K(h) = \frac{3}{\pi} (1 - h^2)^2$;

Kernel Trinagular: $K(h) = (1 - |h|)$;

Kernel Exponencial Negativo: $K(h) = \frac{1}{2\pi} e^{-h}$;

Kernel Uniforme: $K(h) = \frac{1}{2}$.

O presente estudo utiliza o Kernel Quadrático, com a fórmula final:

$$\hat{\lambda}_{\tau} = \sum_{i=1}^n \frac{3}{\pi\tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2,$$

Em que h é a distância entre a localização alvo e o evento estudado e τ o raio de influência que irá determinar a banda de suavização no método.

Em um SIG, é possível construir mapas de densidade demográfica com base em dados de população. Assim, a técnica Kernel avalia os eventos em relação a essas unidades de análise, permitindo a estimativa da intensidade do processo em relação à população.

Esta técnica é útil na área da saúde para analisar a distribuição espacial e concentração de casos de doenças em relação a uma população, identificando as áreas com maior risco.

3.5 Coeficiente de Correlação de Pearson

O coeficiente de correlação de Pearson é utilizado para medir a associação linear entre duas variáveis. Desse modo, duas variáveis com correlação forte serão impactadas pelo aumento ou decréscimo da outra.

Esse coeficiente varia entre -1 e 1, sendo o valor absoluto a força da correlação e o sinal (negativo ou positivo) a direção desta correlação, que pode ser direta ou inversamente proporcional. Há diversas interpretações das classes (forte, média e fraca) de correlação, mas o imperativo é que quanto mais perto de 1 for o valor, mais forte será a correlação entre as duas variáveis estudadas.

Nesse caso, a ferramenta *Band Collection Statistics* do ArcMap é utilizada para realizar o cálculo da correlação entre um grupo de camadas *raster* escolhidas pelo usuário. A saída resultante dessa ferramenta é um arquivo do tipo *txt* com as matrizes de variância/covariância e de correlação para cada par de camadas selecionadas:

Figura 1 - Exemplo de saída da ferramenta Band Collection Statistics

#	STATISTICS of INDIVIDUAL LAYERS				
#	Layer	MIN	MAX	MEAN	STD
#	-----				
	1	0.0000	0.0005	0.0000	-1.0000
	2	0.0000	0.0008	0.0000	0.0001
#	=====				
#	COVARIANCE MATRIX				
#	Layer	1	2		
#	-----				
	1	3.738665e-009	4.950027e-009		
	2	4.950027e-009	8.574920e-009		
#	=====				
#	CORRELATION MATRIX				
#	Layer	1	2		
#	-----				
	1	1.00000	0.87425		
	2	0.87425	1.00000		
#	=====				

Fonte: Autora

Para realizar esses cálculos, a ferramenta utiliza os valores de cada célula dentro do espaço em comum das camadas selecionadas. Os cálculos se dão pelas fórmulas abaixo:

$$Cov_{ij} = \frac{\sum_{k=1}^N (Z_{ik} - \mu_i)(Z_{jk} - \mu_j)}{N - 1}$$

Essa é a fórmula para o cálculo da covariância, onde Z_{ij} é o valor da célula, μ é a média da camada, N é o número de células e k denota uma célula específica.

A fórmula utilizada para o cálculo da correlação é:

$$Corr_{ij} = \frac{Cov_{ij}}{\delta_i \delta_j}$$


3.6 Estimador do Vizinho Mais Próximo

A técnica de estimação do vizinho mais próximo é utilizada para calcular o grau de agrupamento das ocorrências estudadas, classificando-as em dispersas, aleatórias ou *clusterizadas* (agrupadas).

Para isso, mede-se a distância entre cada centroide de um recurso e seu vizinho mais próximo, calculando-se a média dessas distâncias. Se a distância média

observada for menor que a esperada em uma distribuição aleatória, os recursos são considerados agrupados. Se for maior, são dispersos. A razão média do vizinho mais próximo é a distância média observada dividida pela distância média esperada em uma distribuição aleatória com o mesmo número de recursos na mesma área.

Figura 2 – Classificação do estimador do vizinho mais próximo



Disponível em: <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-statistics/average-nearest-neighbor.htm#:~:text=The%20Nearest%20Neighbor%20Index%20is,in%20a%20hypothetical%20random%20distribution.>

Para realizar os cálculos e interpretações temos:

A razão média do vizinho mais próximo (ANN), ou *average nearest neighbor* é calculada pela fórmula:

$$ANN = \frac{\overline{D_o}}{\overline{D_e}}$$

Sendo $\overline{D_o}$ a distância média observada entre cada ponto e seus vizinhos mais próximos, dada por:

$$\overline{D_o} = \frac{\sum_{i=1}^n d_i}{n}$$

Em que d_i é a distância entre cada ponto e seu vizinho mais próximo, n o número de elementos da característica analisada e A a área mínima que contenha os vizinhos.

E $\overline{D_e}$ é a distância média esperada para características de um padrão aleatório.

$$\overline{D_e} = \frac{0,5}{\sqrt{n/A}}$$

Dado o índice R (razão média do vizinho mais próximo), se $R < 1$, os recursos são agrupados, se $R > 1$, são dispersos. O cálculo assume que os pontos podem ser

localizados em qualquer lugar da área de estudo. A estatística Z é usada para determinar a significância do padrão observado e é dada por:


$$Z = \frac{\bar{D}_o - \bar{D}_e}{Se}$$

E Se é:

$$Se = \frac{0.26136}{\sqrt{n^2/A}}$$

No software utilizado, é apresentada a seguinte saída para o cálculo do vizinho mais próximo:

Figura 3 – Saída de software para análise do vizinho mais próximo



Disponível em: <https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-statistics-toolbox/h-how-average-nearest-neighbor-distance-spatial-st.htm#:~:text=The%20Average%20Nearest%20Neighbor%20tool,all%20these%20nearest%20neighb or%20distances>

Vemos que a ferramenta retorna cinco valores principais:

- Distância média observada (D_o)
- Distância média esperada (D_e)
- Índice do vizinho mais próximo (R)
- Pontuação Z
- Valor p

Esses valores são exibidos na janela de resultados e serão utilizados para analisar a possível clusterização dos dados.

A pontuação Z e o valor p estão associados a uma distribuição Normal Padrão, assim, a pontuação Z representa o desvio padrão. Se a ferramenta retornar valores extremos para Z (altos ou baixos) associados a valores p muito pequenos, eles estarão nas caudas da distribuição, indicando improbabilidade de o padrão observado representar um padrão aleatório.

As principais aplicações para essa técnica são:

- Avaliação de competição ou território: Quantificar e comparar a distribuição espacial de diferentes espécies ou tipos de negócios;
- Monitoramento de mudanças ao longo do tempo: Avaliar mudanças no agrupamento espacial de um tipo de negócio;
- Comparação de distribuições: Comparar padrões observados com padrões de controle, como em análises de áreas de colheita de madeira.

3.7 Geocodificação por Endereços

Este é o processo de transformação dos endereços (rua, número, bairro, cep, cidade, estado e país) em coordenadas geográficas de latitude e longitude, que poderão ser utilizadas no GIS.

Para isso, é preciso ter uma planilha e agrupar todos os componentes dos endereços em apenas uma coluna, que será então copiada para uma planilha do Google Planilhas, onde, é possível encontrar o *Apps Script*, na aba de extensões. Lá, utilizando um código preexistente criamos um “*app*” que fará a geocodificação dos endereços para coordenadas do tipo graus decimais. No caso deste projeto, converti-as para o tipo UTM utilizando o site *Species Conversor*.

Com as coordenadas em mãos, é possível transformar a planilha em uma *shapefile* para a manipulação desses dados no software de SIG.

3.8 Índice de Moran e LISA

O índice global de Moran (I) é um Indicador Global de Autocorrelação Espacial, uma das formas de detectar similaridade entre os valores de uma variável em locais próximos.

Ele é dado por I , e é definido como:

$$I = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Em que n é o número de áreas, y_i e y_j são os valores do atributo estudado nas áreas i e j , $\bar{y}$ é a média do atributo estudado na região estudada e w_{ij} os pesos atribuídos de acordo com a conexão entre as áreas i e j .

O I pode assumir valores entre -1 e 1 e sua interpretação é análoga à do coeficiente de correlação de Pearson, valores próximos de -1 indicam autocorrelação espacial negativa e próximos de 1 indicam autocorrelação espacial positiva, enquanto valores próximos de 0 indicam aleatoriedade (ausência de autocorrelação).

Como fornece apenas um único valor como medida de associação espacial, o I de Moran limita a análise de padrões em uma escala maior e, desta limitação, vem o uso dos Indicadores Locais de Associação Espacial (LISA).

Os indicadores LISA trazem um valor para cada objeto estudado, tornando possível a identificação de *clusters* e *outliers*. Segundo Anselin (1995), os LISA devem permitir a identificação de padrões de associação significativos e serem decomposições do índice global de associação espacial.

Há duas famílias de indicadores locais, os G_i e G_i^* e o I_i de Moran, que será o indicador utilizado no trabalho.

O indicador local I_i de Moran é dado por:


$$I_i = \frac{(y_i - \bar{y}) \sum_{j=1}^n w_{ij} (y_j - \bar{y})}{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}}$$

Sendo que $I_i > 0$ indica *clusters* de valores similares (alto-alto ou baixo-baixo) e $I_i < 0$ indica *clusters* de valores distintos (alto-baixo ou baixo-alto).

A significância dos indicadores deve ser avaliada, o que é feito utilizando-se da hipótese de normalidade ou da simulação de distribuição.


O software GeoDa será utilizado para o cálculo e geração de mapas relevantes para interpretação dos indicadores, por meio da ferramenta *Univariate Local Moran's I*, que retorna três saídas gráficas, como visto abaixo:

Figura 4 - Exemplo de saída da ferramenta *Univariate Local Moran's I* (Moran Scatter Plot)




Fonte: Autora

Figura 5 - Exemplo de saída da ferramenta Univariate Local Moran's I (LISA Map)



Fonte: Autora

Figura 6 - Exemplo de saída da ferramenta Univariate Local Moran's I (Significance Map)



Fonte: Autora

A figura 4 (*Moran Scatter Plot*), representa a relação entre os valores da variável e a média dos valores nas áreas vizinhas, cada quadrante representando o regime espacial em que o ponto se encontra (alto-alto, alto-baixo, baixo-alto ou baixo-baixo), a figura 5 (*LISA Map*) exibe os clusters locais, permitindo a observação de padrões espaciais, e a figura 6 (*Significance Map*) indica onde o índice é significativo, evidenciando *clusters* ou *outliers* espaciais.

4 METODOLOGIA

O principal objetivo do trabalho é mapear e relacionar os casos positivos de dengue com a quantidade de residências das classes de concentração de renda nas áreas do município de Presidente Prudente nos anos de 2022 e 2023.

Para isso, foram utilizados dados relativos aos casos positivos de dengue disponibilizados pelo Sistema de Informação de Agravos de Notificação do Brasil (SINAN), assim como dados sobre a concentração de renda das residências locais e mapas dos setores censitários, obtidos dos resultados do CENSO de 2010 e 2022, respectivamente, realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE).

Os dados dos casos de dengue seguem uma classificação numérica: 5 – Negativo, 10 – Positivo, 11 – Dengue com complicações e 12 – Dengue grave. Ao longo do trabalho foi decidido utilizar apenas os casos de categoria 10, isto é, os positivos, em razão de problemas na georreferenciação das demais variações de gravidade da doença.

Nos mapas mencionados, foram projetados os pontos que representam as residências que reportaram casos positivos de dengue e as que pertencem a alguma das duas classes estudadas. Isso foi feito através do georreferenciamento dos endereços vinculados a cada uma das notificações (no caso da dengue) e das residências (no caso das classes de renda). Nessa etapa, foi utilizado o Excel para organização e conversão dos endereços em coordenadas UTM e o MiniTab, para a geração de uma base no formato DBF com os pontos georreferenciados.


A análise espacial foi realizada no *software* de SIG ArcGIS (módulo ArcMap 10.7) e no *software* GeoDa (versão 1.22.0.10). Uma vez que os dados georreferenciados estavam no ambiente de SIG, foram utilizadas técnicas de geoestatística e estatística espacial, como a do estimador do Vizinho Mais Próximo, estimador de Kernel, coeficiente de correlação de Pearson e Índice de Moran para autocorrelações espaciais, para demonstrar o comportamento dos pontos e buscar uma relação de causa e efeito entre eles.

5 APRESENTAÇÃO DOS DADOS

5.1 Concentração Populacional e Setores Censitários

Utilizando as informações do Censo do ano de 2022, foi elaborado um mapa de concentração populacional para Presidente Prudente, dividido de acordo com os setores censitários do ano mencionado.

Figura 7 - Mapa de concentração populacional de Presidente – Censo de 2022




Fonte: Autora

A análise do mapa mostra mais áreas com maior concentração populacional nos setores localizados ao sul do município, representadas pelas áreas em vermelho mais escuro. Nessas regiões a população total varia entre 703 e 1848 pessoas por setor, enquanto ao norte vemos setores com maior extensão territorial e baixa densidade populacional, onde o total de pessoas por setor não ultrapassa 251.


Ademais, não foram disponibilizados dados relativos à ocorrência da dengue em toda a extensão do município, por isso, foi feito um recorte na *shapefile* dos setores censitários do município, a fim de focar nos setores onde há ocorrências a serem analisadas.

Figura 8– Setores Censitários de Presidente Prudente – Censo de 2022, sem recorte



Fonte: Autora

Figura 9– Setores Censitários de Presidente Prudente – Censo de 2022, com recorte




Fonte: Autora

5.2 Casos de dengue


No software ArcMap foram realizadas as análises espaciais dos casos positivos de dengue e da distribuição de residências nas duas classes econômicas selecionadas.

Figura 10 – Distribuição dos casos positivos de dengue no ano de 2022 sobre a malha do setor censitário de Presidente Prudente.



Fonte: Autora

Figura 11 – Distribuição dos casos positivos de dengue no ano de 2023 sobre a malha do setor censitário de Presidente Prudente



Fonte: Autora


Para garantir a confiabilidade das análises e dos mapas produzidos no estudo, foram necessárias limpezas e revisões das *shapefiles* que contém os pontos dos casos da dengue no município. Nessas limpezas, os poucos casos das categorias 11 e 12 foram removidos por inconsistências em suas coordenadas durante a

geocodificação. Por isso, o estudo abordará apenas os casos com classificação 10, isto é, os casos positivos da doença.

Realizando a análise do estimador do Vizinho Mais Próximo nos casos de dengue dos dois anos estudados, verificou-se uma distribuição *clusterizada* nos casos, indicando que os indivíduos infectados tendem a estar localizados em áreas próximas. Isso sugere a existência de fatores – ambientais, sociais ou comportamentais – que podem estar influenciando a propagação da doença.

Figura 12 - Resumo do Vizinho mais próximo para os dados da dengue no ano de 2022

Average Nearest Neighbor Summary




Average Nearest Neighbor Summary

Observed Mean Distance:	26.0184 Unknown Units
Expected Mean Distance:	80.0236 Unknown Units
Nearest Neighbor Ratio:	0.325134
z-score:	-112.166794
p-value:	0.000000

Fonte: Autora

Figura 13 - Resumo do Vizinheiro mais próximo para os casos de dengue no ano de 2023

Average Nearest Neighbor Summary



Average Nearest Neighbor Summary

Observed Mean Distance:	23.2360 Unknown Units
Expected Mean Distance:	71.1140 Unknown Units
Nearest Neighbor Ratio:	0.326744
z-score:	-138.487026
p-value:	0.000000

Fonte: Autora


As figuras 6 e 7 trazem os resultados da aplicação da técnica do Vizinheiro Mais Próximo nas *shapefiles* que contém os dados de incidência de dengue nos anos estudados. Os resultados corroboram o que foi dito acima mostrando que a probabilidade de que o padrão nos dados tenha sido gerado pelo acaso é menor que 1%.

Essa constatação justifica as análises promovidas no presente trabalho, pois permite investigar as possíveis relações entre a incidência de dengue na região e as variáveis socioeconômicas, além de possibilitar a identificação de áreas que devem ser priorizadas nas intervenções de saúde pública. Assim, a análise espacial não apenas traz uma compreensão mais profunda da distribuição espacial da dengue em Presidente Prudente, como contribui para a formulação de estratégias de prevenção e controle verdadeiramente eficazes.

5.3 Classes de renda


Para este estudo, foram selecionadas duas faixas de renda com base nos dados do Censo de 2010: a primeira, composta por domicílios com rendimento mensal entre 1 e 2 salários-mínimos, e a segunda, por domicílios com rendimento mensal entre 5 e 10 salários-mínimos.

Figura 14 – Concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos nos setores censitários de Presidente Prudente – Censo 2010



Fonte: Autora

Figura 15 – Concentração de domicílios com rendimento igual a 5 salários-mínimos até 10 salários-mínimos nos setores censitários de Presidente Prudente – Censo 2010



Fonte: Autora


Os mapas acima mostram uma concentração maior de residências com mais de 5 a 10 salários-mínimos na região central do município, enquanto as residências que vivem com mais de 1 a 2 salários-mínimos se apresentam em áreas mais periféricas.

É relevante mencionar que, durante a realização deste trabalho, os resultados relativos às variáveis de rendimento dos domicílios do Censo de 2022 não foram disponibilizados. Por isso, foram utilizados os resultados do Censo de 2010.

6 DESENVOLVIMENTO


Inicialmente, foram elaborados mapas de Kernel para buscar áreas com maior concentração de ocorrências de casos de dengue nos dois anos estudados.

Figura 16 – Mapa de Kernel para os casos de dengue em Presidente Prudente no ano de 2022



Fonte: Autora

Figura 17 – Mapa de Kernel para os casos de dengue em Presidente Prudente no ano de 2023




Fonte: Autora

A análise comparativa dos mapas de Kernel das ocorrências de dengue nos anos de 2022 e 2023 revela uma diferença significativa entre eles. No ano de 2022, observamos apenas uma área de concentração alta no bairro Ana Jacinta e algumas áreas com concentração média-baixa, além de uma concentração média maior e mais evidente na região do bairro Cecap, o que sugere uma distribuição mais pontual e menos consistente dos casos de dengue.

Já em 2023, com um maior número de casos registrados após a limpeza da base de dados, é possível observar um panorama mais rico e detalhado da distribuição da doença. Há concentrações média-alta e alta nos bairros Ana Jacinta (próximo da área de concentração alta observada no ano anterior), Jardim Humberto Salvador e Brasil Novo. Todos esses bairros estão localizados na periferia do município e são fruto de iniciativas habitacionais do governo, o que indica que as populações de baixa renda são mais afetadas pela doença.


Para concluir com mais precisão a existência de uma relação entre as variáveis analisadas, foi aplicada a técnica de correlação, precedida pela criação dos mapas de concentração de Kernel das duas classes de renda escolhidas.

Figura 18 - Figura 10 – Mapa de Kernel para os domicílios com rendimento mensal de 1 até 2 salários-mínimos



Fonte: Autora

Figura 19 – Mapa de Kernel para os domicílios com rendimento mensal de 5 até 10 salários-mínimos



Fonte: Autora

Observando os mapas da ocorrência de dengue no ano de 2023 e da concentração de domicílios com 1 até 2 salários-mínimos de rendimento podemos notar uma possível relação, já que as áreas com maiores concentrações dos dois mapas parecem se sobrepor nas mesmas regiões.

Assim, partimos para a aplicação da correlação, utilizando a *Band Collection Statistics*, que irá retornar a matriz de correlação das variáveis observadas.

Vale salientar que as correlações deste trabalho são aplicadas a mapas de Kernel (mapas de concentração), por isso valores altos de correlação podem surgir mesmo quando uma análise ponto a ponto não indicaria uma relação tão forte. Isso ocorre porque os mapas de Kernel geram superfícies de densidades, agregando as informações de localizações próximas e, ao correlacionar as superfícies de densidades geradas comparamos não só as ocorrências pontuais, mas os padrões de concentração espacial formados por essas ocorrências, o que permite a detecção de associações e tendências de agrupamento. Assim, as correlações espaciais oferecem uma medida que captura o comportamento espacial das variáveis analisadas.

Tabela 1 - Matriz de correlação entre os casos de dengue em 2022 e os domicílios com rendimento de 1 até 2 salários-mínimos

1,00000	0,61236
0,61236	1,00000

Tabela 2 - Matriz de correlação entre os casos de dengue em 2022 e os domicílios com rendimento de 5 até 10 salários-mínimos

1,00000	0,59091
0,59091	1,00000

Em 2022, as correlações entre a ocorrência da dengue e as classes de renda, 0,61236 para a classe de 1 até 2 salários-mínimos e 0,59091 para a classe de 5 até 10 salários-mínimos, são semelhantes, ou seja, não existe uma diferença significativa de prevalência entre os dois grupos observados, sugerindo que ambos possuem uma relação semelhante com a doença.

Tabela 3 - Matriz de correlação entre os casos de dengue em 2023 e os domicílios com rendimento de 1 até 2 salários-mínimos

1,00000	0,87425
0,87425	1,00000

Tabela 4 - Matriz de correlação entre os casos de dengue em 2023 e os domicílios com rendimento de 5 até 10 salários-mínimos

1,00000	0,58974
0,58974	1,00000

Analizando os valores das correlações do ano de 2023, observamos um valor consideravelmente alto na correlação entre a ocorrência da doença e a concentração de pessoas de baixa renda, 0,87425, indicando que há uma forte relação entre as duas variáveis. Como a correlação entre a ocorrência da dengue e a concentração de pessoas com maior renda retornou um valor mais baixo, 0,58974, temos maior confiança na métrica, reforçando a hipótese de que as regiões com menor poder aquisitivo são mais vulneráveis à doença.


O valor observado na correlação da classe de renda de 1 a 2 salários-mínimos e as ocorrências de dengue no ano de 2023 é notavelmente alto, evidenciando uma possível relação entre a renda e a vulnerabilidade à doença. Esse resultado destaca que as áreas com menor renda apresentam maior incidência, sugerindo que fatores socioeconômicos podem contribuir para a exposição e o risco de transmissão da dengue.

A fim de enriquecer as análises de fatores socioeconômicos, foram elaborados os mapas de concentração da escolaridade das pessoas infectadas pela dengue nos anos estudados.

Os dados de escolaridade usados são fruto das informações da base de pacientes infectados com dengue fornecida pelo SINAN, a mesma usada para a elaboração dos mapas dos casos da doença, por isso, a informação abrange apenas as pessoas pacientes. Os dados atualizados de escolaridade do Censo 2022 não foram liberados a tempo de serem incluídos no estudo.


Na base utilizada, a escolaridade é dividida em níveis que vão de 0 a 8. Para a elaboração dos mapas, foram agrupados os níveis 1 e 2 (1ª a 4ª série incompleta do ensino fundamental e 4ª série completa do ensino fundamental, respectivamente) para compor o grupo de menor escolaridade e os níveis 7 e 8 (ensino superior incompleto e ensino superior completo, respectivamente) foram usados para compor o grupo com maior escolaridade.

Figura 20 Mapa de Kernel para os infectados com níveis 1 e 2 de escolaridade no ano de 2022




Fonte: Autora

Figura 21 - Mapa de Kernel para os infectados com níveis 7 e 8 de escolaridade no ano de 2022




Fonte: Autora

Figura 22 - Mapa de Kernel para os infectados com níveis 1 e 2 de escolaridade no ano de 2023



Fonte: Autora

Figura 23 - Mapa de Kernel para os infectados com níveis 7 e 8 de escolaridade no ano de 2023




Fonte: Autora

Ao comparar os mapas de kernel acima com os mapas de concentração de domicílios por faixa de renda (figuras 10 e 11), observa-se que as distribuições espaciais apresentam comportamento similar, principalmente entre o grupo com maior rendimento mensal e o grupo com maior escolaridade. Esse padrão sugere que a população com maior renda tende a apresentar níveis de escolaridade mais elevados.


Com o intuito de investigar a existência de padrões espaciais na distribuição de diferentes níveis de renda, aplicou-se o Índice I de Moran, acompanhado da análise dos mapas de significância e agrupamento. Esses métodos permitem identificar possíveis autocorrelações espaciais, destacando regiões onde há uma tendência de concentração de domicílios com rendas semelhantes, o que pode revelar dinâmicas de segregação socioeconômica na cidade. A seguir, são apresentados os resultados dessa análise.

Figura 24 - Significance map para a concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos




Fonte: Autora

Figura 25 - LISA map para a concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos



Fonte: Autora

Figura 26 - Moran scatter plot para a concentração de domicílios com rendimento igual a 1 salário-mínimo até 2 salários-mínimos




Fonte: Autora

O índice de Moran para a concentração de domicílios de baixa renda ($I = 0,509$) indica autocorrelação espacial positiva moderada. Na figura 24, observamos as regiões com significância estatística, indicadas pelas áreas em tons de verde, que

representam uma confiança de 95% a 99,9%, o que nos permite identificar as áreas onde há autocorrelação espacial significativa.


A figura 25 traz as classificações dos *clusters* identificados na figura anterior: as áreas em vermelho representam os *clusters* “Alto-Alto” (altas concentrações de domicílios de baixa renda estão próximas de outras altas concentrações), enquanto as áreas em azul indicam clusters “Baixo-Baixo” (baixa concentração de baixa renda próxima a outras áreas de baixa concentração). Podemos ver que as áreas “Alto-Alto” se encontram nas periferias da cidade, enquanto a maioria das áreas “Baixo-Baixo” estão localizadas na porção central.

Figura 27 - Significance map para a concentração de domicílios com rendimento igual a 5 até 10 salários-mínimos




Fonte: Autora

Figura 28 - LISA map para a concentração de domicílios com rendimento igual a 5 até 10 salários-mínimos



Fonte: Autora

Figura 29 - Moran scatter plot para a concentração de domicílios com rendimento igual a 5 até 10 salários-mínimos



Fonte: Autora

O índice de Moran para a concentração de domicílios de alta renda ($I = 0,540$) indica também autocorrelação espacial positiva moderada para a classe de maior renda. Na figura 27 observamos as áreas com *clusters* estatisticamente significativos e, na 28, a classificação desses *clusters*, onde podemos ver que os grupos “Alto-Alto”

se encontram centralizados, enquanto os “Baixo-Baixo” estão, em sua maioria, nas periferias.

Assim, as análises de autocorrelação espacial para a concentração de domicílios de baixa e alta renda revelam uma segregação espacial clara entre as duas classes de renda abordadas. As áreas de baixa renda estão concentradas na periferia enquanto as de alta renda são mais centralizadas.

7 CONSIDERAÇÕES FINAIS

A pesquisa realizada relevou informações importantes sobre a relação entre fatores socioeconômicos e a incidência da dengue em Presidente Prudente. A aplicação de técnicas de análise espacial, como o Índice de Moran e o estimador de Kernel, juntamente com a criação de mapas de concentração e significância, permitiu a identificação de padrões de concentração e autocorrelação entre áreas de alta e baixa renda. Esses padrões revelam uma segregação espacial que posiciona as áreas de baixa renda nas periferias da cidade, enquanto as áreas de alta renda se concentram nas regiões centrais.

Além disso, a análise de correlação evidenciou uma relação significativa entre a concentração de domicílios de baixa renda e a maior incidência dos casos de dengue, reforçando a hipótese de que a vulnerabilidade social exerce influência na distribuição espacial da doença. A maior concentração de casos nas periferias pode ser associada a condições menos favoráveis, como menor acesso a serviços de saúde e informação, infraestrutura deficiente e hábitos que auxiliam na propagação do vetor.

Os achados do estudo mostram a importância do direcionamento de políticas públicas às áreas mais vulneráveis, que são mais propensas a apresentarem surtos de dengue. A análise espacial e a correlação entre as classes de renda e a incidência da doença expõe os fatores socioeconômicos envolvidos e trazem subsídio para a implementação de estratégias mais eficazes de conscientização e enfrentamento da dengue na região.

Além disso, a pesquisa contribui para melhorar o entendimento da interação entre as condições socioeconômicas da população e a saúde pública, trazendo uma base para futuras pesquisas e políticas focadas na redução das desigualdades no enfrentamento de doenças transmissíveis.

Referências

ANSELIN, L. Local indicators of spatial association—LISA. *Geographical Analysis*, 27(2), 93-115. DOI: <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>. Acesso em 26 out 2024.

BERTACCO, E. A. M. Análise do Espaço Temporal da Dengue na Área Urbana de Presidente Prudente (SP) Buscando Associação de Fatores de Riscos Ambientais e Bocas de Lobo. Orientador: Prof. Dr. Edilson Ferreira Flores. 2023. 143 p. Dissertação (Mestrado) - Curso de Geografia, Universidade Estadual Paulista, Presidente Prudente, 2023. Acesso em 17 out. 2023.

DINIZ, A. Estatística Espacial: Geoprocessamento 2000. 15 p. Apostila - Universidade Federal de Minas Gerais. Disponível em: <http://www.csr.ufmg.br/geoprocessamento/publicacoes/estespacial.pdf>. Acesso em 05 out. 2023.

ESRI. Average Nearest Neighbor. ArcGIS Pro. Disponível em: <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-statistics/average-nearest-neighbor.htm#:~:text=The%20Nearest%20Neighbor%20Index%20is,in%20a%20hypothetical%20random%20distribution>. Acesso em: 25 maio 2024.

ESRI. How Average Nearest Neighbor Distance (Spatial Statistics) works. ArcGIS Desktop. Disponível em: <https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-statistics-toolbox/h-how-average-nearest-neighbor-distance-spatial-st.htm#:~:text=The%20Average%20Nearest%20Neighbor%20tool,all%20these%20nearest%20neighbor%20distances>. Acesso em: 15 maio 2024.

ESRI. How Band Collection Statistics works. ArcGIS Desktop. Disponível em: <https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-analyst-toolbox/how-band-collection-statistics-works.htm>. Acesso em: 27 setembro 2024.

FLORES, Edilson Ferreira. Técnica do Vizinho Mais Próximo. [Documento interno], 2024. Baseado em: GETIS, Arthur; ORD, J. K. The Analysis of Spatial Association by Use of Distance Statistics. Geographical Analysis, v. 24, n. 3, 1992. MITCHELL, Andy. The ESRI Guide to GIS Analysis, Volume 2. ESRI Press, 2005. Acesso em 20 de abril 2024.

FLORES, Edilson Ferreira. Análise espacial – Análise de Padrões de Área. [Documento interno]. Acesso em 26 out 2024.

GEOAPLICADA. Como baixar os dados do IBGE. YouTube, 1 nov. 2021. Disponível em: <https://www.youtube.com/watch?v=cJyAi4tanN8>. Acesso em: 19 abr. 2024.

GEODA. Local Spatial Autocorrelation (1). Disponível em: https://geodacenter.github.io/workbook/6a_local_auto/lab6a.html#implementation. Acesso em 26 out 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Censo Demográfico 2022: resultados. IBGE. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/22827-censo-demografico-2022.html?edicao=39499&t=resultados>. Acesso em: 19 abr. 2024.

KULARATNE, S. A.; DALUGAMA, C. Dengue infection: Global importance, immunopathology and management. Clin Med (Lond). 2022 Jan;22(1):9-13. doi: 10.7861/clinmed.2021-0791. PMID: 35078789; PMCID: PMC8813012. Acesso em 23 set. 2023.

MINISTÉRIO DA SAÚDE, F. O.; CRUZ SIMONE, M. Christovam Barcellos, organizadores. Abordagens Espaciais na Saúde Pública. Brasília: Ministério da Saúde, 2006. 136 p. (Série B. Textos Básicos de Saúde). v. 1. Acesso em 03 out. 2023.

MINISTÉRIO DA SAÚDE, F. O. et al. Introdução à Estatística Espacial para a Saúde Pública - 2007. 120 p. (Série B. Textos Básicos de Saúde). v. 3. Acesso em 03 out. 2023.

PRESTES-CARNEIRO, L. E. et al. Dengue outbreaks in a city with recent transmission in São Paulo State, Brazil. *International Journal of Environmental Health Research*, 2023. DOI: 10.1080/09603123.2023.2199972. Acesso em 23 set. 2023.

PROENÇA, C. Análise Espacial e Fatores de Risco Ambiental da Dengue na Área Urbana de Presidente Prudente - SP. Orientador: Prof. Dr. Edilson Ferreira Flores. 2023. 44 p. TCC (Graduação) - Curso de Estatística, Universidade Estadual Paulista, Presidente Prudente, 2023. Acesso em 03 out. 2023.

TALITA, T. F. Aplicação de Estatística Espacial Visando o Mapeamento dos Acidentes de Trânsito em Presidente Prudente Orientador: Prof. Dr. Edilson Ferreira Flores. 2010. 64 p. TCC (Graduação) - Curso de Estatística, Universidade Estadual Paulista, Presidente Prudente, 2010. Acesso em 20 mar. 2024.

SÁ-GUIMARÃES, T.; ALVARENGA, E. et al. History, epidemiology and diagnostics of dengue in the American and Brazilian contexts: a review. *Parasites Vectors* 11, 264 (2018). Disponível em: <https://doi.org/10.1186/s13071-2018-2830-8>. Acesso em 23 set. 2023.

WONG, J.; ADAMS, L.; DURBIN, A.; MUÑOZ-JORDÁN, J.; POEHLING, K.; SÁNCHEZ-GONZÁLES, L.; VOLKMAN, H.; PAZ-BAILEY, G. Dengue: A Growing Problem With New Interventions. *Pediatrics*. 2022 Jun 1;149(6). doi: 10.1542/peds.2021-055522. PMID: 35543085. Acesso em 23 set. 2023.


ZARA, A. Estratégias de controle do *Aedes aegypti*: uma revisão. *Epidemiol. Serv. Saúde* [online]. 2016, vol.25, n.2, pp.391-404. ISSN 1679-4974. Disponível em: <http://dx.doi.org/10.5123/S1679-49742016000200017>. Acesso em 23 set. 2023.

ANEXO A

Para facilitar o entendimento do cálculo e aplicação da fórmula do I de Moran, foi resolvido um exercício.

Considerando as regiões A, B, C e D abaixo, vamos calcular o Índice I de Moran para a vizinhança.

Figura 30 - Regiões hipotéticas para exercício I de Moran



Fonte: Autora

$$\bar{y} = \frac{20 + 15 + 24 + 5}{4} = 16$$

$$\sigma^2 = \frac{(20 - 16)^2 + (15 - 16)^2 + (24 - 16)^2 + (5 - 16)^2}{4} = 50,5$$

$$\sigma = \sqrt{\sigma^2} = \sqrt{50,5} = 7,1063$$

A matriz de proximidade W da situação é dada por:

Tabela 5 - Tabela de pesos W para exercício I de Moran

	A	B	C	D
A	0	1	1	0
B	1	0	1	1
C	1	1	0	1
D	0	1	1	0

Dada da fórmula do Índice I de Moran:

$$I = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Teremos:

$$\begin{aligned} \sum_{i=1}^n \sum_{j=1}^n w_{ij} &= (0 + 1 + 1 + 0) + (1 + 0 + 1 + 1) + (1 + 1 + 0 + 1) + (0 + 1 + 1 + 0) \\ &= 10 \end{aligned}$$

$$\begin{aligned} \sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y}) &= (0 \cdot (20 - 16) \cdot (20 - 16) + 1 \cdot (20 - 16) \cdot (15 - 16) + 1 \cdot (20 - 16) \cdot (24 - 16) + 0 \cdot (20 - 16) \cdot (5 - 16)) \\ &+ (1 \cdot (15 - 16) \cdot (20 - 16) + 0 \cdot (15 - 16) \cdot (15 - 16) + 1 \cdot (15 - 16) \cdot (24 - 16) + 1 \cdot (15 - 16) \cdot (5 - 16)) \\ &+ (1 \cdot (24 - 16) \cdot (20 - 16) + 1 \cdot (24 - 16) \cdot (15 - 16) + 0 \cdot (24 - 16) \cdot (24 - 16) + 1 \cdot (24 - 16) \cdot (5 - 16)) \\ &+ (0 \cdot (5 - 16) \cdot (20 - 16) + 1 \cdot (5 - 16) \cdot (15 - 16) + 1 \cdot (5 - 16) \cdot (24 - 16) + 0 \cdot (5 - 16) \cdot (5 - 16)) = -114 \end{aligned}$$

$$\sum_{i=1}^n (y_i - \bar{y})^2 = (20 - 16)^2 + (15 - 16)^2 + (24 - 16)^2 + (5 - 16)^2 = 202$$

Assim, teremos:


$$I = \frac{4}{10} \cdot \frac{(-114)}{202} \cong -0,2258$$

Portanto concluímos que há uma autocorrelação espacial negativa, como o valor não é muito distante de 0, indica uma leve tendência de dispersão espacial.

ANEXO B

Para melhor compreensão dos cálculos por trás da estimativa de Kernel, abaixo estão alguns exercícios resolvidos para diferentes situações.

Figura 31 - Grade de eventos para exercícios de Kernel pontual



Fonte: Autora

No caso de um estimador de Kernel para análise pontual sem atributos, temos a fórmula:

$$\hat{\lambda}_{\tau} = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2$$

Assim, para estimar o ponto A(5,4), faremos:

$$\hat{\lambda}_{\tau}(5,4) = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2$$

Para encontrar h pode ser necessário utilizar o Teorema de Pitágoras: $h^2 = a^2 + b^2$

$$Ponto(3,3) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{(\sqrt{5})^2}{2,5^2} \right) = 0,1528 \cdot 0,0400 = 0,0061$$

$$Ponto(4,3) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{(\sqrt{2})^2}{2,5^2} \right) = 0,1528 \cdot 0,4624 = 0,0706$$

$$Ponto(3,4) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{2^2}{2,5^2} \right) = 0,1528 \cdot 0,1296 = 0,0198$$

$$Ponto(4,6) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{2^2}{2,5^2} \right) = 0,1528 \cdot 0,1296 = 0,0198$$

$$Ponto(7,4) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{2^2}{2,5^2} \right) = 0,1528 \cdot 0,1296 = 0,0198$$

$$\hat{\lambda}_\tau(5,4) = 0,0061 + 0,0706 + 0,0198 + 0,0198 + 0,0198 = 0,1361$$

E, no caso de um estimador de Kernel com atributos, teremos a fórmula alterada para:

$$\hat{\lambda}_\tau = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2} \right)^2 y_i$$

Assim, para o mesmo A(5,4), teríamos:

$$\hat{\lambda}_\tau(5,4) = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2} \right)^2 y_i$$

$$Ponto(3,3) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{(\sqrt{5})^2}{2,5^2} \right)^2 \cdot 1 = 0,1528 \cdot 0,0400 \cdot 1 = 0,0061$$

$$Ponto(4,3) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{(\sqrt{2})^2}{2,5^2} \right)^2 \cdot 2 = 0,1528 \cdot 0,4624 \cdot 2 = 0,1413$$


$$Ponto(3,4) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{2^2}{2,5^2} \right)^2 \cdot 2 = 0,1528 \cdot 0,1296 \cdot 2 = 0,00396$$

$$Ponto(4,6) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{2^2}{2,5^2}\right)^2 \cdot 4 = 0,1528 \cdot 0,1296 \cdot 4 = 0,0792$$

$$Ponto(7,4) = \frac{3}{3,14 \cdot 2,5^2} \left(1 - \frac{2^2}{2,5^2}\right)^2 \cdot 1 = 0,1528 \cdot 0,1296 \cdot 1 = 0,0198$$

$$\hat{\lambda}_\tau(5,4) = 0,0061 + 0,1413 + 0,0396 + 0,0792 + 0,0198 = 0,2860$$

Figura 32 - Grade de eventos para exercícios de Kernel em área



Fonte: Autora

No caso de um estimador de Kernel de área, sem atributos, temos a fórmula:

$$\hat{\lambda}_{\tau}(s) = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2$$

Assim, para estimar a área $A(3,5)$, temos:

$$\hat{\lambda}_{\tau}(3,5) = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2$$

$$Ponto(3,3) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 = 0,0956 \cdot 0,8395 = 0,0802$$

$$Ponto(1,5) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 = 0,0956 \cdot 0,8395 = 0,0802$$

$$Ponto(3,7) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 = 0,0956 \cdot 0,8395 = 0,0802$$

$$Ponto(5,5) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 = 0,0956 \cdot 0,8395 = 0,0802$$

$$\hat{\lambda}_{\tau}(5,4) = 0,0802 + 0,0802 + 0,0802 + 0,0802 = 0,3208$$

E, finalmente, para um estimador de Kernel de área, com atributos, temos:

$$\hat{\lambda}_{\tau}(s) = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2 y_i$$

Assim, para estimar a área $A(3,5)$, temos:

$$\hat{\lambda}_{\tau}(3,5) = \sum_{i=1}^n \frac{3}{\pi \tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2 y_i$$

$$Ponto(3,3) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 \cdot 1 = 0,0956 \cdot 0,8395 \cdot 1 = 0,0802$$

$$Ponto(1,5) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 \cdot 3 = 0,0956 \cdot 0,8395 \cdot 3 = 0,2406$$

$$Ponto(3,7) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 \cdot 2 = 0,0956 \cdot 0,8395 \cdot 2 = 0,1604$$

$$Ponto(5,5) = \frac{3}{3,14 \cdot 3,16^2} \left(1 - \frac{2^2}{3,16^2}\right)^2 \cdot 1 = 0,0956 \cdot 0,8395 \cdot 1 = 0,0802$$

$$\hat{\lambda}_\tau(5,4) = 0,0802 + 0,2406 + 0,1604 + 0,0802 = 0,5614$$

ANEXO C

Este anexo busca complementar as análises realizadas ao longo deste estudo, trazendo algumas reflexões sobre a influência da seleção do raio do kernel nos mapas de densidade gerados. A ferramenta de seleção automática do raio ideal não foi utilizada durante a execução desta pesquisa, por divergências no tipo de estimador de Kernel utilizado na pesquisa e aquele requerido pela ferramenta. Ela foi incluída no anexo por sua relevância e potencial interesse para estudos futuros na área.

Enquanto os mapas no estudo principal utilizam parâmetros definidos manualmente, este anexo procura demonstrar que o padrão espacial identificado é consistente, fortalecendo assim a validade das conclusões obtidas.

Para a seleção do raio ideal é utilizada a ferramenta *Incremental Spatial Autocorrelation*, no software ArcGIS, que analisa a distribuição espacial de valores numéricos associados a entidades geográficas e faz o cálculo da autocorrelação espacial para diferentes distâncias, avaliando a existência de agrupamentos. Por associar valores numéricos às entidades estudadas, a ferramenta pede uma coluna de pesos para basear as contas. Como neste estudo os mapas de concentração para os casos de dengue são baseados em estimadores de Kernel sem atributos, os cálculos utilizaram uma coluna com menos variabilidade já presente nos dados, para fins de estudo.

Todas as possibilidades abaixo têm o mesmo raio inicial, 200 metros, com mudanças em seus incrementos, sendo eles 200 metros, 1000 metros e 2000 metros.

Figura 33 - Exemplo de entrada para a ferramenta Incremental Spatial Autocorrelation

The screenshot shows the 'Incremental Spatial Autocorrelation' tool dialog box. The main area contains the following settings:

- Input Features:** 2023_join
- Input Field:** constante
- Number of Distance Bands:** 10 (with a slider bar)
- Beginning Distance (optional):** 200
- Distance Increment (optional):** 200
- Distance Method (optional):** EUCLIDEAN
- Row Standardization (optional):** ☒
- Output Table (optional):** (empty field)

On the right side, there is a help panel titled 'Distance Increment (optional)' with the following text:

The distance to increase after each iteration. The distance used in the analysis starts at the Beginning Distance and increases by the amount specified in the Distance Increment. The value entered for this parameter should be in the units of the Output Coordinate System environment setting.


At the bottom of the dialog are buttons for 'OK', 'Cancel', 'Environments...', '<< Hide Help', and 'Tool Help'.

Fonte: Autora

Os resultados da ferramenta são apresentados num arquivo *pdf* gerado após sua execução. Nele é possível observar o comportamento do *z-score* em cada um dos raios testados.


Abaixo seguem os resultados para os três valores escolhidos.

Figura 34 - Resultado da Incremental Spatial Autocorrelation para incremento de 200 metros




Fonte: Autora

Figura 35 - Resultado da Incremental Spatial Autocorrelation para incremento de 1000 metros



Fonte: Autora

Figura 36 - Resultado da Incremental Spatial Autocorrelation para incremento de 2000 metros



Fonte: Autora

Analisando os gráficos, podemos observar que o incremento de 200 metros (figura 34) apresenta um padrão crescente para o z-score, mas sem um pico significativo, sugerindo que, nessa escala, os dados não possuem um agrupamento espacial forte em nenhum dos raios testados.

Já nos gráficos com incrementos de 1000 e 2000 metros (figuras 35 e 36, respectivamente), podemos observar os valores do z-score crescendo até atingirem um pico e então diminuírem. Esses picos mostram a distância onde o agrupamento espacial é mais significativo e, portanto, a medida ideal para uso na criação de mapas de Kernel.

Para encontrar a distância exata indicada no gráfico, a saída da ferramenta também exibe uma lista das distâncias testadas e indica o pico, ou picos, caso haja mais de um, chamada de *Global Moran's I Summary by Distance*. Abaixo estão as listas associadas aos incrementos de 1000 e 2000 metros que exibiram algum pico.

Figura 37 - Moran's I Summary by Distance para incremento de 1000 metros

Global Moran's I Summary by Distance					
Distance	Moran's Index	Expected Index	Variance	z-score	p-value
200.00*	0.156448	-0.000087	0.000007	58.547991	0.000000
1200.00*	0.140222	-0.000087	0.000000	204.090544	0.000000
2200.00	0.126769	-0.000087	0.000000	327.120668	0.000000
3200.00	0.112277	-0.000087	0.000000	441.267157	0.000000
4200.00	0.093207	-0.000087	0.000000	545.070022	0.000000
5200.00	0.073644	-0.000087	0.000000	631.272367	0.000000
6200.00	0.055646	-0.000087	0.000000	649.581417	0.000000
7200.00	0.039552	-0.000087	0.000000	639.112627	0.000000
8200.00	0.026021	-0.000087	0.000000	606.314909	0.000000
9200.00	0.015740	-0.000087	0.000000	535.488525	0.000000

First Peak (Distance, Value): 6200.00, 649.581417

Max Peak (Distance, Value): 6200.00, 649.581417

Fonte: Autora

Figura 38 - Moran's I Summary by Distance para incremento de 2000 metros

Global Moran's I Summary by Distance					
Distance	Moran's Index	Expected Index	Variance	z-score	p-value
200.00*	0.156448	-0.000087	0.000007	58.547991	0.000000
1439.40*	0.137414	-0.000087	0.000000	241.216000	0.000000
2678.80	0.120524	-0.000087	0.000000	383.116700	0.000000
3918.20	0.098645	-0.000087	0.000000	495.798846	0.000000
5157.60	0.074465	-0.000087	0.000000	629.333535	0.000000
6397.00	0.052132	-0.000087	0.000000	647.131453	0.000000
7636.40	0.033397	-0.000087	0.000000	629.852782	0.000000
8875.80	0.018694	-0.000087	0.000000	563.807742	0.000000
10115.20	0.009540	-0.000087	0.000000	438.975850	0.000000
11354.60	0.004599	-0.000087	0.000000	317.655199	0.000000

First Peak (Distance, Value): 6397.00, 647.131453

Max Peak (Distance, Value): 6397.00, 647.131453


Fonte: Autora

Os resultados exatos obtidos, de 6200 metros e 6397 metros apresentam uma diferença de menos de 200 metros, um valor relativamente pequeno considerando o tamanho do raio. Devido à natureza do Kernel, que é uma função suavizada e contínua, variações pequenas no raio não resultam em mudanças significativas nos padrões de concentração espacial. Portanto, é razoável concluir que os resultados

dos mapas de concentração gerados para esses dois raios serão extremamente semelhantes.

O Kernel, ao ser aplicado, suaviza os dados de maneira progressiva, de modo que alterações sutis no tamanho do raio não causam alterações drásticas no resultado. Com isso, a diferença de apenas 197 metros entre os dois raios não é suficiente para justificar a necessidade de gerar ambos os mapas. Isso se deve ao fato de que, para a análise de concentração dos casos, ambos os mapas apresentariam padrões espaciais muito próximos, sendo a variação mínima o suficiente para não afetar as conclusões gerais da análise.

Figura 39 - Mapa de Kernel com raio de 6200 metros



Fonte: Autora

Podemos observar que o mapa gerado com o raio de 6200 metros apresentou um resultado muito semelhante ao do Kernel sem atributos, utilizado na análise de concentração dos casos em 2023 (Figura 17). Isso demonstra que o Kernel com o raio automático é altamente confiável, especialmente em situações em que não há atributos específicos a serem considerados, como no caso da análise de concentração dos casos.

A semelhança dos resultados reforça a ideia de que o raio automático ajustado pelo ArcMap é adequado para modelar a densidade de casos de forma eficaz, quando não há atributos adicionais.