

ANÁLISE DA DISTRIBUIÇÃO ESPACIAL DO NÚMERO DE CASOS DE COVID-19 NO MUNICÍPIO DE TOLEDO-PARANÁ

Analysis of the spatial distribution of the number of COVID-19 cases in the municipality of Toledo-Paraná

Análisis de la distribución espacial del número de casos de COVID-19 em el município de Toledo-Paraná

DOI: [10.48075/igepec.v28i1.31804](https://doi.org/10.48075/igepec.v28i1.31804)

Amilton Luciano Garcia da Silva
Universidade Estadual do Oeste do Paraná – Cascavel

Gustavo Henrique Dalposso
Universidade Tecnológica Federal do Paraná

Miguel Angel Uribe-Opazo
Universidade Estadual do Oeste do Paraná – Cascavel

Elizabeth Giron Cima
Universidade Estadual do Oeste do Paraná - Toledo

ANÁLISE DA DISTRIBUIÇÃO ESPACIAL DO NÚMERO DE CASOS DE COVID-19 NO MUNICÍPIO DE TOLEDO-PARANÁ

Analysis of the spatial distribution of the number of COVID-19 cases in the municipality of Toledo-Paraná

Análisis de la distribución espacial del número de casos de COVID-19 em el município de Toledo-Paraná

Amilton Luciano Garcia da Silva¹
Gustavo Henrique Dalposso²
Miguel Angel Uribe-Opazo³
Elizabeth Giron Cima⁴

Resumo: A estatística espacial desempenha um papel importante em diferentes áreas do conhecimento, fornecendo metodologias que possibilitam a identificação de padrões espaciais (*clusters*) e a determinação de regiões com características semelhantes dos dados em estudo. No presente estudo, foi utilizada a metodologia chamada de estatística espacial de dados de áreas para investigar a taxa de crescimento de casos de COVID-19 no município de Toledo, no estado do Paraná-Brasil, nos períodos de junho a outubro do ano de 2020. Foram gerados mapas que identificaram as regiões em que a autocorrelação espacial apresentou significância estatística. Concluiu-se que bairros que apresentavam baixa taxa de contaminação pela COVID-19 foram incorporados pelos bairros adjacentes, que possuíam alta taxa de contaminação. Essa constatação ressalta a relevância da estatística espacial de dados de áreas, uma vez que, mediante a devida atenção das autoridades de saúde municipais, permitem uma alocação adequada de recursos para tratamentos localizados, reduzindo os impactos causados pelas doenças, possibilitando prevenir a ocorrência de situações semelhantes no futuro e evitando a transformação de toda a região em um extenso aglomerado caracterizado por taxas elevadas de contaminação.

Palavras-chave: Autocorrelação espacial. Índice de Moran. Índice de autocorrelação espacial local. LISA *cluster map*. Estatística espacial de dados de áreas.

Abstract: *Spatial statistic play a significant role in various fields of knowledge, providing methodologies that enable the identification of spatial patterns (clusters) and the determination of regions with similar characteristics of the data under study. In the present study, a methodology called spatial statistics of area data was used to investigate the growth rate of COVID-19 cases in the city of Toledo, in the state of Paraná-Brazil, during the periods from June to October 2020. Maps were generated that identified the regions where spatial autocorrelation showed statistical significance. It was concluded that neighborhoods that had a low rate of COVID-19 contamination were incorporated by adjacent neighborhoods, which had a high rate of contamination. This finding underscores the relevance of spatial statistic of area data, as, with due attention from municipal health authorities, they allow for an appropriate allocation of resources for localized treatments, reducing the impacts caused by diseases, enabling the prevention of similar situations in the future, and avoiding the transformation of the entire region into an extensive cluster characterized by high contamination rates.*

¹ PGEAGRI, Universidade Estadual do Oeste do Paraná (UNIOESTE), Cascavel-PR, Brasil. E-mail: amilton.silva1@unioeste.br

² PPGGIO, Universidade Tecnológica Federal do Paraná (UTFPR), Toledo-PR, Brasil. E-mail: gustavodalposso@hotmail.com

³ PGEAGRI, Universidade Estadual do Oeste do Paraná (UNIOESTE), Cascavel-PR, Brasil. E-mail: miguel.opazo@unioeste.br

⁴ PGDRA, Universidade Estadual do Oeste do Paraná (UNIOESTE), Toledo-PR, Brasil. E-mail: Elizabeth.cima@unioeste.br

Keywords: *Spatial autocorrelation. Moran's index. Local spatial autocorrelation index. LISA cluster map. Spatial statistic of area data.*

Resumen: *La estadística espacial desempeña un papel importante en diferentes áreas de conocimiento, ofreciendo metodologías que posibilitan la identificación de padrones espaciales (clusters) y la determinación de regiones con características similares de los datos en estudio. En el presente estudio, fue utilizado la metodología llamada de estadística espacial de datos de áreas para investigar la tasa de crecimiento de los casos de COVID-19, en el municipio de Toledo, en el estado del Paraná-Brasil, en los períodos de junio a octubre del año de 2020. Fueron generados mapas que identifican las regiones en que la autocorrelación espacial presentó significancia estadística. Como conclusión se obtuvieron que barrios que presentan bajas tasa de contaminación por COVID-19 fueron incorporados pelos barrios adyacentes, que poseían altas tasas de contaminación. Esa constatación resalta la relevancia da estadística espacial de dados de áreas, una vez que, mediante la debida atención de las autoridades de salud municipales permitirá una distribución adecuada de los recursos para tratamientos localizados, reduciendo los impactos causados por las enfermedades, posibilitando prevenir la ocurrencia de situaciones semejantes en el futuro y impidiendo la transformación de toda la región en un extenso aglomerado caracterizado por tasas elevadas de contaminación.*

Palabras clave: *Autocorrelación espacial. Índice de Moran. Índice de autocorrelación espacial local. LISA cluster map. Estadística espacial de datos de áreas.*

INTRODUÇÃO

Os coronavírus infectam tanto humanos quanto animais e são responsáveis por ocasionar infecções agudas e graves no trato respiratório. O SARS-CoV-2 (*Severe Acute Respiratory Syndrome 2*) é um vírus da família de vírus *Coronaviridae* que, ao infectar humanos, causa uma doença chamada COVID-19, sigla em inglês para doença do coronavírus 2019. Esse vírus é o sétimo membro da família dos coronavírus que infectam humanos. Por ser um microrganismo que até pouco tempo não era transmitido entre humanos, ele ficou conhecido, no início da pandemia, como “novo coronavírus” (ANDERSEN *et al.*, 2020; ZHU *et al.*, 2020).

Diante da pandemia de COVID-19, provocada pelo vírus SARS-CoV-2, que representa um dos maiores desafios sanitários do século XXI, com consequências epidemiológicas, sociais, econômicas, políticas, históricas e culturais inéditas na história recente das epidemias, a análise espacial de dados se mostra como uma ferramenta essencial para os gestores de saúde pública. Essa análise permite visualizar espacialmente o problema e associar outras variáveis que podem agravar a situação. Além disso, possibilita estimar tendências futuras, auxiliando as instâncias decisórias, com o propósito de reduzir o número de mortes e o colapso do sistema de saúde (NOBRE *et al.*, 2014).

Pradipta *et al.* (2023) realizaram um estudo na província de Sumatra Ocidental, na Indonésia, com o objetivo de analisar a distribuição espacial da COVID-19 utilizando o índice local de Moran (MORAN, 1950). Os resultados apontaram para a existência de autocorrelação espacial positiva, formando *clusters* na região de estudo. Por sua vez, Cima *et al.* (2022) estudaram a distribuição espacial da taxa de incidências de casos de COVID-19 no estado do Paraná e a correlação com variáveis socioeconômicas, como o índice de Gini, índice de Theil-L e índice de desenvolvimento humano municipal (IDHM). Os autores identificaram correlações entre a taxa de incidências de casos de COVID-19 e o índice Gini, índice Theil-L e IDHM nas regiões em estudo, em que as áreas de maior risco se concentram nas macrorregiões leste e oeste do estado do Paraná.

Neste contexto, torna-se importante e necessário entender o comportamento espacial da transmissão do vírus SARS-CoV-2, causador da doença COVID-19, a fim de aprimorar a compreensão e análise de eventuais padrões.

Assim, este estudo se justifica pela importância de realizar uma análise espacial detalhada da evolução da COVID-19 no município de Toledo-Paraná-Brasil, a fim de identificar áreas de maior risco. Dessa forma, este trabalho pode contribuir para o monitoramento de situações semelhantes no futuro, mediante a análise espacial de dados e a implementação de tomada de decisões e ações preventivas inerentes à realidade local.

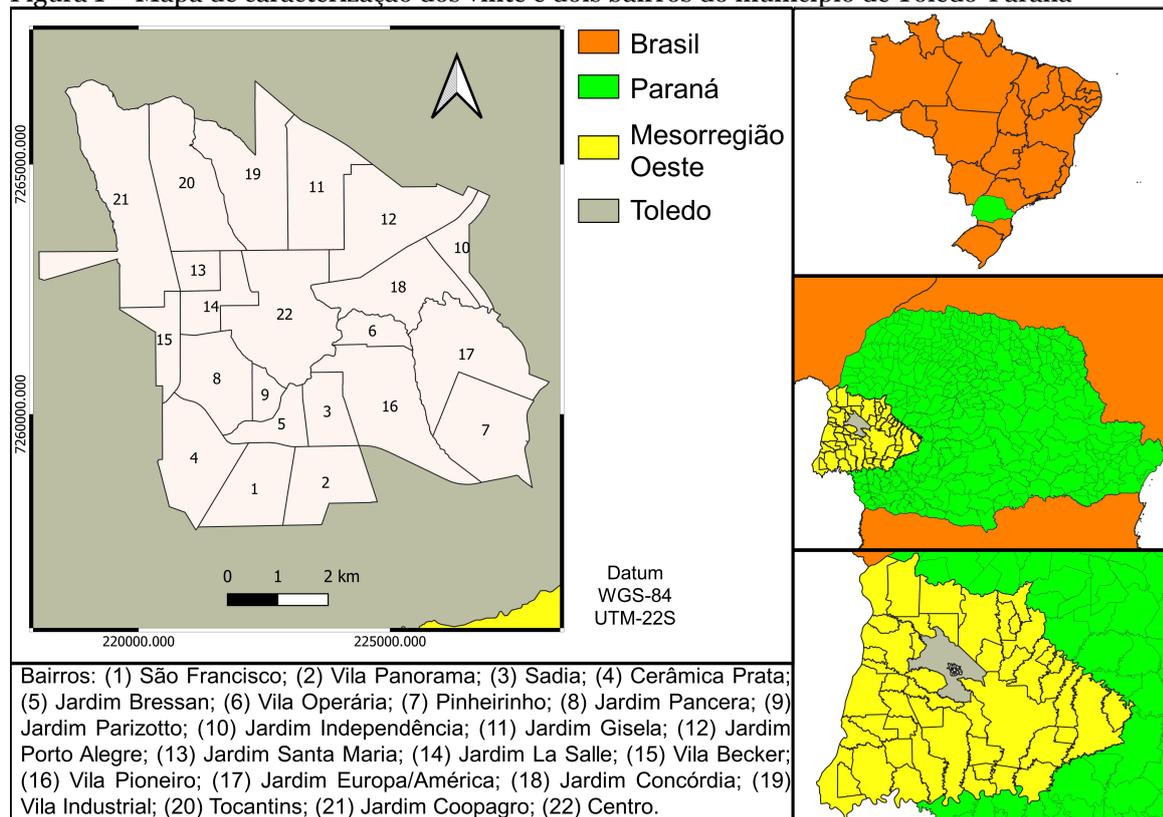
Este trabalho tem como objetivo investigar, por meio da metodologia de análise espacial de dados de áreas, a taxa de crescimento do número de casos de COVID-19 nos bairros do município de Toledo-Paraná-Brasil, nos períodos compreendidos entre 25/06/2020 e 20/10/2020. Para isso, elaborou-se mapas temáticos que mostram a distribuição espacial da taxa de crescimento do número de casos de COVID-19 nos bairros de Toledo e investigou-se a existência de autocorrelação espacial dessa variável.

A estrutura deste artigo é composta pelos seguintes elementos: após a introdução, apresenta-se a metodologia utilizada no desenvolvimento do estudo; em seguida, expõe-se os resultados obtidos e as discussões decorrentes; por fim, tecem-se as considerações finais e as referências bibliográficas.

2 – MATERIAL E MÉTODOS

O município de Toledo está localizado no oeste do estado do Paraná, Brasil, e possui aproximadamente 150 mil habitantes e uma área de 1.198 Km² (IBGE, 2023). Este estudo abrange os 22 bairros do município de Toledo, conforme ilustrado na Figura 1. A variável georreferenciada em estudo foi a taxa de crescimento percentual do número de casos de COVID-19. Para a construção do banco de dados espaciais, foi utilizado um *shapefile* dos bairros de Toledo (IBGE, 2022).

Figura 1 – Mapa de caracterização dos vinte e dois bairros do município de Toledo-Paraná



Fonte: Elaboração própria a partir de dados do IBGE (2022).

Os dados utilizados foram fornecidos pela Secretaria de Saúde do município de Toledo e corresponde ao período compreendido entre 25/06/2020 e 20/10/2020, divididos em 16 períodos. Para o cálculo da taxa de crescimento percentual do número de casos de COVID-19 foi utilizada a Equação (1) (RAMOS; SANCHES, 2000):

$$T_p = \frac{V_p - V_a}{V_a} \times 100, \quad (1)$$

em que, T_p é a taxa de crescimento percentual do número de casos de COVID-19 no período presente, V_p e V_a são os valores da taxa de crescimento percentual do número de casos de COVID-19 do período presente e anterior, respectivamente.

2.1 – ESTATÍSTICA ESPACIAL DE DADOS DE ÁREAS

A estatística espacial de dados de áreas consiste na explícita consideração da localização geográfica dos dados durante o processo de coleta, descrição e análise. É comum que fenômenos sociais, econômicos e naturais apresentem características específicas que envolvem autocorrelações dos dados associado às distâncias entre eles. A estatística espacial de dados de áreas é um método estatístico que permite a descrição e visualização de distribuições espaciais, a identificação e gerenciamento de fenômenos afetados pela localização geográfica, e a modelagem de processos espaciais que consideram a estrutura de dependência espacial entre os dados (CÂMARA *et al.*, 2004; MARCONATO *et al.*, 2015).

2.1.1 – Matriz de Proximidade Espacial

A matriz de proximidade espacial (W), também chamada de matriz de vizinhança, representa a relação de proximidade entre as unidades espaciais em análise. Essa matriz é uma ferramenta importante para descrever o padrão espacial dos dados de área e estimar a autocorrelação espacial, que mede o grau de dependência entre os valores de uma variável observados em diferentes localizações (CÂMARA *et al.*, 2004; DALPOSSO, 2010).

De acordo com Câmara *et al.* (2004) a matriz W é uma matriz quadrada de dimensão $n \times n$ onde n é o número de unidades espaciais, e cada elemento w_{ij} indica o grau de conexão ou interação entre a unidade espacial i e a unidade espacial j , de acordo com algum critério de distância ou contiguidade. O critério de contiguidade (ou adjacência) pode ser calculado da seguinte maneira: $w_{ij} = 1$, se a unidade espacial i compartilha um lado comum com a unidade espacial j , e $w_{ij} = 0$ caso contrário. Como a matriz de proximidade é utilizada em cálculos de indicadores, é útil normalizar suas linhas, para que a soma dos pesos de cada linha seja igual a 1.

Para definir a matriz de proximidade espacial que considera a adjacência entre as unidades espaciais, é preciso estabelecer um critério de vizinhança, que pode ser baseado em movimentos de peças do jogo de xadrez, como rainha, torre e bispo (CÂMARA *et al.*, 2004). A Figura 2 exemplifica os critérios de vizinhança para identificar os vizinhos da área j . Na Figura 2 (a), o critério adotado é o da rainha (*Queen*), ou seja, são vizinhos da área j todas as áreas que têm intersecção não nula com ela. Na Figura 2 (b), o critério adotado é o da torre (*Rook*), ou seja, são vizinhos da área j apenas as áreas que têm um lado em comum com ela. Na Figura 2 (c), o critério adotado é o do bispo (*Bishop*), ou seja, são vizinhos da área j apenas as áreas que se localizam nas diagonais. Neste estudo são considerados a adjacência rainha.

Figura 2 – Representação dos tipos de adjacência entre unidades espaciais: (a) adjacência rainha (*Queen*); (b) adjacência torre (*Rook*); e (c) adjacência bispo (*Bishop*)

A	B	C	D	A	B	C	D	A	B	C	D
E	F	G	H	E	F	G	H	E	F	G	H
I	J	K	L	I	J	K	L	I	J	K	L
M	N	O	P	M	N	O	P	M	N	O	P
(a)				(b)				(c)			

Fonte: Elaboração própria.

2.1.2 – Autocorrelação Espacial

A autocorrelação espacial é definida como a relação entre os valores de uma variável observados em diferentes pontos no espaço. Essa relação pode ser caracterizada por meio de uma série de medidas estatísticas que avaliam a similaridade entre as observações espaciais. Neste sentido a literatura apresenta o Índice Global de Moran (I) e o Índice Local de Moran-LISA (I_i) como medidas de autocorrelação espacial (CAPUCHO; PARRÉ, 2012; CIMA *et al.*, 2021).

O Índice Global de Moran (I) é uma medida que avalia a intensidade da autocorrelação espacial presente nos dados, e seus valores variam de -1 a +1. Uma autocorrelação espacial positiva sugere a presença de agrupamentos no espaço, em que regiões com valores elevados (ou baixos) para uma variável em estudo, seja ela discreta ou contínua, tendem a estar cercadas por regiões com valores elevados (ou baixos). Por outro lado, caso seja uma autocorrelação espacial negativa, então pode-se esperar que se uma região apresentar valores elevados (ou baixos) para uma variável contínua ou discreta, deverá estar cercada por regiões cujos valores para esta mesma variável devem ser baixos (ou elevados). Um valor zero indica ausência de autocorrelação espacial dos dados (NEVES *et al.*, 2000; DALPOSSO, 2010).

Segundo Anselin (1995) o Índice Global de Moran (I) é (Equação (2)):

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{S_0 \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (2)$$

em que, n é o número de unidades espaciais em estudo, x_i e x_j : valores da variável X em estudo considerando as unidades espaciais i e j ; \bar{x} valor médio da variável X na região em estudo; w_{ij} : elemento da matriz de proximidade espacial normalizada W , correspondente aos pesos espaciais 0 ou 1, segundo o critério de adjacência rainha (Queen); S_0 : somatório dos elementos w_{ij} da matriz W , ou seja, $S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}$.

Outra abordagem para a análise da autocorrelação espacial é oferecida pelo Índice Local de Moran – LISA (*Local Indicator of Spatial Association*). O cálculo desse índice (Equação (3)) permite a decomposição da autocorrelação espacial em *cluster*, bem como a avaliação da significância desses padrões. Desta forma, o índice LISA possibilita a atribuição de um valor para cada localização analisada e a elaboração de um mapa de dependência espacial local, o qual apresenta informações sobre a natureza localizada da associação indicada pelo Índice Global de Moran (ANSELIN, 1995; NASCIMENTO; JUSTO, 2023).

$$I_i = \frac{x_i - \mu}{\sigma_0^2} \sum_{j=1}^n w_{ij} (x_j - \mu), \quad (3)$$

em que, I_i é o Índice Local de Moran para a unidade espacial i , com $i = 1, \dots, n$; σ_0^2 : variância populacional da variável X em estudo nas n unidades espaciais, $\sigma_0^2 = \frac{(x_i - \mu)^2}{n}$; x_i : observação da variável de X de interesse na unidade espacial i , para $i = 1, \dots, n$; μ : média da variável X das n unidades espaciais.

A significância estatística do uso do Índice de Moran Global e Local é realizada por um teste de pseudo-significância (ANSELIN, 1995).

O mapa de *cluster* LISA representa a distribuição dos índices LISA, permitindo identificar o tipo de correlação existentes entre as regiões. Neste mapa, as regiões são agrupadas em *cluster* da seguinte maneira: Alto-Alto (AA), onde regiões com valores elevados para uma determinada variável tendem a estar cercadas por regiões com valores semelhantes; Alto-Baixo (AB), onde regiões com valores elevados para uma variável estão cercadas por regiões com valores baixos para a mesma variável; Baixo-Baixo (BB), onde regiões com valores baixos para uma variável estão cercadas por regiões com valores baixos; e Baixo-Alto (BA), onde regiões com valores baixos para uma variável tem regiões vizinhas com valores elevados para a mesma variável. As regiões que não se encontram em nenhum desses agrupamentos acima, ocorrem porque o valor da variável para essa região não é significativo estatisticamente (MARCELLO *et al.*, 2019).

Para os cálculos dos indicadores e construção dos mapas foi utilizado o *software* R 4.2.2 (R Core Team, 2022) e para o geoprocessamento dos dados os *softwares* GeoDa 1.18 (ANSELIN; SYABRI; KHO, 2006) e QGIS 3.16.16 (SHERMAN *et al.*, 2020).

3 – RESULTADOS E DISCUSSÕES

A Tabela 1 apresenta as estatísticas descritivas da taxa de crescimento percentual do número de casos de COVID-19 (T_p) nos 22 bairros do município de Toledo-Paraná em diferentes períodos de tempo. Os períodos foram definidos como: P1: 25/06 a 02/07; P2: 03/07 a 09/07; P3: 10/07 a 20/07; P4: 21/07 a 27/07; P5: 28/07 a 04/08; P6: 05/08 a 11/08; P7: 12/08 a 17/08; P8: 18/08 a 24/08; P9: 25/08 a 30/08; P10: 31/08 a 08/09; P11: 09/09 a 14/09; P12: 15/09 a 21/09; P13: 22/09 a 29/09; P14: 30/09 a 06/10; P15: 07/10 a 12/10; P16: 13/10 a 20/10. Identifica-se que em todos os períodos em estudo existe alta heterogeneidade nos dados (CV > 30%).

Ao comparar as taxas de crescimento percentual do número de casos de COVID-19 do período P1 (de 25/06 a 02/07) com o período P2 (de 03/07 a 09/07), destaca-se um aumento acentuado no valor máximo da taxa de crescimento percentual do número de casos de COVID-19, passando de 103,23% para 200%. Este valor máximo de contaminação de casos de COVID-19 se manteve constante no período subsequente P3 (de 10/07 a 20/07), que representou o último período com valores máximos de contaminação expressiva.

Este resultado sugere que a população economicamente mais vulnerável de Toledo enfrentou uma grave dificuldade financeira, decorrente do aumento da taxa de contágio por COVID-19, pois, como descrevem Porsse *et al.* (2020) esse aumento da taxa de contágio por COVID-19, reflete no cenário econômico, afetando principalmente famílias de baixa renda. Essa situação tende a agravar problemas de pobreza e desigualdade social, afetando de forma desproporcional as populações mais vulneráveis em termos de renda.

Verifica-se também na Tabela 1, que o valor máximo da taxa de crescimento percentual de casos de COVID-19 para o período P15 (de 07/10 a 12/10) foi de apenas 5,96%. Esse resultado está relacionado à política de prevenção da doença aplicada pelo município, que manteve a suspensão do funcionamento de diversos estabelecimentos, atividades e serviços no município de Toledo a partir de 31/08.

Resultados semelhantes foram obtidos por Houvèssou, Souza e Silveira (2021) que estudaram medidas de contenção e a incidência de casos de COVID-19 com dados da África do Sul, Alemanha, Brasil, Espanha, Estados Unidos, Itália e

Nova Zelândia e concluíram que após a implementação de medidas de contenção, houve diminuição considerável no número de casos confirmados de COVID-19.

Neste sentido, Cardoso *et al.* (2021) informam que diante da crise econômica decorrente da pandemia, vários países adotaram políticas emergenciais para minimizar seus impactos socioeconômicos e que grande parte dessas medidas são amparadas em transferências de renda ou benefícios temporários como foi o caso de licenças remuneradas para os indivíduos contaminados por COVID-19.

Tabela 1 – Estatísticas descritivas da taxa de crescimento percentual do número de casos de COVID-19 (T_p) nos períodos compreendidos entre 25/06/2020 e 20/10/2020

Período	Mínimo	Q1	Mediana	Média	Q3	DP	CV(%)	Máximo
P1	0	41,36	53,57	52,07	69,51	34,00	65,29	103,23
P2	0	19,89	30,31	40,32	44,86	41,40	102,67	200,00
P3	0	21,73	28,99	39,18	38,54	44,79	114,31	200,00
P4	0	8,27	12,36	13,55	18,06	9,01	66,49	34,37
P5	0	4,31	6,42	6,03	8,21	4,36	72,30	16,66
P6	0	6,75	10,41	11,34	16,60	8,52	75,13	30,16
P7	0	1,09	2,79	3,79	4,13	5,66	149,34	27,27
P8	0	9,30	13,28	16,76	24,66	14,04	65,87	61,02
P9	0	2,04	5,57	6,41	8,93	6,62	103,27	27,27
P10	0	3,57	6,40	7,92	10,97	6,50	82,07	24,49
P11	0	4,81	8,58	9,24	11,38	8,58	92,85	40,98
P12	0	5,06	8,72	10,16	15,51	6,68	60,94	20,33
P13	0	5,24	10,71	10,71	15,17	7,11	66,38	25,86
P14	0	5,32	8,14	7,80	10,53	5,52	70,76	22,22
P15	0	0,19	2,22	2,19	3,52	1,76	80,36	5,96
P16	0	2,18	3,33	3,58	4,86	2,68	74,86	11,53

Q1: primeiro quartil; Q3: terceiro quartil; DP: desvio padrão; CV: coeficiente de variação; P1: 25/06 a 02/07; P2: 03/07 a 09/07; P3: 10/07 a 20/07; P4: 21/07 a 27/07; P5: 28/07 a 04/08; P6: 05/08 a 11/08; P 7: 12/08 a 17/08; P8: 18/08 a 24/08; P9: 25/08 a 30/08; P10: 31/08 a 08/09; P11: 09/09 a 14/09; P12: 15/09 a 21/09; P13: 22/09 a 29/09; P14: 30/09 a 06/10; P15: 07/10 a 12/10; P16: 13/10 a 20/10.

Fonte: Resultados da Pesquisa.

A Tabela 2 apresentam os valores do Índice Global de Moran (I) da taxa de crescimento percentual do número de casos de COVID-19 (T_p) para cada período, bem como seus respectivos p-valores do teste de pseudo-significância (ANSELIN, 1995).

Verifica-se que no período P2 (de 03/07 a 09/07) o Índice Global de Moran (I) foi negativo e significativo ao nível de 5% de probabilidade ($I=-0,230$, p-valor=0,027), indicando que houve uma autocorrelação espacial negativa, ou seja, bairros com baixa taxa de crescimento do número de casos de COVID-19 estiveram cercados por outros bairros com altas taxas de crescimento do número de casos de COVID-19, e vice-versa.

Por outro lado, no período P10 (de 31/08 a 08/09), o índice (I) foi positivo e significativo ao nível de 5% de probabilidade ($I=0,213$, p-valor=0,027), indicando que houve uma autocorrelação espacial positiva, ou seja, bairros com alta taxa de crescimento do número de casos de COVID-19 estiveram cercados por outros bairros também com elevada incidência de COVID-19, e vice-versa.

Tabela 2 – Índice Global de Moran (I) da taxa de crescimento do número de casos de COVID-19 (T_p) por período no ano de 2020

Período	I	p-valor	Período	I	p-valor
P1	-0,173	0,193 ns	P9	0,186	0,055**
P2	-0,230	0,027*	P10	0,213	0,027*
P3	-0,047	0,417 ns	P11	0,121	0,061**
P4	0,045	0,251 ns	P12	0,088	0,166 ns
P5	0,066	0,217 ns	P13	0,185	0,057**
P6	0,173	0,066**	P14	-0,032	0,459 ns
P7	0,004	0,235 ns	P15	-0,045	0,464 ns
P8	0,149	0,077**	P16	-0,053	0,478 ns

P1: 25/06 a 02/07; P2: 03/07 a 09/07; P3: 10/07 a 20/07; P4: 21/07 a 27/07; P5: 28/07 a 04/08; P6: 05/08 a 11/08; P7: 12/08 a 17/08; P8: 18/08 a 24/08; P9: 25/08 a 30/08; P10: 31/08 a 08/09; P11: 09/09 a 14/09; P12: 15/09 a 21/09; P13: 22/09 a 29/09; P14: 30/09 a 06/10; P15: 07/10 a 12/10; P16: 13/10 a 20/10; ns: não significativo; *estatisticamente significativos ao nível de 5%* e 10%** de probabilidade.

Fonte: Resultados da Pesquisa.

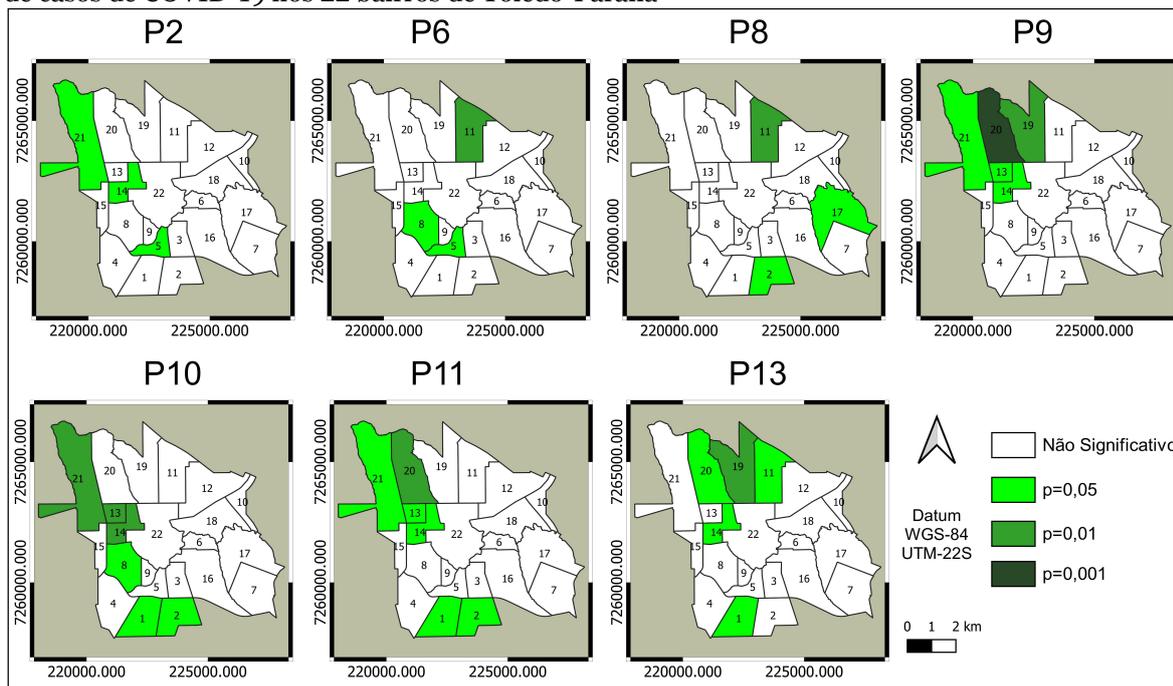
Observa-se na Tabela 2 que durante os períodos P3, P4 e P5 (de 10/07 a 04/08) e P14, P15 e P16 (de 30/09 a 20/10), o valor do Índice Global de Moran (I) foi baixo. Tal fato sugere uma autocorrelação espacial extremamente fraca, ou seja, não houve similaridade entre o valor observado em uma determinada região e os valores médios dos seus vizinhos. Além disso, a combinação desses baixos valores do Índice Global de Moran com uma significância acima de 0,10 (p-valor) levou à aceitação da hipótese nula de independência espacial para esses períodos, ou seja, cada uma das regiões possui comportamentos independentes.

Boumahdi, Zaoujal e Fadlallah (2021) encontraram resultados semelhantes ao estudarem a incidência de casos de COVID-19 em províncias do Marrocos. Eles obtiveram um Índice Global de Moran muito baixo e não significativo, em alguns períodos, para a taxa de infecção e a taxa de mortalidade, o que levou à não rejeitar a hipótese de independência espacial.

A Figura 3 mostra os mapas de significância do Índice Local de Moran – LISA, que avalia a autocorrelação espacial local dos dados, isto é, mede o grau de dependência espacial entre os valores da variável em diferentes localizações. O índice LISA permite identificar *clusters* espaciais, que são grupos de unidades espaciais com valores similares, e testar sua significância estatística, considerando os níveis de 0,1%, 1% e 5% de probabilidades. Os *clusters* podem ser de alto valor (Alto-Alto), baixo valor (Baixo-Baixo), ou misto (Alto-Baixo ou Baixo-Alto) conforme a classificação proposta por Anselin (1995).

A análise dos mapas da Figura 3 mostra que houve a formação de *clusters* na região norte do município de Toledo nos períodos P9 (de 25/08 a 30/08) formado pelos bairros: Jardim Santa Maria (13), Jardim La Salle (14), Vila Industrial (19), Tocantins (20) e Jardim Coopagro (21); P11 (de 09/09 a 14/09) formado pelos bairros: Jardim Santa Maria (13), Jardim La Salle (14), Tocantins (20) e Jardim Coopagro (21); e P13 (de 22/09 a 29/09) formado pelos bairros: Jardim La Salle (14), Jardim Gisela (11), Vila Industrial (19) e Tocantins (20), com diferentes níveis de significância estatística (0,1%, 1% e 5%). Os bairros que não se encontram em nenhuma dessas classificações de significância, ocorrem porque não apresentaram autocorrelação espacial significativas em relação aos seus vizinhos.

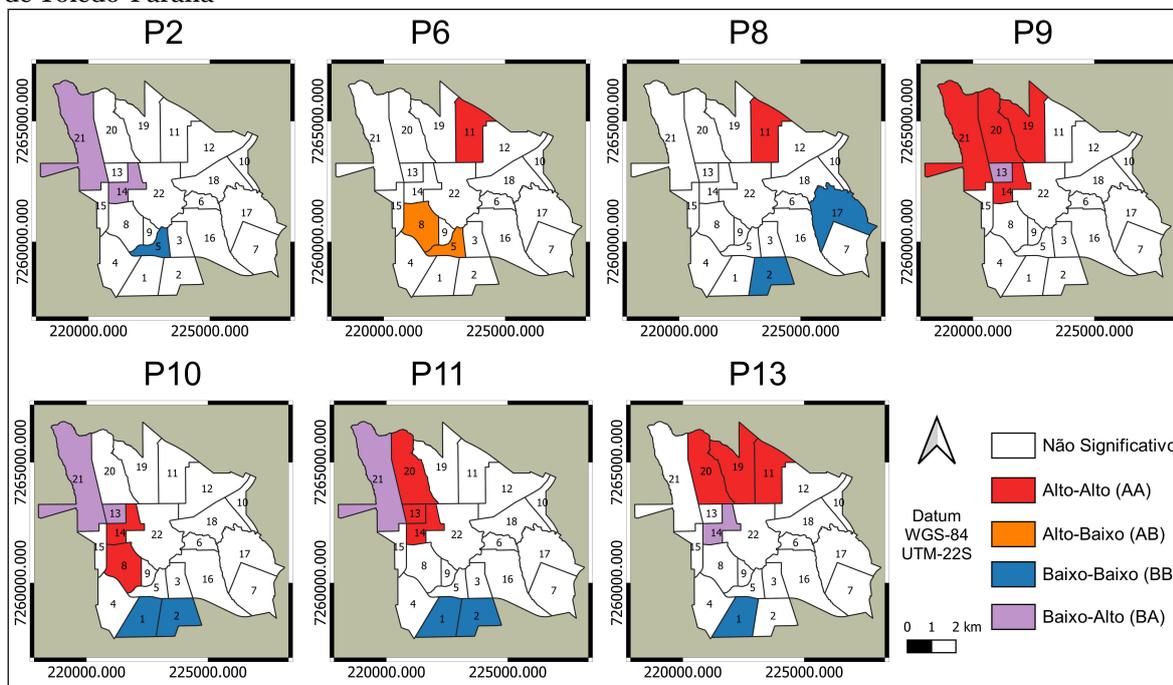
Figura 3 – Mapa de significância do Índice Local de Moran - LISA da taxa de crescimento do número de casos de COVID-19 nos 22 bairros de Toledo-Paraná



Fonte: Resultados da Pesquisa.

Para visualizar melhor o tipo de autocorrelação espacial existente entre os bairros, elaborou-se na Figura 4 os mapas denominados LISA *cluster map*. Esses mapas indicam se os bairros formam *clusters* de alto valor, baixo valor ou misto.

Figura 4 – LISA *cluster map* da taxa de crescimento do número de casos de COVID-19 nos 22 bairros de Toledo-Paraná



Fonte: Resultados da Pesquisa.

No período P9 (de 25/08 a 30/08) observou-se a formação de um *cluster* de alto valor na região norte do município, composto pelos bairros Jardim La Salle (14), Vila Industrial (19), Tocantins (20) e Jardim Coopagro (21), que representam uma alta taxa de crescimento do número de casos de COVID-19, tanto local quanto regional.

Em contraste, o bairro Jardim Santa Maria (13), localizado no centro desse *cluster*, apresentou uma baixa taxa de crescimento local, mas uma alta taxa de crescimento regional, devido à influência dos bairros vizinhos. Esse bairro foi classificado como Baixo-Alto (BA), configurando-se como um *outlier* espacial, ou seja, uma unidade espacial que apresenta um valor atípico ou discrepante em relação aos seus vizinhos.

O bairro Jardim Santa Maria (13), permanece nesta classificação no período seguinte (P10), e no próximo período P11 (de 09/09 a 14/09), ele passa para a classificação Alto-Alto (AA).

O bairro Jardim Santa Maria (13), apresenta uma peculiaridade, uma vez que é absorvido pelos bairros adjacentes, evidenciando que bairros com baixa taxa de contaminação são incorporados por seus vizinhos que apresentam taxas mais elevadas de crescimento do número de casos de COVID-19.

Ghosh e Cartone (2020) realizaram um estudo sobre a dinâmica espaço-temporal da COVID-19 na Itália, utilizando o índice LISA para identificar os padrões de autocorrelação espacial. Os autores observaram que, em vários períodos, houve a formação de *clusters* de alto valor (AA) em diversos estados do país, enquanto alguns desses apresentaram valores baixos locais, sendo classificadas como Baixo-Alto (BA). Com o avanço da pandemia, essas regiões foram incorporadas pelos *clusters* de alto valor, indicando a presença de uma maior disseminação da doença.

A análise dos bairros que compõe o *cluster* de alto valor, no norte do município de Toledo, revela a existência de diferenças socioeconômica entre eles, que podem estar relacionadas com a dinâmica da doença. O bairro Jardim Coopagro (21) é caracterizado por ser de classe econômica média-baixa, onde residem muitos trabalhadores de mão de obra assalariada e muitos com empregos informais, que possuem maior dificuldade de adotar medidas de prevenção, como o isolamento social (CAMPOS; DIAS, 2015, CIMA *et al.*, 2022). Já o bairro Jardim Santa Maria (13) é de classe econômica média, e possui uma população diversificada, com a presença de imigrantes, como do Haiti e Senegal (CAMPOS; DIAS, 2015, LOMBARDI, 2020). Esses fatores podem contribuir em diferentes graus de vulnerabilidade desses bairros à infecção da COVID-19.

Diferentemente do bairro Jardim Santa Maria (13), que apresentou mudança de padrão espacial de baixa para alta incidência de COVID-19, o bairro Jardim Coopagro (21) mostrou uma situação inversa. No período P9 (de 25/08 a 30/08), esse bairro foi classificado como Alto-Alto (AA), assim como seus vizinhos, indicando uma alta taxa de contaminação local e regional. No entanto, nos períodos seguintes P10 e P11 (de 31/08 a 14/09), ele passou para a classificação Baixo-Alto (BA), revelando uma redução da taxa de contaminação local, mas mantendo uma alta taxa de contaminação regional, devido a proximidade com bairros com elevada incidência de COVID-19.

Esse bairro merece uma atenção especial, para que não ocorra uma reinfecção por seus vizinhos, como aconteceu com o bairro Jardim Santa Maria (13). Nessas situações é necessário reforçar medidas de prevenção e controle da doença no bairro, bem como monitorar a situação epidemiológica dos bairros adjacentes.

Siljander *et al.* (2022) realizaram uma análise espacial da incidência de COVID-19 nos bairros de Helsinque, capital da Finlândia, utilizando o índice LISA.

Os autores identificaram a existência de *clusters* de alto valor (AA) em algumas áreas da cidade, indicando uma alta incidência de COVID-19. Os autores observaram que alguns bairros dentro desses *clusters* apresentaram uma redução significativa da incidência de COVID-19 em relação aos períodos anteriores, enquanto seus vizinhos mantiveram altas taxas. Esses bairros foram classificados como Baixo-Alto (BA), configurando-se como *outliers* espaciais.

No período P13 (de 22/09 a 29/09), verificou-se a ocorrência de um *cluster* de alto valor (AA) na região norte do município, formado pelos bairros Jardim Gisela (11), Vila Industrial (19) e Tocantins (20), que apresentam uma alta taxa de incidência de COVID-19 tanto local quanto regional. Esses bairros foram classificados como Alto-Alto (AA), seguindo a metodologia de Anselin (1995).

Em contrapartida, o bairro Jardim La Salle (14), localizado no limite sul desse *cluster*, apresentou uma baixa incidência local, mas uma alta incidência regional, devido a influência dos bairros vizinhos. Esse bairro foi classificado como Baixo-Alto (BA), sendo uma unidade espacial que apresenta um valor discrepante em relação aos seus vizinhos.

Esse resultado é consistente com a dinâmica espacial da doença, que tende a se propagar dos bairros com maior taxa de crescimento para bairros com menor taxa de crescimento que corrobora com Nunes (2021).

Finalmente, ao analisar os períodos P10, P11 e P13, observou-se que o bairro São Francisco (1) apresentou uma baixa taxa de crescimento de casos de COVID-19 ao longo desses períodos, mantendo-se em um padrão de autocorrelação espacial Baixo-Baixo (BB). Esse padrão também foi observado em seus vizinhos, formando um *cluster* de baixo valor na região sul do município.

Os resultados aqui encontrados sugerem que os efeitos causados pela pandemia refletiram diretamente na população economicamente mais vulnerável, aquelas de origem assalariada e que praticavam trabalhos na informalidade, essa população de pessoas foi expressivamente afetada pela perda de renda (poder de compra) e pela impossibilidade de fazer o distanciamento social, que corrobora com Bird (2020).

CONSIDERAÇÕES FINAIS

Este trabalho evidenciou a existência de autocorrelação espacial positiva na taxa de crescimento do número de casos de COVID-19 nos bairros de Toledo-Paraná, formando *clusters* de alto risco e baixo risco de contaminação. A identificação de bairros com correlação Baixo-Alto (BA) é fundamental para a implementação de medidas localizadas que evitem a progressão para o *status* Alto-Alto (AA).

Observou-se que o bairro Jardim Santa Maria (13), que apresentou classificação Baixo-Alto (BA), foi incorporado pelos bairros adjacentes, com classificação Alto-Alto (AA), o que demonstra a influência dos vizinhos na disseminação da doença.

Os resultados encontrados no presente estudo evidenciam a relevância da análise espacial de dados de áreas, pois, com uma intervenção adequada das autoridades de saúde municipais, é possível evitar a repetição de situações semelhantes no futuro, impedindo a formação de um grande *cluster* caracterizado por taxas altas de contaminação de COVID-19.

REFERÊNCIAS

- ANDERSEN, K. G.; RAMBEUT, A.; LIPKIN, W. L.; HOLMES, E. C.; GARRY, R. F. The proximal origin of SARS-CoV-2. **Nature Medicine**, v. 26, n. 4, p. 450-452, 2020.
- ANSELIN, L. Local Indicators of Spatial Association – LISA. **Geographical Analysis**, v. 27, n. 2, p. 93-115, 1995.
- ANSELIN, L.; SYABRI, I.; KHO, Y. GeoDa: An introduction to Spatial Data Analysis. **Geographical Analysis**, Athens, v. 38, n. 1, p. 5-22, 2006. Disponível em: <<https://geodacenter.github.io/download.html>>. Acesso em: 18 ago. 2023.
- BOUMAHDJI, I.; ZAOUJAL, N.; FADLALLAH, A. Is there a relationship between industrial clusters and the prevalence of COVID-19 in the provinces of Marocco, **Regional Science Policy & Practice**. v. 1, n. 13, p. 138-157, 2021. DOI: <https://doi.org/10.1111/rsp3.12407>
- BRIDI, M.A. A pandemia Covid-19: crise e deterioração do mercado de trabalho no Brasil. **Estudos Avançados**, v. 34, n. 100, 2020.
- CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V. Análise espacial de áreas. In: DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. (Org.). **Análise Espacial de Dados Geográficos**. Brasília, Embrapa, 2004.
- CAMPOS, S.; DIAS, S. A desigualdade social espacializada na cidade de Toledo, PR. In: 4ª CONFERÊNCIA DE MORFOLOGIA URBANA E OS DESAFIOS DA URBANALIDADE, 2015, Brasília – DF. **Anais ...** Brasília, 2015. Disponível em: <https://www2.fag.edu.br/professores/solange/PRODUCAO%20CIENTIFICA/2015%20PNUM%20-%20BRASILIA/PNUM%202015_2_Sabine%20Campos_Solange%20Dias%20-%20ARTIGO%20FINAL.pdf>. Acesso em: 12 nov. 2023.
- CAPUCHO, T. O.; PARRÉ, J. L. Produção leiteira no Paraná: um estudo considerando os efeitos espaciais. **Informe Gepec**, Toledo, v. 16, n. 1, p. 112-127, 2012.
- CARDOSO, D. F.; DOMINGUES, E.; MAGALHÃES, A.; SIMONATO, T.; MIYAJIMA, D. Pandemia de covid-19 e famílias: impactos da crise e da renda básica emergencial. **Políticas Sociais: acompanhamento e análise | BPS** |, n. 28, 2021. DOI: <http://dx.doi.org/10.38116/bps28/notadepoliticassocial2>
- CIMA, E. G.; URIBE-OPAZO, M. A.; DA ROCHA-JUNIOR, W. F.; RUI MANUEL DE SOUZA FRAGOSO. A spatial analysis of western Paraná: scenarios for regional development. **Revista Brasileira de Gestão e Desenvolvimento Regional**. v.17, n.2, p. 151-164. 2021.
- CIMA, E. G.; URIBE-OPAZO, M. A.; BOMBACINI, M. R.; ROCHA JR., W. F. DA; GUEDES, L. P. C. Spatial analysis: a socioeconomic view on the incidence of the new coronavirus in Paraná-Brazil. **Stats**, v. 5, p. 1029-1043, 2022.

DALPOSSO, G. H. Estatística espacial aplicada a agricultura de precisão. 2010. **Dissertação (Mestrado em Engenharia Agrícola)** Universidade Estadual do Oeste do Paraná-UNIOESTE, Cascavel, 2010.

GHOSH, P.; CARTONE, A. A spatio-temporal analysis of COVID-19 outbreak in Italy. **Regional Science Policy & Practice**, n. 12, p. 1047-1062, 2020. DOI: <https://doi.org/10.1111/rsp3.12376>

HOUVÈSSOU, G. M.; SOUZA, T. T. de.; SILVEIRA, M. F. da. Medidas de contenção de tipo *lockdown* para prevenção e controle da COVID-19: estudo ecológico descritivo, com dados da África do Sul, Alemanha, Brasil, Espanha, Estados Unidos, Itália e Nova Zelândia, fevereiro a agosto de 2020. **Epidemiologia e Serviços de Saúde**, n. 30, v. 1, 2021. DOI: <https://doi.org/10.1590/S1679-49742021000100025>

IBGE - Instituto Brasileiro de Geografia e Estatística. **Geociências: Malha Municipal**. Rio de Janeiro, 2022. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>>. Acesso em: 11 nov. 2023.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Cidades e Estado: Toledo**. Rio de Janeiro, 2023. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/pr/toledo.html>>. Acesso em: 30 jun. 2023.

LOMBARDI, B. V. N. Migração e identidade: a presença islâmico-senegalesa em Toledo, PR (2014-2020). 2020. **Dissertação (Mestrado em Geografia)** Universidade Estadual do Oeste do Paraná-UNIOESTE, Marechal Cândido Rondon, 2020.

MARCELLO, T.; CAVALARI, I. A.; CARVALHO, M.; ROCHA, A. C.; FOLLADOR, F. A. C.; VIEIRA, A. P.; WELDT, G. W. Space analysis of child mortality in Paraná. **Brasilian Journal of Development**, Curitiba, v. 5, n. 10, p. 18862-18876, 2019.

MARCONATO, M.; BRAMBILLA, M. A.; NASCIMENTO, S. P.; CAMARA, M. R. G. A focalização do Programa Bolsa Família nos municípios de Santa Catarina: uma análise espacial. **Informe Gepec**, Toledo, v. 19, n. 1, p. 37-38, jan./jun. 2015.

MORAN, P. A Test for the Serial Independence of Residuals. **Biometrika**, 37, 178-181. 1950. DOI: <http://dx.doi.org/10.1093/biomet/37.1-2.178>

NASCIMENTO, E. F.; JUSTO, W. R. Interação intersetorial e a produção das commodities agrícolas na região centro-oeste: uma abordagem espacial. **Informe Gepec**, Toledo, v. 27, n. 1, p. 320-335, jan./jun. 2023.

NEVES, M. C.; RAMOS, F. R.; CAMARGO, E. C. G.; CÂMARA, G.; MONTEIRO, A. M. Análise exploratória espacial de dados sócio-econômicos de São Paulo. In: SIMPÓSIO BRASILEIRO DE GEOTECNOLOGIAS – GISBrasil, 2000, Salvador - BA. **Anais ...** Salvador: GIS Brasil Editora, 2000.

NOBRE, A. F. S.; SOUZA, R. C. M.; SANTOS, M. C.; BARBAGELATA, L. S.; COSTA JÚNIOR, E.; LIMA, D. F.; SOUZA, E. M. A.; MELLO, W. A. Primeira detecção de coronavírus humano associado à infecção respiratória aguda na Região Norte do

Brasil. **Revista Pan-Amazônica de Saúde**, Ananindeua, v.5, n. 2, p. 37-41, jun. 2014.

NUNES, M. O papel das estruturas territoriais na propagação da COVID-19 na fronteira amazônica. Nota técnica nº 25, **Diretoria de Estudos e Políticas Regionais, Urbanas e Ambientais (DIRUR)**, 2021. DOI: <http://dx.doi.org/10.38116/ntdirur25>

PORSSE, A. A.; SOUZA, K.B.; CARVALHO, T.S.; VALE, V. A. Impactos Econômicos da Covid-19 no Brasil. Nota Técnica NEDUR-UFPR Nº 01-2020, **Núcleo de Estudos em Desenvolvimento Urbano e Regional (NEDUR)**, Curitiba, abr. 2020.

PRADIPTA, Y.; PUTRI, A. S. E.; ILMASKAL, R. Distribution of coronavirus disease (Covid-19) in west Sumatra Province with local indicator of spatial association (LISA) cluster map. **Scientific Periodical of Public Health and Coastal Health**, Halaman, v. 5, n. 1, p. 141-153, 2023.

SHERMAN, G.E.; SUTTON, T.; BLAZEK, R.; HOLL, S.; DASSAU, O.; MORELY, B.; MITCHELL, T.; LUTHMAN, L. **Quantum GIS User Guide** – Version 3.16 “Hannover”, 2020. Disponível em: <<https://qgis.org/en/site/>>. Acesso em: 18 ago. 2023.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Viena, 2022. Disponível em: <<https://www.R-project.org>>. Acesso em: 18 ago. 2023.

RAMOS, C. S.; SANCHES, M. C. Estudo metodológico de classificação de dados para cartografia temática. **Geografia**, Rio Claro, v. 25, n. 2, p. 23-52, ago. 2000.

SILJANDER, M.; UUSITALO, R.; PELLIKKA, P.; ISOSOMPPI, S.; VAPALAHTI, O. Spatiotemporal clustering patterns and sociodemographic determinants of COVID-19 (SARS-CoV-2) infections in Helsinki, Finland. **Spatial and Spatio-temporal Epidemiology**, v. 41, 2022. DOI: <https://doi.org/10.1016/j.sste.2022.100493>

ZHU, N.; ZHANG, D.; WANG, W.; LI, X.; YANG, B.; SONG, J.; ZHAO, X.; HUANG, B.; SHI, W.; LU, R.; NIU, P.; ZHAN, F.; MA, X.; WANG, D.; XU, W.; WU, G.; GAO, G. F.; TAN, W. A novel coronavirus from patients with pneumonia in China, 2019. **The New England Journal of Medicine**, v. 382, n. 8, p. 727-733, 2020. DOI: <https://doi.org/10.1056/nejmoa2001017>

Recebido em 28/08/2023.
Aceito em 22/02/2024.