

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Instituto de Geociências

Departamento de Geografia

LEONARDO KENDZIERSKI WINTER

**Análise espacial do desenvolvimento da pandemia da Covid-19 no Estado do
Rio Grande do Sul**

Porto Alegre,

2022

CIP - Catalogação na Publicação

Kendzierski Winter, Leonardo
Análise Espacial do Desenvolvimento da Pandemia no
Estado do Rio Grande do Sul / Leonardo Kendzierski
Winter. -- 2022.
51 f.
Orientador: Marcos Wellausen Dias de Freitas.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Instituto
de Geociências, Bacharelado em Geografia, Porto
Alegre, BR-RS, 2022.

1. Análise Espacial. 2. Epidemiologia. 3.
Geografia. 4. Geografia da Saúde. 5. COVID-19. I.
Wellausen Dias de Freitas, Marcos, orient. II.
Título.

LEONARDO KENDZIERSKI WINTER

**Análise espacial do desenvolvimento da pandemia da Covid-19 no Estado do
Rio Grande do Sul**

Trabalho de Conclusão de Curso do
Departamento de Geografia, da
Universidade Federal do Rio Grande do
Sul.

Prof. Orientador: Dr. Marcos Wellausen
Dias de Freitas

Porto Alegre,
2021

LEONARDO KENDZIERSKI WINTER

**Análise espacial do desenvolvimento da pandemia da Covid-19 no Estado do
Rio Grande do Sul**

Trabalho de Conclusão de Curso de
graduação apresentado ao Instituto de
Geociências da Universidade Federal do
Rio Grande do Sul como requisito para a
obtenção do título de Bacharel em
Geografia.

Aprovado em:

BANCA EXAMINADORA

Prof. Ricardo Dagnin – UFRGS

Prof. Adriana Dorfman - UFRGS

Prof. Dr. Marcos Wellausen Dias de Freitas – UFRGS (Orientador)

AGRADECIMENTOS

Sempre fui ruim com agradecimentos, mas agradeço especialmente a meu pai Jackson Winter, minha mãe Sandra Winter, e a todos os meus amigos que ajudaram não com o TCC, mas a tornar a vida mais tranquila e menos estressante enquanto eu o produzia. Deixo aqui minha eterna gratidão a todos.

RESUMO

Em março de 2020, a Organização Mundial da Saúde (OMS) declarou que uma nova doença respiratória, a SARS-CoV-2, atingiu o estágio de pandemia. No Brasil, os primeiros casos foram relatados em fins de fevereiro e, no Rio Grande do Sul, no dia 10 de março. No presente estudo, realizou-se uma análise espacial associando dados referentes às taxas de mortalidade e incidência dos municípios sul riograndenses com dados socioeconômicos, para dois momentos separados da pandemia. Assim, foi possível uma compreensão do processo de espalhamento do vírus pelo Estado. Foram utilizados métodos estatísticos espaciais, seguidos de interpretação dos dados gerados referentes às correlações presentes entre as variáveis socioeconômicas e as referentes ao avanço da COVID-19. A pesquisa utilizou dados provenientes da Secretária Estadual de Saúde do Rio Grande do Sul e da Fundação de Economia e Estatística (FEE) para o período do primeiro mês da pandemia e até setembro de 2021. Foi constatado que questões socioeconômicas foram cruciais para o valor das taxas, principalmente a de mortalidade, revelando a importância de políticas públicas que pensam as diferenças inter-regionais do Estado do Rio Grande do Sul.

Palavras-chaves: Análise espacial; Pandemia; Covid-19; Incidência; Mortalidade.

ABSTRACT

At March 2020, the World Health Organization declared that the new respiratory disease, which emerged in the city of Wuhan in China, SARS-CoV-2, has reached a pandemic stage. In Brazil, the first cases were reported in February and in Rio Grande do Sul on March 10. The present study was dedicated to spatial analysis, associating data on mortality and incidence rates in southern Rio Grande do Sul municipalities with socioeconomic data, for two separate moments of the pandemic. Thus, a better understanding of the spread of the virus across the state was possible. Statistical methods were used, followed by the interpretation of the data generated regarding the correlation between socioeconomic variables and those referring to COVID-19. The research used data from the State Secretary of Health of Rio Grande do Sul and the Economics and Statistics Foundation (FEE) for the period from the first month of the pandemic to September 2021. It was found that socioeconomic issues are crucial for the value of rates, especially mortality, revealing the importance of public policies that consider the interregional differences in the state of Rio Grande do Sul.

Keywords: Spatial analysis; Pandemic; Covid-19; Incidence; Mortality.

SUMÁRIO

1 INTRODUÇÃO	11
2 REFERENCIAL TEÓRICO	13
2.1 Análise espacial e epidemiologia	13
2.2 Análise de correlação espacial	15
2.3 Mapeamento de autocorrelação espacial local	15
3 METODOLOGIA	17
3.1 Banco de dados geográficos	18
3.2 Análise de autocorrelação espacial global	19
3.3 Mapeamento de autocorrelação espacial local	21
4 RESULTADOS	23
4.1 Análise de autocorrelação espacial global	23
4.1.1 Análise de autocorrelação espacial global univariada	23
4.1.2 Análise de autocorrelação espacial global bivariada	25
4.1.2.1 Distância de Porto Alegre	25
4.1.2.2 Densidade demográfica	26
4.1.2.3 PIB per capita	28
4.1.2.4 Índice IDESE Saúde	30
4.2 Mapas de autocorrelação espacial local	31
4.2.1 Mapas de autocorrelação espacial local univariados	31
4.2.2 Mapas de autocorrelação espacial local bivariados	34
4.2.2.1 Distância de Porto Alegre	34
4.2.2.2 Densidade demográfica	36
4.2.2.3 PIB per capita	39
5 DISCUSSÃO	44
6 CONCLUSÃO	48
7 REFERÊNCIAS BIBLIOGRÁFICAS	50

LISTA DE FIGURAS

Figura 1 - Fluxograma das etapas metodológicas.....	17
Figura 2 - Diagrama de dispersão do índice de Moran univariável da Taxa de Incidência.	23
Figura 3 - Diagrama de dispersão do índice de Moran univariável da Taxa de Mortalidade.....	24
Figura 4 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Incidência X Distância de Porto Alegre.	25
Figura 5 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X Distância de Porto Alegre.....	26
Figura 6 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Incidência X Densidade demográfica.....	27
Figura 7 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X Densidade demográfica.....	28
Figura 8 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Incidência X PIB per capita.	29
Figura 9 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X PIB per capita.....	30
Figura 10 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X Índice IDESE Saúde.....	31
Figura 11 - Mapas de autocorrelação espacial local da taxa de incidência em março de 2020 (A) e setembro de 2021 (B).	32
Figura 12 - Mapas de autocorrelação espacial local da taxa de mortalidade em março de 2020 (A) e setembro de 2021 (B).	34
Figura 13 - Mapas de autocorrelação espacial local bivariados da taxa de incidência em relação à distância à Porto Alegre em março de 2020 (A) e setembro de 2021 (B).....	35
Figura 14 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação à distância à Porto Alegre em março de 2020 (A) e setembro de 2021 (B).....	36
Figura 15 - Mapas de autocorrelação espacial local bivariados da taxa de incidência em relação à densidade demográfica em março de 2020 (A) e setembro de 2021 (B).....	37
Figura 16 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação à densidade demográfica em março de 2020 (A) e setembro de 2021 (B).....	39

Figura 17 - Mapas de autocorrelação espacial local bivariados da taxa de incidência em relação ao PIB per capita em março de 2020 (A) e setembro de 2021 (B).....	40
Figura 18 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação ao PIB per capita em março de 2020 (A) e setembro de 2021 (B).....	41
Figura 19 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação ao IDESE Saúde em março de 2020 (A) e setembro de 2021 (B).....	43
Figura 20 - Leitos de UTI por mil habitantes no Estado do Rio Grande do Sul.	46

LISTA DE ABREVIATURAS

FEE	Fundação de Economia e Estatística
IDESE	Índice de Desenvolvimento Socioeconômico
LISA	Indicadores Locais de Associação Espacial
OMS	Organização Mundial da Saúde
PIB	Produto Interno Bruto
RMPA	Região Metropolitana de Porto Alegre
SIG	Sistemas de Informações Geográficas
UTI	Unidade de Tratamento Intensivo

1 INTRODUÇÃO

Em março de 2020, a Organização Mundial da Saúde (OMS) declarou que uma nova doença respiratória, SARS-CoV-2, atingiu o estágio de pandemia. No Brasil, os primeiros casos foram relatados em fins de fevereiro e, no Rio Grande do Sul, no dia 10 de março. Por ser uma doença de alta transmissibilidade, a necessidade de organização do combate e prevenção à doença se fez necessária. Entretanto, a dificuldade de comunicação entre as três esferas governamentais (estadual, municipal e federal), para agir de forma sincronizada e coerente, fez com que no Brasil houvesse um enorme número de casos confirmados. Atualmente (abril de 2022), há mais de 23 milhões de casos e de mortes mais de 587 mil. No Rio Grande do Sul, o total de mortes chegou a 34.510, sendo o quinto Estado da federação com o maior número de óbitos. O conceito de sindemia, cunhado pelo antropólogo e médico Merrill Singer, emergiu no debate popular, principalmente, em países com alta desigualdade como o Brasil. A sindemia é caracterizada pela interação mutuamente agravante entre problemas de saúde e características sociais, trazendo à superfície problemas como a falta de acessibilidade aos serviços de saúde, baixa renda e baixa qualidade de vida (SINGER, 2009).

Inegavelmente, o entendimento das relações entre variáveis socioeconômicas associadas com o desenvolvimento espacial da pandemia de COVID-19 é importante para impulsionar a concepção de novas formas de políticas públicas em relação às pandemias e endemias. Susser (1994) já afirmava a necessidade de se analisar fatores fora da esfera individual para se entender uma epidemia, pois:

[...] a principal justificativa para uma abordagem ecológica em epidemiologia é a de estudar a saúde num contexto ambiental. [...] Medições de atributos individuais não podem dar conta desses processos; pares, famílias, grupos, escolas, comunidade, culturas e leis são todos contextos que alteram os impactos de maneiras que não é explicável por estudos que focam somente no indivíduo. (SUSSER, 1994).

A partir disso, o espaço e suas variáveis associadas são importantes para o entendimento epidemiológico de uma doença, tomando como limite espacial os limites administrativos dos municípios do Rio Grande do Sul. Cada um destes municípios tendo sua própria organização territorial, composição social e econômica, logo contextos

diferentes, podem ajudar a explicar a relação do desenvolvimento da pandemia com relação às variáveis a serem correlacionadas.

Em complemento a isso, sabe-se que a dificuldade de acesso a saúde diretamente influencia na chance de morte pela COVID-19 e já foi relatada no Brasil, como cita SANTOS et al (2020):

As diferenças, injustas, nos dados de saúde durante a pandemia (calculada a partir dos dados de 24 de maio 2020, da Faculdade de Medicina da USP de Ribeirão Preto e Voz das Comunidades) estão evidentes ao analisarmos a letalidade da COVID-19 na população residente em favelas no município do Rio de Janeiro (24%) e a letalidade para a cidade do Rio de Janeiro, incluídos os residentes em favelas, que foi de 12% e no Brasil 6%. (FIOCRUZ, 2020)

É também definido o conceito de mistanásia, onde essa é definida como morte evitável, ou seja mortes que ocorreram por fatores externo aos puramente individuais e biológicos.

A partir disso, o objetivo que o presente trabalho se coloca é fazer uma análise espacial do desenvolvimento da pandemia no Estado do Rio Grande do Sul, considerando intervalos ao longo do período que vai de março de 2020 até setembro 2021, através de métodos estatísticos espaciais. Além disso, correlacionando dados referentes à pandemia e à socioeconomia dos municípios do Estado, gerando mapas e a análise espacial em si junto com a consequente análise de fatores correlacionados.

A aplicação dessa análise parte da hipótese de que existe correlação entre as taxas de incidência e mortalidade nos municípios sul riograndenses e as variáveis socioeconômicas, e de que, a partir destas e das suas estruturas de autocorrelação espacial, é possível um melhor entendimento do desenvolvimento da pandemia e como se distribuiu no território do Rio Grande do Sul. A partir da comprovação desta hipótese, pretende-se contribuir para a organização de futuras políticas públicas e trazer para o debate a relação entre saúde e os fatores sociais em cada município, assim como as suas diferenças.

2 REFERENCIAL TEÓRICO

2.1 Análise espacial e epidemiologia

A análise espacial e epidemiologia tem suas origens no estudo do médico John Snow, que, durante a epidemia de cólera que atingiu Londres na metade do século XIX, ao reconhecer um padrão da localização dos óbitos decorridos pela doença, associando com a localização das bombas de água da cidade. A partir disso, foi possível evidenciar a associação dessas mortes com a bomba de *Board Street* por meio de representações cartográficas, descobrindo seu padrão de distribuição no espaço. Essa descoberta foi determinante para o entendimento da transmissão da cólera, assim como para o desenvolvimento de políticas públicas, iniciando, também, toda uma nova gama de estudos. Assim, mostrou-se, que, a análise espacial e a epidemiologia necessitam indubitavelmente, para seu desenvolvimento, considerar o espaço como objeto essencial, pois é nele que se desenvolvem as relações humanas, as quais são fundamentais para o espalhamento de qualquer patógeno.

Atualmente, a análise espacial se põe como sinônimo de um conjunto de técnicas de manipulação de dados espaciais associados à estatística a partir de Sistemas de Informações Geográficas (SIG). Em um guia do Ministério da Saúde sobre abordagens espaciais na saúde pública (2006) foi evidenciada a importância dos SIGs para a análise espacial através de quatro funcionalidades comuns a estes: aquisição de dados; gerenciamento de banco de dados; visualização e apresentação cartográfica; consulta e análise. Concomitantemente, Câmara *et al.* (2002) afirmam “A ênfase da Análise Espacial é mensurar propriedades e relacionamentos, levando em conta a localização espacial do fenômeno em estudo de forma explícita. Ou seja, a ideia central é incorporar o espaço à análise que se deseja fazer.”

Por fim, há autores que referenciam a parte mais metodológica deste trabalho, os quais foram utilizados de apoio e subsidiaram essa pesquisa com conhecimentos técnicos de ferramentas muito utilizadas, como Sistemas de informações Geográficas (SIG). Também foram utilizados para buscar quais os locais de coletas de dados para compor os resultados apresentados, assim como algumas definições e conceitos importantes que serão ser destacados.

Recomendações de Carvalho (1997) estabelecem um mapeamento padrão, focado em limites geopolíticos, com os indicadores sendo calculados e permitindo a classificação destas divisões territoriais. A partir disso, pode-se determinar a autocorrelação espacial, ou seja, a associação entre as variáveis e as áreas utilizadas.

Ramirez-Aldana *et al.* (2020) utilizaram métodos de análise espacial similar ao presente trabalho, foi tomado, como divisão política administrativa, as unidades federativas do Irã associando variáveis geográficas e socioeconômicas com a taxa de incidência, através de métodos estatísticos. Desta forma, foi comprovada a importância de variáveis como porcentagem da população em área urbana para a distribuição dos casos de coronavírus no país.

Em resultados apresentados por Ferreira (2020), é perceptível a influência de variáveis como média salarial na distribuição da incidência dos casos de coronavírus, sendo que esta pesquisa foi focada, especificamente, no município de São Paulo. A pesquisa mostrou que áreas de alto risco no município estão associadas com indicadores sociais além de meros fatores individuais. Nesse mesmo artigo, foi apresentado que as áreas com maior número de desempregados tinham relação direta com o número de casos, provavelmente relacionado com a impossibilidade de isolamento social, à medida que a maioria dos desempregados brasileiros se ocupam com atividades informais.

Cabe destacar, também, o projeto do LabCidade da USP, o qual é responsável por diversos artigos e estudos que focam na relação do espaço com a distribuição do coronavírus e os impactos da pandemia, com foco majoritário no Estado de São Paulo, assim como em questões de mobilidade urbana.

Então, mais uma vez, fica evidente a importância de métodos estatísticos espaciais para lidar com dados referentes à pandemia. Estes métodos são ferramentas capazes de auxiliar no entendimento do comportamento de seu desenvolvimento e, conseqüentemente, possibilitam, no futuro, uma melhor gestão de situações similares.

2.2 Análise de correlação espacial

A “autocorrelação espacial” se refere ao reconhecimento das similaridades entre os espaços, por meio de métodos estatísticos e a dependência que a variável possui do espaço. Cabe ressaltar que há a possibilidade da hipótese nula, ou seja, quando o espaço é um fator totalmente aleatório. Tendo em vista a necessidade de trabalhar com dados e métodos estatísticos, o GeoDa mostra-se um *software* de alta utilidade. É uma ferramenta que permite analisar dados através de métodos de autocorrelação espacial desenvolvida por Luc Anselin. O *software* já foi utilizado na análise espacial da Covid-19 por Ramirez-Aldana *et al.* (2020), que produziram um artigo, onde, a partir de análises conduzidas, discutem a influência de diversas variáveis associadas ao espaço no espalhamento do coronavírus no Irã.

Os materiais de Luc Anselin e do INPE, referentes à análise espacial e ao GeoDa, serviram como referência principal para elaborar o método estatístico que foi utilizado no trabalho, assim como para a classificação das áreas e a interpretação dos dados obtidos. Da mesma forma, dados provenientes da FEE a respeito dos municípios serão de extrema importância para a análise.

2.3 Mapeamento de autocorrelação espacial local

O mapeamento de autocorrelação espacial local foi desenvolvido “[...] para quantificar o grau de associação espacial que cada localização do conjunto amostral está submetida em função de um modelo de vizinhança preestabelecido.”, como diz Paiva (2002) em seu breve resumo sobre dependência espacial. Para esta finalidade, são gerados os *clusters* (aglomerados), conhecidos como Indicadores Locais de Associação Espacial (LISA), que espacializam áreas em que a autocorrelação espacial se destaca significativamente. Desta forma, é possível inferir padrões locais da distribuição espacial das variáveis interessadas. Anselin (2020) descreve os LISA da seguinte forma:

Um LISA é visto como tendo duas características importantes. Primeiro provendo uma estatística para cada localidade com uma avaliação de significância. Em segundo, estabelece uma relação proporcional entre a soma

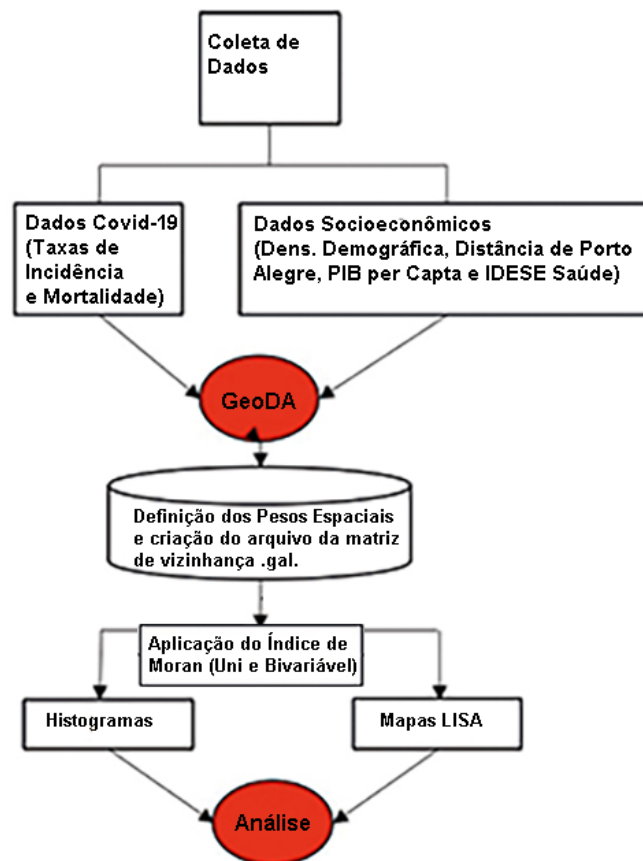
de uma estatística local e uma estatística global correspondente. (ANSELIN, 2020)

Esse tipo de mapeamento foi utilizado por artigos já citados referentes ao coronavírus, como também em relação a outras variáveis de saúde, como no artigo de Sinkh *et al.* (2011), onde foram utilizados os mapas LISA para a análise da distribuição da mortalidade infantil na Índia ao longo de duas décadas.

3 METODOLOGIA

O presente trabalho apresenta-se como um estudo geográfico, utilizando unidades espaciais políticas, neste caso, os municípios do Rio Grande do Sul. Para tal, foram realizadas três etapas sucessivas e complementares: 1) montagem de banco de dados geográfico; 2) análise de autocorrelação espacial global; e 3) mapeamento de autocorrelação espacial global. A primeira etapa constitui-se, majoritariamente, da coleta e seleção de dados referentes aos municípios, assim como de sua organização. A segunda etapa corresponde ao cálculo do Índice de Moran, tanto univariados quanto bivariados, assim como a produção de histogramas. Por fim, a última etapa corresponde a representação cartográfica da autocorrelação espacial calculada, na segunda etapa, através de mapas LISA.

Figura 1 - Fluxograma das etapas metodológicas.



Fonte: Elaborado pelo autor (2022).

3.1 Banco de dados geográficos

Para realização desta pesquisa foi considerada a hipótese de que haveria uma relação entre a distribuição de taxas mais elevadas de mortalidade e incidência com as variáveis socioeconômicas. Portanto, foram selecionadas quatro variáveis: IDESE Saúde, PIB per Capita, Densidade Demográfica e Distância de Porto Alegre.

Todas as informações das variáveis utilizadas foram obtidas a partir de base de dados da FEE. Os dados das taxas de incidência foram obtidos baseados em dados da Secretaria de Saúde do Estado do Rio Grande do Sul. Para se ter melhor compreensão da distribuição espacial foram comparados dois períodos: o primeiro mês de pandemia (10/03/2020 – 10/04/2020) e do início da pandemia até setembro de 2021, para assim ser possível interpretar o avanço do vírus Sars-CoV-2 e a relação das variáveis analisadas com este evento.

As taxas foram calculadas da seguinte forma: a taxa de incidência foi calculada em número de casos, acumulados na data de referência, por 100 mil habitantes. Já a taxa de mortalidade considerou, da mesma forma, o número de óbitos por 100 mil habitantes, sendo que a população de referência foi a estimativa mais recente do IBGE. Os municípios foram considerados em sua totalidade mesmo no primeiro período em que só alguns possuíam valores para as referidas taxas, para tais municípios foram dados o valor 0 para fins comparativos entre os dois períodos temporais.

As variáveis socioeconômicas, extraídas do portal da FEE, são brevemente descritas abaixo:

- a) **IDESE Saúde:** Segundo a FEE, “O IDESE é um indicador-síntese que tem o propósito de mensurar o nível de desenvolvimento dos municípios do Rio Grande do Sul.”, para o bloco da saúde são utilizados dados referentes à: a) saúde materno-infantil; b) condições gerais da saúde; c) longevidade; d) taxa de mortalidade por causas evitáveis; e) taxa de mortalidade para menores de cinco anos; f) número de consultas pré-natais por nascidos vivos e proporção de óbitos por causas mal definidas. Portanto, este indicador foi escolhido apenas para correlação com a taxa de mortalidade à medida que estas variáveis estão associadas à estrutura que lida com os casos de COVID-19 e seu tratamento,

mas não lidam diretamente com o controle de espalhamento do vírus.

- b) **PIB per capita:** É a divisão do Produto Interno Bruto (PIB) pelo número de habitantes do município. Este indicador é importante para compreender a condição econômica dos municípios, se são de grande fluxo econômico, pois, na maioria dos casos, municípios de grande fluxo econômico possuem um PIB per capita elevado, assim como indicam municípios que possuem uma parcela, grande ou pequena, de alta renda que impulsionam este valor.
- c) **Densidade Demográfica:** É a divisão da população do município, baseada em estimativas mais recentes, pela sua área em km². Esta variável indica a aglomeração de pessoas em um espaço menor, sendo que, geralmente, em municípios de alta densidade há contato constante entre inúmeras pessoas, assim como, uma alta movimentação econômica, pois municípios de alta densidade costumam ser mais urbanizados.
- d) **Distância de Porto Alegre:** É a distância euclidiana em quilômetros, calculada dos municípios até os limites da capital Porto Alegre. Esta variável, ao identificar os municípios pela distância da capital sul riograndense, possibilita entender a influência desta na distribuição dos casos e óbitos no Estado, sendo a capital a principal porta de entrada por via aérea e, também, local de constante fluxo de pessoas de outras municipalidades.

3.2 Análise de autocorrelação espacial global

Para a realização da análise de dependência espacial foi utilizado o *software* GeoDA, o qual possui ferramentas de análise espacial, sendo utilizado o Índice de Moran univariado para a análise da autocorrelação espacial global. Para isso, foi necessário, inicialmente, a definição da matriz de pesos espaciais (*spatial weights matrix*) com a estrutura de vizinhança dos municípios, gerando uma matriz de vizinhança que serve de base para a aplicação dos índices, sendo um arquivo no formato “.gal”. O valor da matriz é 1 para aqueles que compartilham um vértice ou ponto em comum de medidas mínimas estabelecidas, sendo considerado ‘1’ para os vizinhos e ‘0’ para aqueles que não são vizinhos. O método utilizado para a definição da matriz

de vizinhança selecionado no *software* GeoDA foi o *Queen*, o qual considera vizinhos qualquer outro polígono que tenha seu limite, em qualquer extensão, interagindo com o limite do polígono de referência.

O índice de Moran possui como principal funcionalidade estimar a autocorrelação espacial da distribuição das taxas epidemiológicas entre os municípios, identificando a existência de agrupamentos (*clusters*) espaciais que evidenciam a influência do espaço na variação das taxas. Esse índice pode variar de -1 e +1, de modo que valores positivos indicam autocorrelação positiva, valores negativos uma autocorrelação negativa e valores nulos expressam ausência de autocorrelação espacial.

A fórmula para o cálculo do Índice de Moran univariável é:

$$I_i = z_i \sum_j w_{ij} z_j$$

Onde: W_{ij} é igual à matriz de vizinhança para a relação dos locais i e j em função de pesos definidos e Z_i e Z_j são os desvios em relação à média. Assim, se calcula o desvio de cada local da média e as suas relações entre si associados a vizinhança, chegando-se a um valor para I_i , podendo variar de -1 a 1. Esse índice foi rodado e testado em relação à significância estatística, com base no teste de permutação aleatória com 9999 permutações.

Já o bivariado identifica *clusters* similares, mas relacionando duas variáveis diferentes, destacando os municípios em que elas tiveram aspecto de significância e, concomitantemente, verificando a correlação de ambas com o espaço.

A fórmula para o cálculo do Índice de Moran bivariável é

$$I_i^B = x_i \sum_j w_{ij} y_j$$

Onde w_{ij} é igual à matriz de vizinhança para a relação dos locais i e j , em função de pesos definidos (novamente), e x e y são as duas variáveis sendo relacionadas. A partir disso, são calculados os desvios de cada local e cada variável associados ao fator de vizinhança, chegando-se a um valor para I_i^B , podendo variar de -1 a 1.

3.3 Mapeamento de autocorrelação espacial local

Para complementar a análise de autocorrelação espacial global, foi realizado o mapeamento de autocorrelação espacial local para a identificação, mais detalhada, da estrutura de dependência espacial dos dados da pandemia. Assim, foram obtidos *indicadores locais espaciais de autocorrelação*, ou LISA, uma decomposição do índice de Moran que permite identificar a contribuição de cada município, estatisticamente, de forma mais clara e visual. Com estes indicadores, para cada variável epidemiológica, foi possível gerar mapas com *clusters* de maior significância, estes sendo divididos em: Alto-Alto; Baixo-Baixo; Baixo-Alto; Alto-Baixo. No caso de univariados, *clusters* 'Alto-Alto' indicam municípios com valores altos de uma variável que estão limitados por outros com valores altos similares, *clusters* 'Baixo-Baixo' indicam o contrário, *clusters* 'Alto-Baixo' indicam municípios com valores altos limitados por aqueles com valores baixos e nos *clusters* 'Baixo-Alto', os com valores baixos limitados por aqueles de valores altos.

No caso do bivariado, 'Alto-Alto' e os outros estão diretamente relacionados com o fato de que, hipoteticamente, no caso de municípios possuírem valores acima da média referente à variável desemprego e valores acima da média referentes à taxa de mortalidade por coronavírus e percebendo-se que estes se estabelecem em relação de vizinhança, ocorre a classificação do conjunto de municípios como um *cluster* 'Alto-Alto'. No caso de 'Baixo-Baixo', municípios com valores abaixo da média referente ao desemprego e valores abaixo da média para a taxa de mortalidade. No 'Alto-Baixo', aqueles com valores acima da média para o desemprego e abaixo da média para a taxa de mortalidade. Por fim, no 'Baixo-Alto', os com valores abaixo da média para o desemprego e acima da média para taxa de mortalidade.

Foi estabelecido o nível de significância de valor $p < 0,05$ como limiar mínimo de significância para as análises estatísticas. Por fim, os mapas foram gerados no *software* ArcGIS, permitindo sua visualização cartografada em Mapas LISA, explicitando os *clusters* e os locais com significância espacial, sendo: *clusters* 'Alto – Alto' em vermelho;

'Baixo – Baixo' em azul marinho; 'Alto – Baixo' em rosa; e 'Baixo – Alto' em azul claro. Os municípios foram considerados em sua totalidade mesmo no primeiro período em que só alguns possuíam valores, para estes foram dados o valor 0 para fins comparativos entre os dois períodos temporais.

4 RESULTADOS

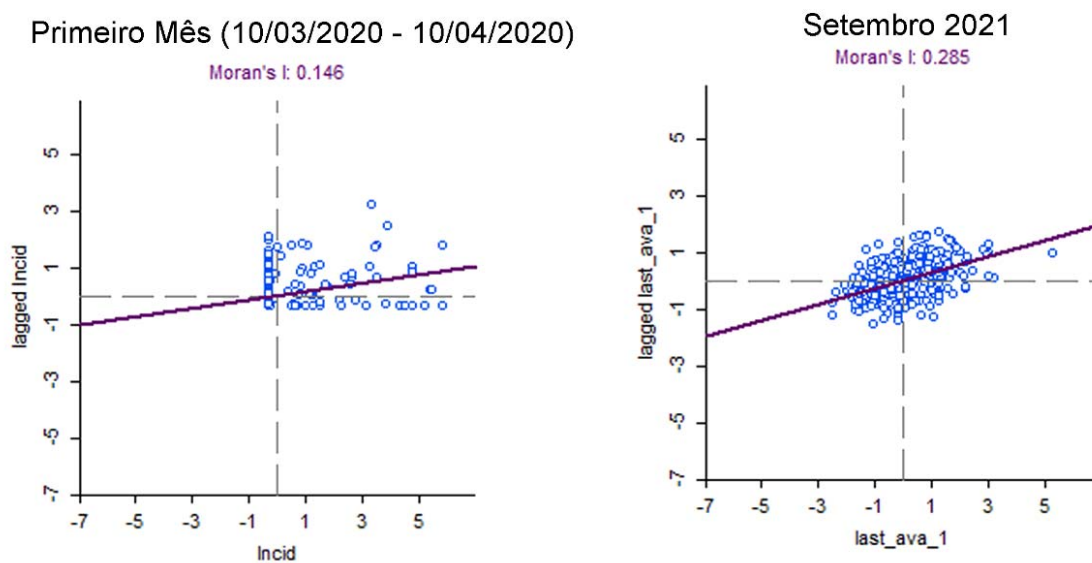
4.1 Análise de autocorrelação espacial global

4.1.1 Análise de autocorrelação espacial global univariada

O índice de Moran univariável foi utilizado para verificar a existência de autocorrelação espacial na distribuição das taxas de incidência e mortalidade abaixo e acima da média nos municípios sul-rio-grandenses. Foram gerados diagramas de dispersão do Índice de Moran para os períodos da pandemia selecionados (Figura 2 e 3).

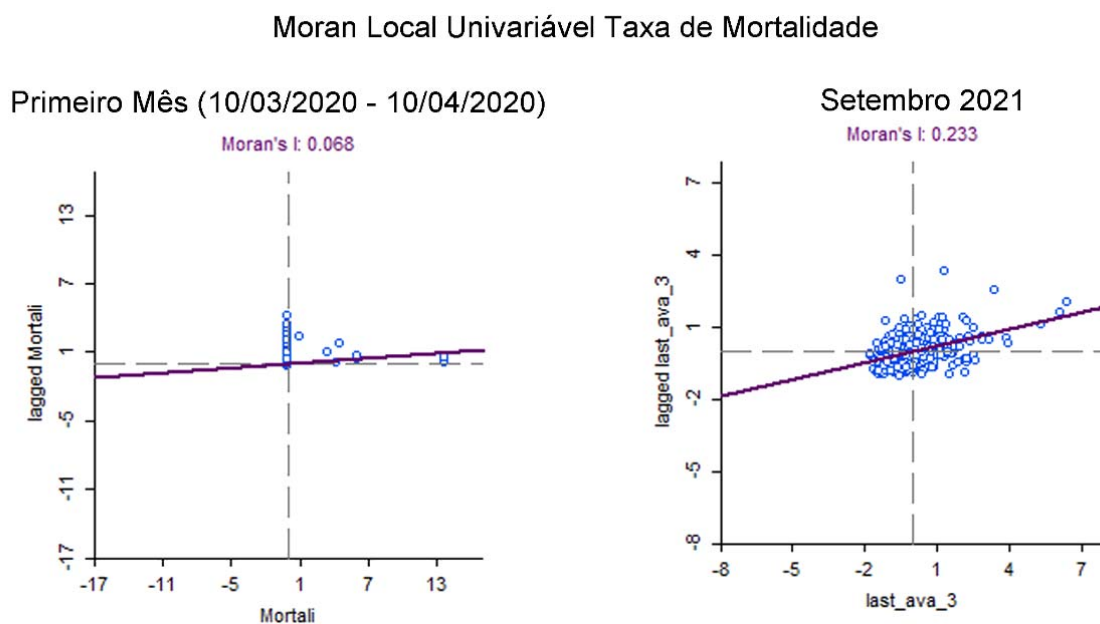
Figura 2 - Diagrama de dispersão do índice de Moran univariável da Taxa de Incidência.

Moran Local Univariável Taxa de Incidência



Fonte: Elaborado pelo autor (2022).

Figura 3 - Diagrama de dispersão do índice de Moran univariável da Taxa de Mortalidade.



Fonte: Elaborado pelo autor (2022).


Percebe-se que no primeiro mês de pandemia o valor do índice encontra-se mais baixo do que no mês de setembro de 2021 ao analisar-se os histogramas, isso evidencia o aumento da existência de autocorrelação espacial no conjunto geral dos dados. Para a taxa de incidência aumentou-se de um $I = 0,146$ para um $I = 0,285$ e para a taxa de mortalidade de um $I = 0,068$ para um $I = 0,233$. Fica explicitado, assim, o aumento da presença de *clusters* espaciais com taxas acima (*hot spots*) e abaixo (*cold spots*) da média geral, ou seja, a pandemia sofreu um processo de concentração espacial ao longo da disseminação. Os municípios que apresentaram dependência espacial aumentaram com a passagem do tempo, conforme indicam os dados referentes aos níveis de significância, indicando maior importância da variável espacial com o desenrolar da pandemia e do espalhamento do vírus. Isso também é indicado com o aumento do valor do índice de Moran.

4.1.2 Análise de autocorrelação espacial global bivariada

4.1.2.1 Distância de Porto Alegre

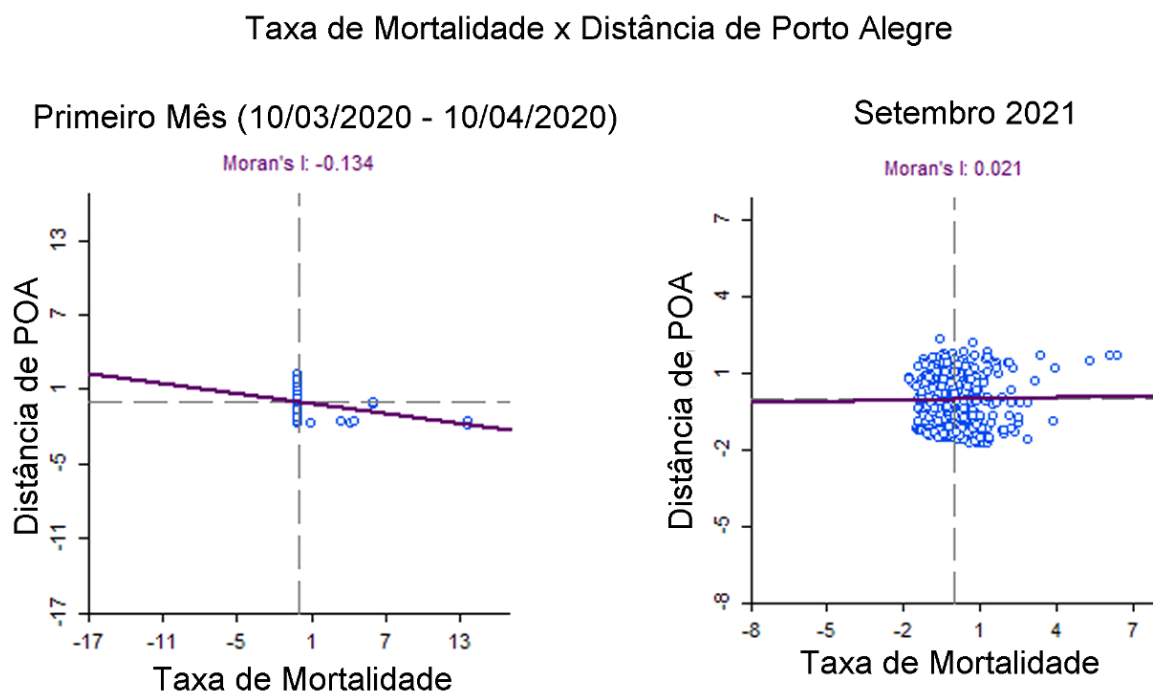
A partir do uso do índice de Moran bivariável associado a distância dos municípios da Capital Porto Alegre, percebe-se que o índice que gera relevância para a importância da distância da Capital diminuiu conforme o desenrolar da pandemia. Este resultado evidencia uma diminuição da importância da variável da distância para a presença de taxas acima/abaixo da média. Inicialmente, para a relação taxa de incidência X distância de Porto Alegre, o índice foi igual à $-0,224$ no primeiro mês da pandemia, ou seja, quanto mais alto a distância mais baixa a taxa de incidência. Já em setembro de 2021, este índice foi igual à $-0,090$, ainda mostrando o mesmo tipo de correlação inversa (ou negativa), porém mais atenuada. Para a relação taxa de mortalidade X distância de Porto Alegre, o índice do primeiro mês foi igual à $-0,134$ e, em setembro de 2021, igual à $0,021$, mostrando uma tendência de inversão de que começa a haver cada vez mais municípios com alta distância e com taxa de morte acima da média (Figura 4 e 5).

Figura 4 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Incidência X Distância de Porto Alegre.



Fonte: Elaborado pelo autor (2022).

Figura 5 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X Distância de Porto Alegre.



Fonte: Elaborado pelo autor (2022).

4.1.2.2 Densidade demográfica

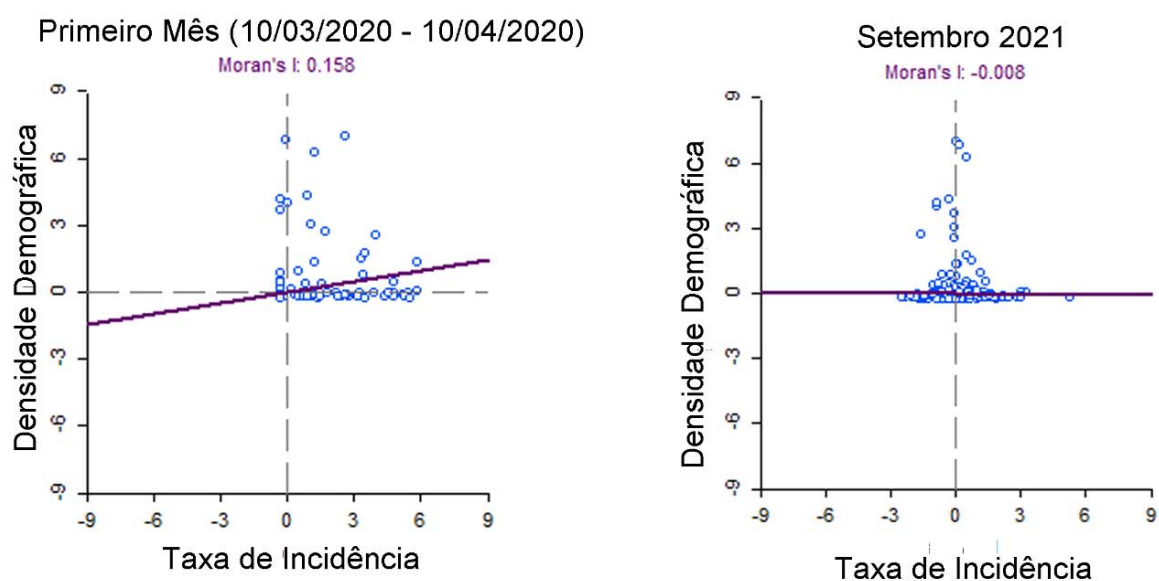
A partir do uso do índice de Moran bivariável associado a densidade demográfica dos municípios, percebe-se que o índice que gera relevância para a importância da densidade demográfica diminuiu conforme o desenrolar da pandemia. Entretanto, neste caso, mais para a relação com a taxa de incidência do que para a taxa de mortalidade. Isso evidencia uma diminuição da importância da variável da densidade demográfica para a presença de taxas acima/abaixo da média, mas mantendo-se significativa para a taxa de mortalidade, o que pode estar relacionado com a questão da capacidade do sistema de saúde de absorção de pacientes em locais de alta densidade.

Inicialmente, para a relação taxa de incidência X densidade demográfica o índice foi igual à 0,158, uma correlação positiva no primeiro mês da pandemia, ou seja, quanto mais alta a densidade, maior a taxa de incidência. Já em setembro de 2021, este índice foi igual à -0,008, mostrando uma correlação quase nula entre a densidade e a taxa de incidência (Figura 6). Para a relação taxa de mortalidade X densidade demográfica, o

Índice do primeiro mês foi igual à 0,230 e em setembro de 2021 igual à 0,101. Esse resultado mostra que a densidade demográfica ainda possui uma correlação positiva que influencia na distribuição espacial das taxas de mortalidade acima e abaixo da média (Figura 7). Como dito anteriormente, este resultado pode estar relacionado com a incapacidade de absorção de uma alta demanda por parte do sistema de saúde.

Figura 6 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Incidência X Densidade demográfica.

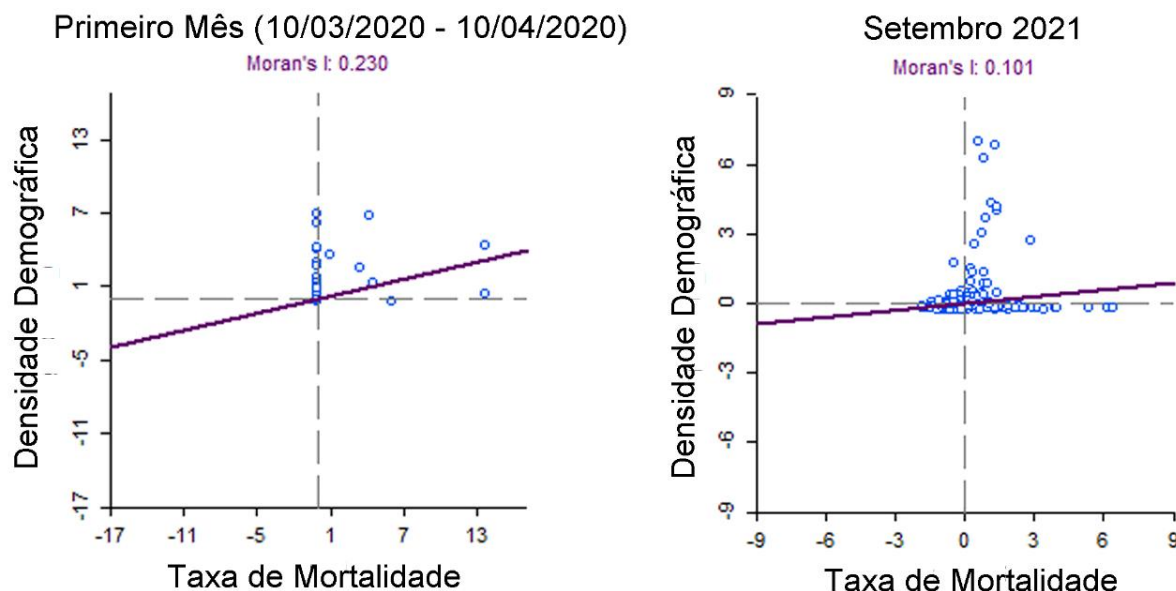
Taxa Incidência X Dens. Demográfica



Fonte: Elaborado pelo autor (2022).

Figura 7 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X Densidade demográfica.

Taxa de Mortalidade x Dens. Demográfica



Fonte: Elaborado pelo autor (2022).

4.1.2.3 PIB per capita

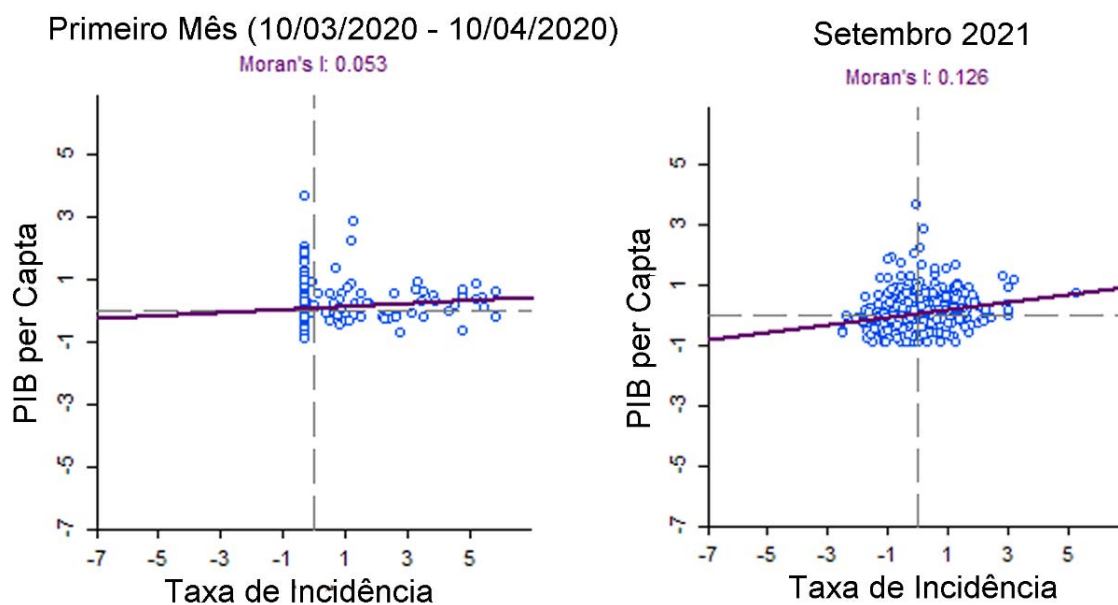
O índice de Moran bivariável associado ao PIB per capita dos municípios, explicita que, conforme o desenrolar da pandemia, o índice para a taxa de incidência X PIB per capita aumenta. Este resultado evidencia um aumento da importância da variável de PIB per capita para a presença de taxas acima/abaixo da média. Inicialmente, para a relação taxa de incidência X PIB per capita o índice foi igual à 0,053 no primeiro mês da pandemia, ou seja, quanto mais alto o PIB per capita mais alta a taxa de incidência. Já em setembro de 2021, este índice foi igual à 0,126, mostrando uma correlação positiva que se intensificou com o desenrolar da pandemia. Este resultado pode estar associado com a intensa atividade econômica, muitas vezes, presente nestes municípios, o que aumenta o fluxo de pessoas (Figura 8).

Para a relação taxa de mortalidade X PIB per capita, o índice do primeiro mês foi igual à 0,053 e em setembro/2021 à -0,035, mostrando uma tendência de inversão da correlação, sendo que quanto menor o PIB per capita maior a taxa de mortalidade. Este

resultado demonstra que a mortalidade da doença é maior, principalmente, em municípios de baixo PIB per capita, mesmo estes não sendo dominantes em relação à contribuição para a taxa de incidência do estado (Figura 9).

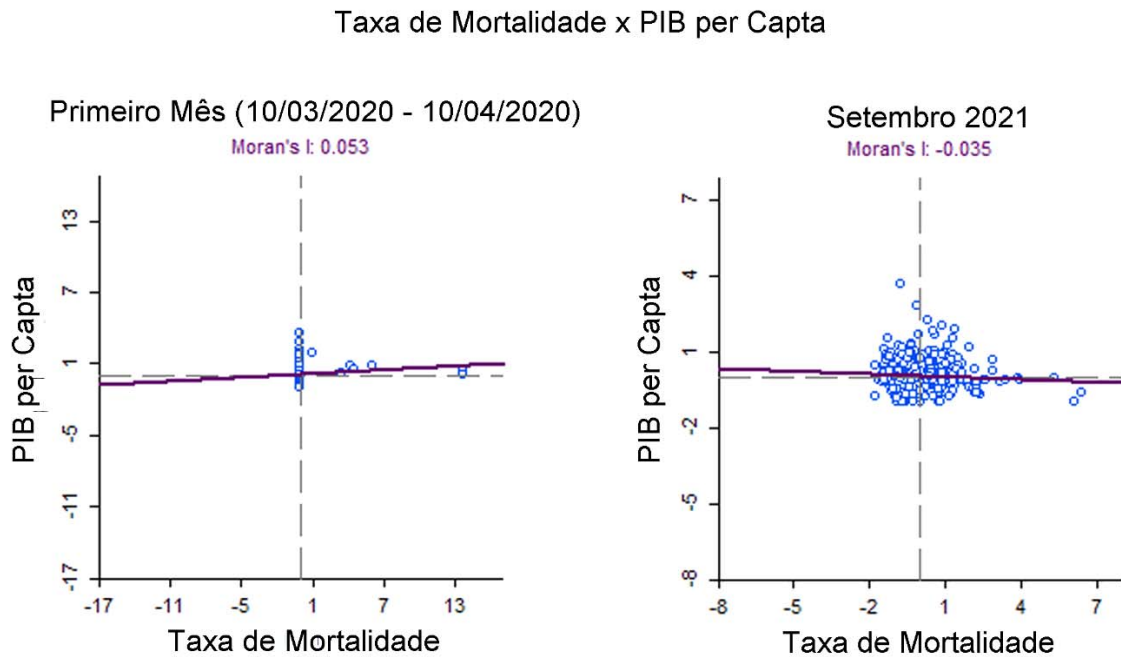
Figura 8 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Incidência X PIB per capita.

Taxa de Incidência x PIB per Capta



Fonte: Elaborado pelo autor (2022).

Figura 9 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X PIB per capita.

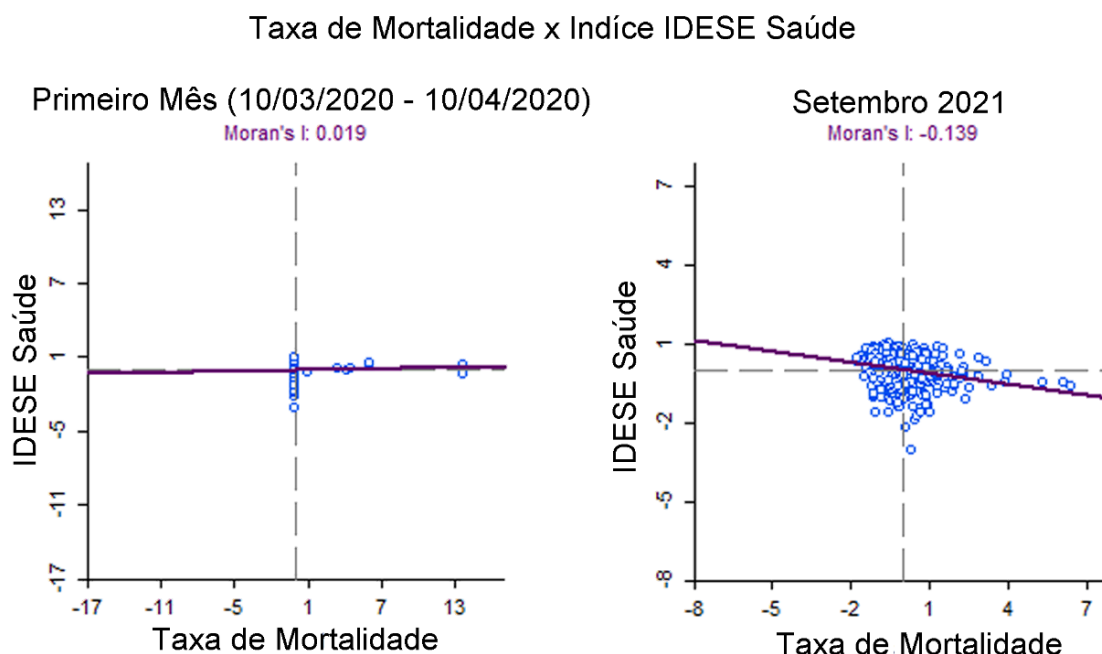


Fonte: Elaborado pelo autor (2022).

4.1.2.4 Índice IDESE Saúde

O índice de Moran bivariável associado ao IDESE Saúde dos municípios explicita que para a taxa de mortalidade X IDESE Saúde, conforme o desenrolar da pandemia, aumenta sua correlação negativa. Esse resultado evidencia um aumento da importância da variável do IDESE Saúde de forma inversa para a presença de taxas acima/abaixo da média. Inicialmente, para a relação taxa de mortalidade X IDESE Saúde, o índice foi igual à 0,019 no primeiro mês da pandemia, ou seja, um índice quase nulo. Este fato demonstra uma baixa influência da estrutura de saúde num contexto geral para a presença de alta taxa de mortalidade, sendo que muitos municípios de baixo IDESE ainda não haviam sido afetados pelo vírus. Em setembro de 2021, este índice foi igual à -0,139, mostrando uma correlação negativa que se intensificou abruptamente com o desenrolar da pandemia, associando, diretamente, que quanto melhor a avaliação no bloco saúde do IDESE, melhores são as chances do município estar abaixo da média da taxa de mortalidade (Figura 10).

Figura 10 - Diagrama de dispersão comparativo do índice de Moran bivariável da Taxa de Mortalidade X Índice IDESE Saúde.



Fonte: Elaborado pelo autor (2022).

4.2 Mapas de autocorrelação espacial local

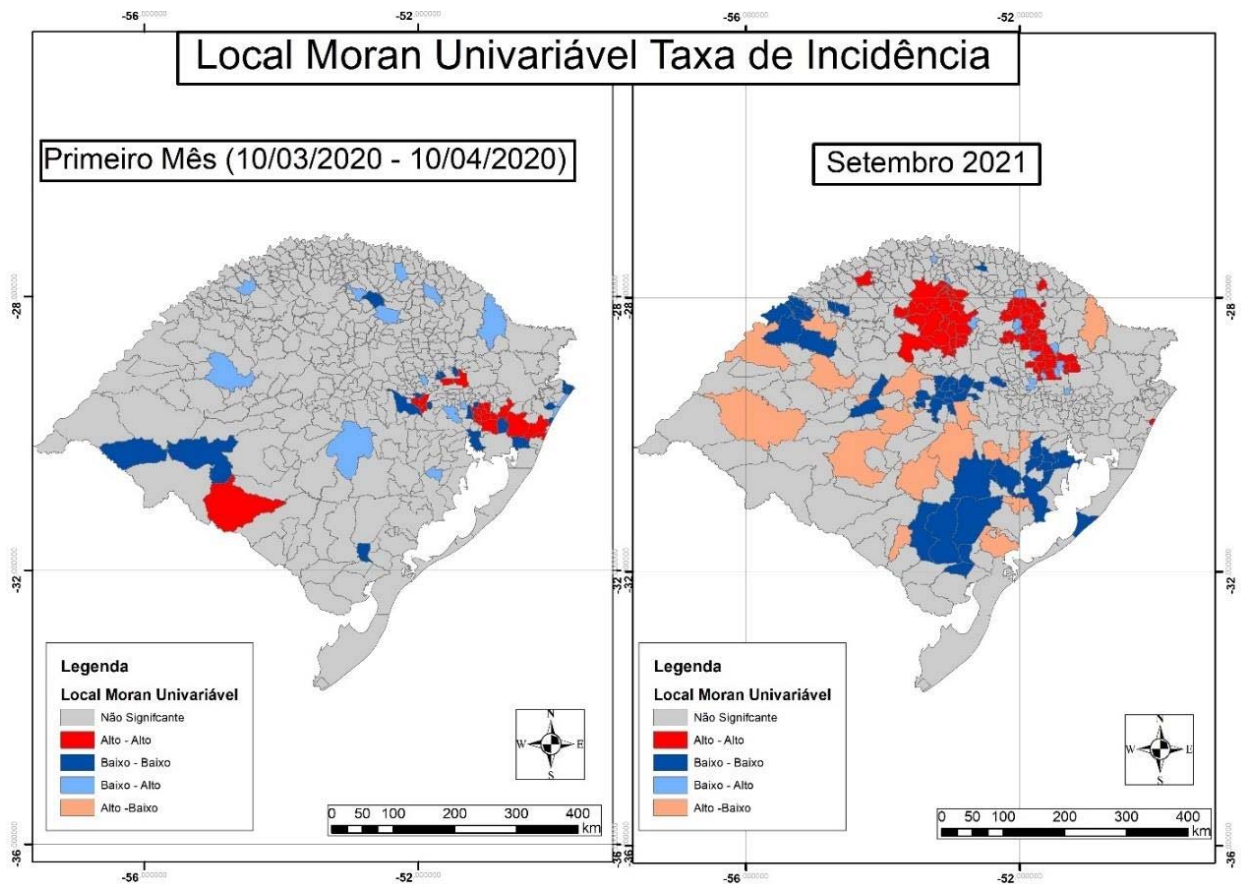
4.2.1 Mapas de autocorrelação espacial local univariados

Ao espacializar-se a análise de autocorrelação espacial local univariada dos dados epidemiológicos, pode-se perceber nos mapas que, no primeiro mês, municípios com taxas de incidência acima da média foram de regiões de movimentação econômica mais intensa e mais próximos da capital do Estado, neste caso, a Região Metropolitana e o Litoral Norte (Altos-Altos), enquanto Bagé é um caso anômalo (*outlier*) Alto-Baixo (Figura 11a). Isso evidencia um espalhamento da COVID-19 para municípios de grande fluxo de populações não só locais, mas provenientes de todo o Estado para diversas finalidades, desde Torres e Litoral Norte para turismo e lazer e até a Região Metropolitana para o uso do sistema de saúde que facilmente pode sobrecarregar, e sobrecarregou, como em Porto Alegre, que se manteve em 2021 por mais de um mês com leitos de UTI lotados, sendo, inclusive notícia internacional no New York Times

com o título: “Um Colapso Previsto: Como o surto de Covid-19 no Brasil sobrecarregou os hospitais”.

Já em setembro de 2021 (Figura 11b), os municípios com taxas de incidência acima da média deixaram de ser os anteriores, mas sim municípios, principalmente, da área de influência de Passo Fundo (Altos-Altos) e alguns municípios isolados no sul e oeste do Estado (Altos-Baixos). Tal mapa evidencia que, com o passar do tempo, os municípios mais afetados pela alta contaminação foram os de menor porte e estrutura, os quais são influenciados por municípios de maior movimentação econômica e por estradas, como os municípios próximos de Passo Fundo e municípios da fronteira sul e oeste.

Figura 11 - Mapas de autocorrelação espacial local da taxa de incidência em março de 2020 (A) e setembro de 2021 (B).

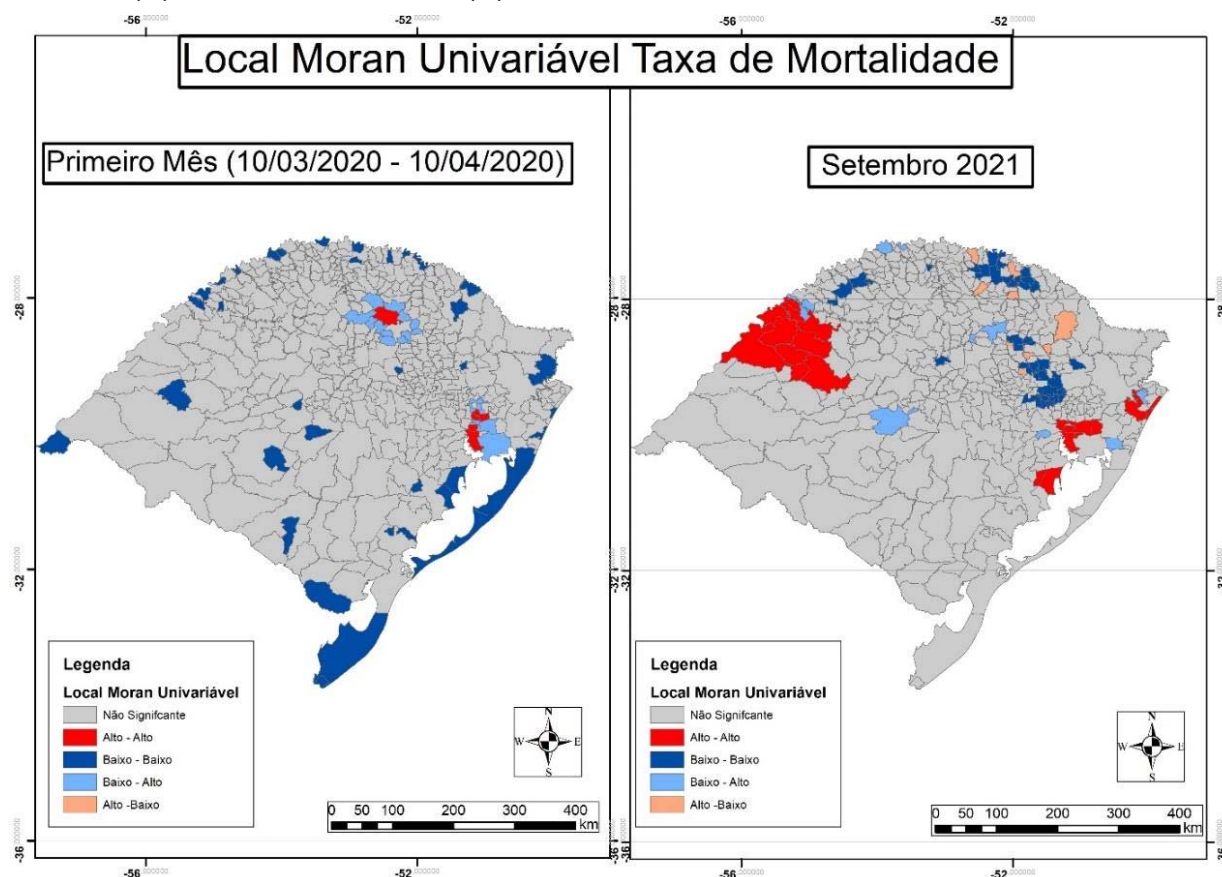


Fonte: Elaborado pelo autor (2022).

Ao analisar-se o mapa da autocorrelação espacial local da taxa de mortalidade (Figura 12), percebe-se que, no primeiro mês, municípios com taxas de mortalidade acima da média foram de regiões de movimentação econômica mais intensa e mais próximos da capital do Estado, neste caso, a Região Metropolitana e Passo Fundo (Altos-Altos), havendo casos anômalos (*outlier*) Baixo-Alto como municípios da RMPA e vizinhos de Passo Fundo (Figura 12b). Isso evidencia um já assentamento da COVID-19 nestes municípios, à medida que a doença é de lento desenvolvimento dos sintomas, que também são de grande fluxo de populações não só locais, mas provenientes de todo o Estado para diversas finalidades, Passo Fundo recebe também habitantes do oeste de Santa Catarina da região próximo à fronteira.

Já em setembro de 2021 (Figura 12b), os *clusters* de taxa de mortalidade acima da média significativos são encontrados na Região Metropolitana, no Litoral Norte e na região da fronteira oeste de influência do município de São Borja (Altos-Altos) e alguns municípios isolados no norte do Estado (Altos-Baixos). Tal mapa evidencia que, com o passar do tempo, os municípios mais afetados pela alta mortalidade, foram os de menor porte e estrutura, os quais são influenciados por municípios de maior movimentação econômica e/ou turística e por estradas, como o litoral e a fronteira oeste, sendo essa caracteristicamente mais precária, possuindo estrutura inferior a diversos municípios que possuíam números de casos maiores, entretanto com maior capacidade em estrutura para lidar com os casos graves.

Figura 12 - Mapas de autocorrelação espacial local da taxa de mortalidade em março de 2020 (A) e setembro de 2021 (B).



Fonte: Elaborado pelo autor (2022).

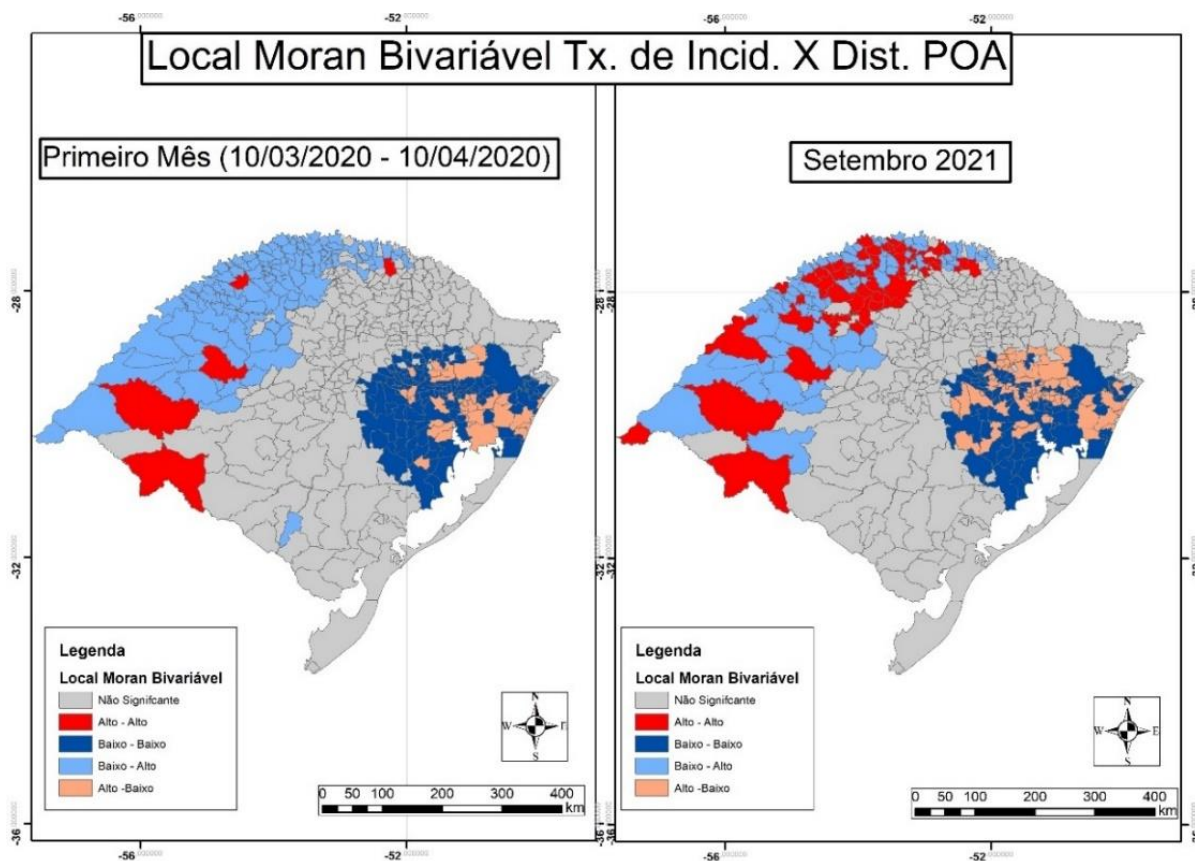
4.2.2 Mapas de autocorrelação espacial local bivariados

4.2.2.1 Distância de Porto Alegre

Observando os dados espacializados em mapas autocorrelação espacial local bivariados, percebe-se que, no primeiro mês (Figura 13a), a taxa de incidência estava acima da média majoritariamente na região de proximidade à capital com diversos municípios classificados em Alto-Baixo (Alta taxa de incidência – Baixa distância). Entretanto, se evidenciam alguns municípios de alta distância que já começavam a apresentar taxas de incidências acima da média, com a passagem do tempo. Já em setembro de 2021 (Figura 13b), diversos municípios de alta distância da capital encontram-se com taxas de incidência acima da média evidenciando o espalhamento aguçado da pandemia para regiões mais distantes com seu desenrolar. Também,

municípios que antes se encontravam com taxas acima da média e próximos à Porto Alegre, como Viamão, já não se encontram mais, mostrando que com o passar da pandemia a relevância da proximidade da capital vai diminuindo.

Figura 13 - Mapas de autocorrelação espacial local bivariados da taxa de incidência em relação à distância à Porto Alegre em março de 2020 (A) e setembro de 2021 (B).

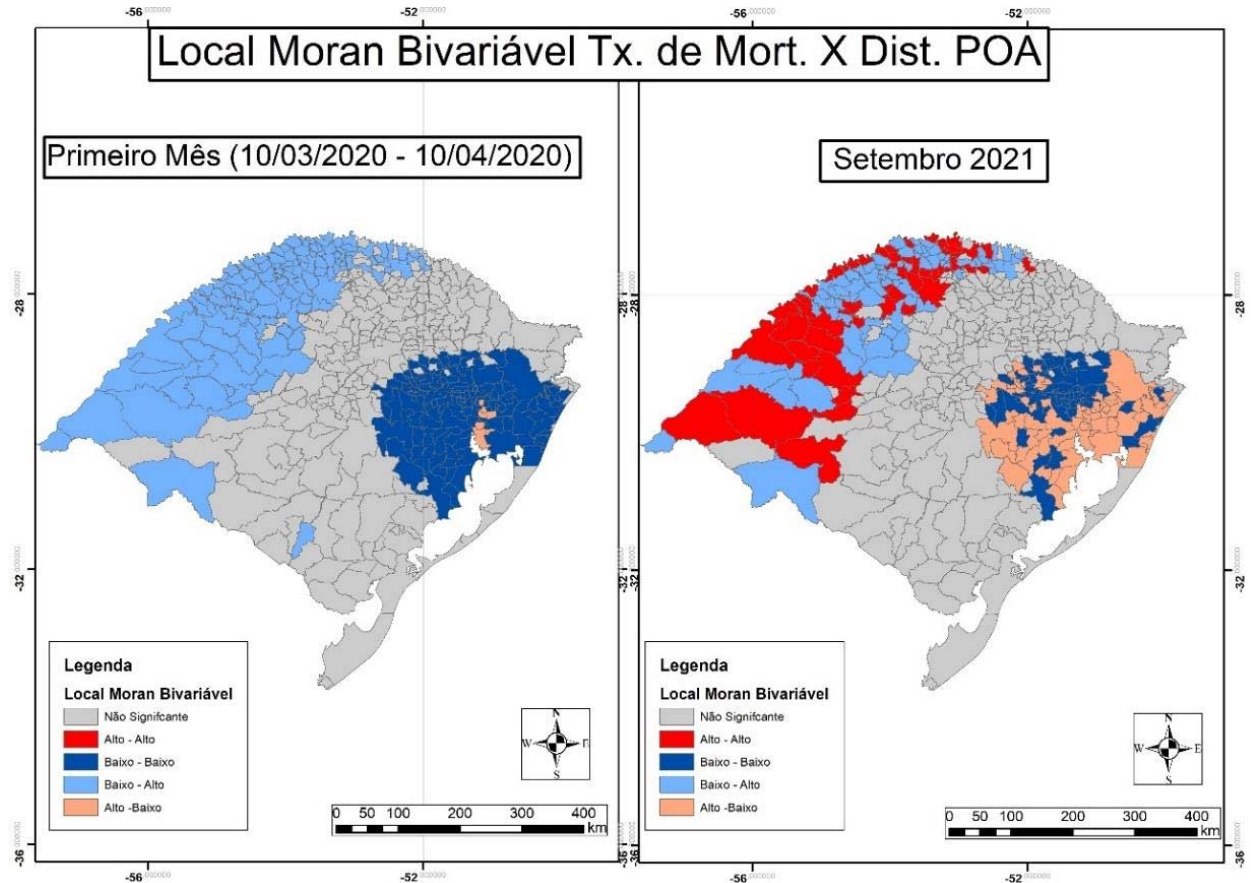


Fonte: Elaborado pelo autor (2022).

Os mapas de autocorrelação espacial local bivariados referentes à taxa de mortalidade em relação à distância à Porto Alegre explicitam que, no primeiro mês (Figura 14a), apenas poucos municípios na proximidade de Porto Alegre encontravam-se com taxas acima da média em relação à baixa distância (Alto-Baixo): Porto Alegre, Canoas, Alvorada, São Leopoldo, Novo Hamburgo e Estância Velha. Estes são municípios com alta mobilidade entre si e outros, seja por carro, transporte público, ônibus metropolitano ou a linha de trem urbano, que passa por 4 destas cidades. Já em setembro de 2021 (Figura 14b), a quase totalidade dos municípios próximos à capital apresentavam taxas de mortalidade acima da média junto com os municípios distantes,

mostrando uma quase nulidade de influência da proximidade de Porto Alegre, o que evidencia o espalhamento aguçado das fatalidades causadas pelo vírus no Estado.

Figura 14 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação à distância à Porto Alegre em março de 2020 (A) e setembro de 2021 (B).



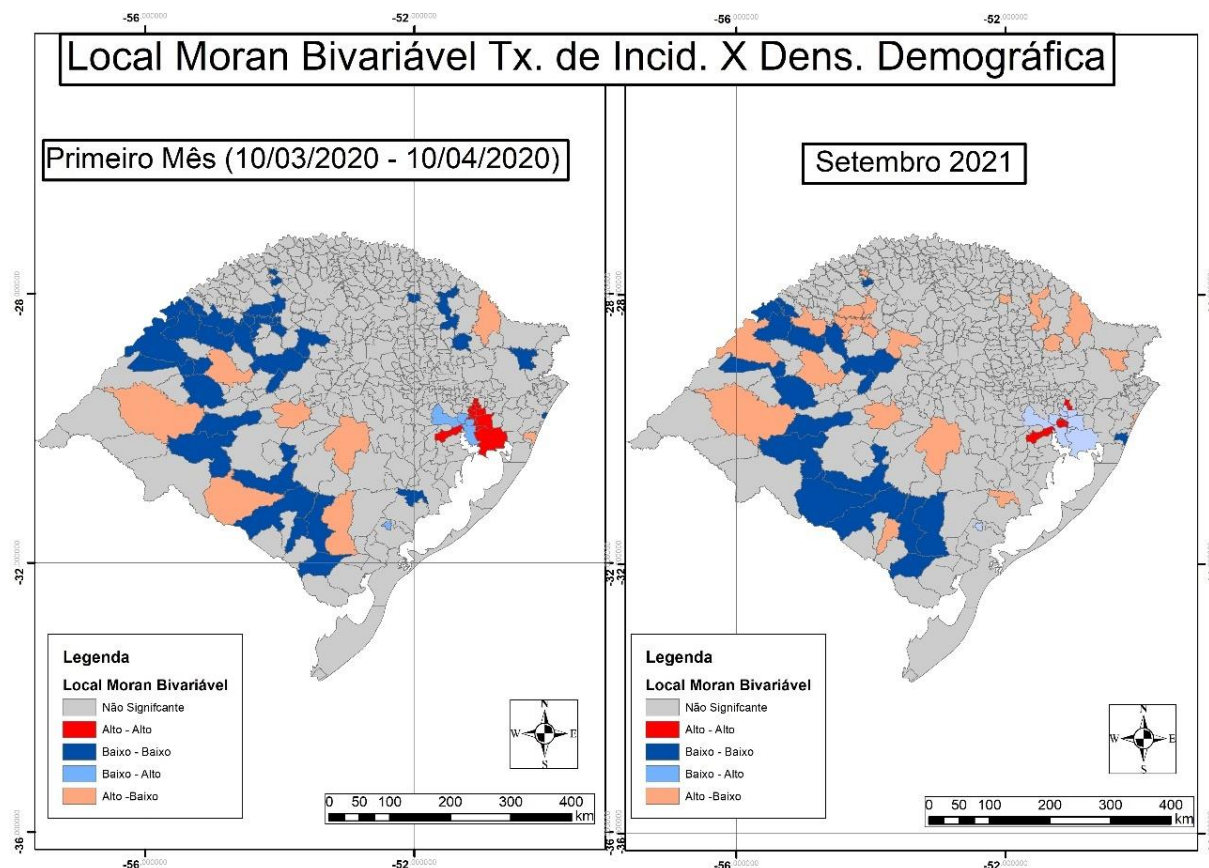
Fonte: Elaborado pelo autor (2022).

4.2.2.2 Densidade demográfica

Nos mapas de autocorrelação espacial local bivariados da taxa de incidência em relação à densidade demográfica, percebe-se que, no primeiro mês (Figura 15a), estava acima da média na região próxima à capital com alguns municípios de alta densidade e alta taxa de incidência (Alto–Alto). Entretanto, se percebe a presença de diversos municípios de baixa densidade com taxas de incidências acima da média, mostrando um espalhamento deveras rápido da pandemia para os locais de baixa densidade demográfica. Com a passagem do tempo, em setembro de 2021 (Figura 15b), a maioria dos municípios com baixa distância da capital e alta densidade

demográfica encontravam-se com taxas de incidência abaixo da média (Baixo-Alto). Evidencia-se também uma intensificação da transmissão do vírus em municípios de baixa densidade demográfica, refletindo um movimento da pandemia para o interior, onde começa a haver um maior impacto no crescimento de casos em locais de baixa densidade demográfica (Alto–Baixo).

Figura 15 - Mapas de autocorrelação espacial local bivariados da taxa de incidência em relação à densidade demográfica em março de 2020 (A) e setembro de 2021 (B).



Fonte: Elaborado pelo autor (2022).

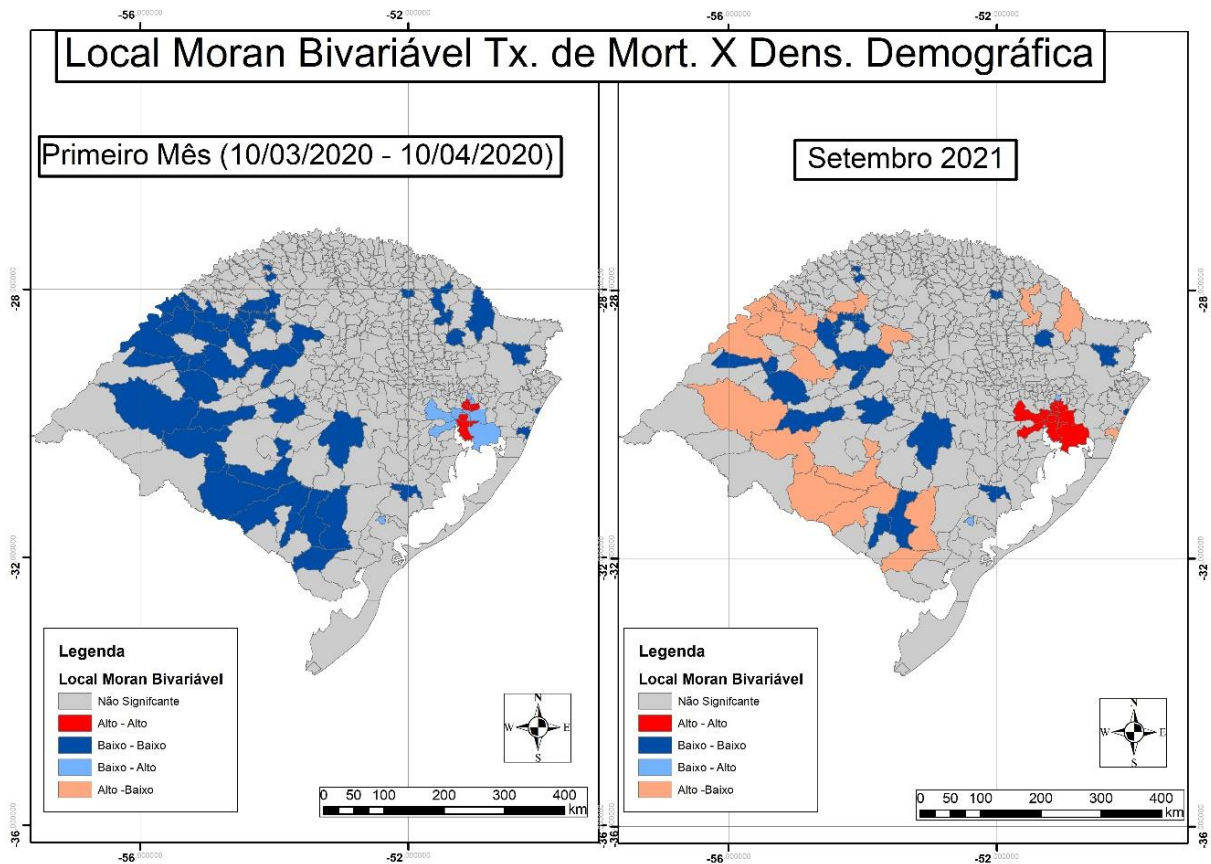
Desta forma, percebe-se a taxa de incidência de casos elevada, principalmente, na Região Metropolitana de Porto Alegre associada com a alta densidade demográfica, evidenciando uma importância maior no espalhamento inicial da doença no Estado. Entretanto, se evidenciavam municípios de baixa densidade com taxas acima da média, (Alto – Baixo), como Alegrete que, apesar de baixa densidade demográfica, possui um fluxo de mobilidade constante, mostrando que outros fatores começavam a influenciar no espalhamento da doença. Em setembro de 2021, evidenciava-se uma diminuição da

contribuição dos locais de alta densidade para níveis de taxa de incidência acima da média. Desse modo, mostrando que o espalhamento da doença já se dava com maior intensidade em locais de baixa densidade e, muitas vezes, pouco controle e medidas de prevenção contra Covid, seja adotado por moradores ou pelo próprio município.

Os mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação à densidade demográfica explicitam que, no primeiro mês (Figura 16a), municípios de alta densidade demográfica da Região Metropolitana apresentaram maiores taxas de mortalidade, estes sendo: Porto Alegre, Canoas, São Leopoldo e Novo Hamburgo, os quais possuem um fluxo de pessoas constante por meio de transporte público e privado, sendo por trem, carro ou ônibus metropolitano. Associado com a alta densidade demográfica, o transporte público se revela um agente influente no espalhamento da doença, pois em áreas com alta densidade demográfica a tendência é de transportes lotados. Como em estudo de Rolnik *et al.* (2020), onde foi explicitado que, no município de São Paulo, a aglomeração em transporte público e o fluxo constante de pessoas para trabalhar através destes meios foi determinante para o espalhamento do vírus.

A alta incidência de casos também pode influenciar em maior letalidade, pois, apesar de muitas vezes municípios de alta densidade possuírem melhor estrutura, não estão preparados para absorver uma demanda de população muito elevada, além de pesar o fato que estas estruturas, muitas, vezes absorvem casos de municípios menores. Já em setembro de 2021 (Figura 16b), a totalidade dos municípios com alta densidade demográfica do Rio Grande do Sul se encontrava com taxa de mortalidade acima da média, mostrando que este *cluster* continua a ser um centro de alta mortalidade por COVID-19, por fatores provavelmente similares aos citados anteriormente, diferente da taxa de incidência que se encontrava abaixo da média nesta região no mesmo momento. Entretanto, percebe-se que municípios de baixa densidade demográfica já começam a, significativamente, terem altas taxas de mortalidades, diminuindo a relevância da densidade demográfica para o valor do índice citado anteriormente.

Figura 16 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação à densidade demográfica em março de 2020 (A) e setembro de 2021 (B).



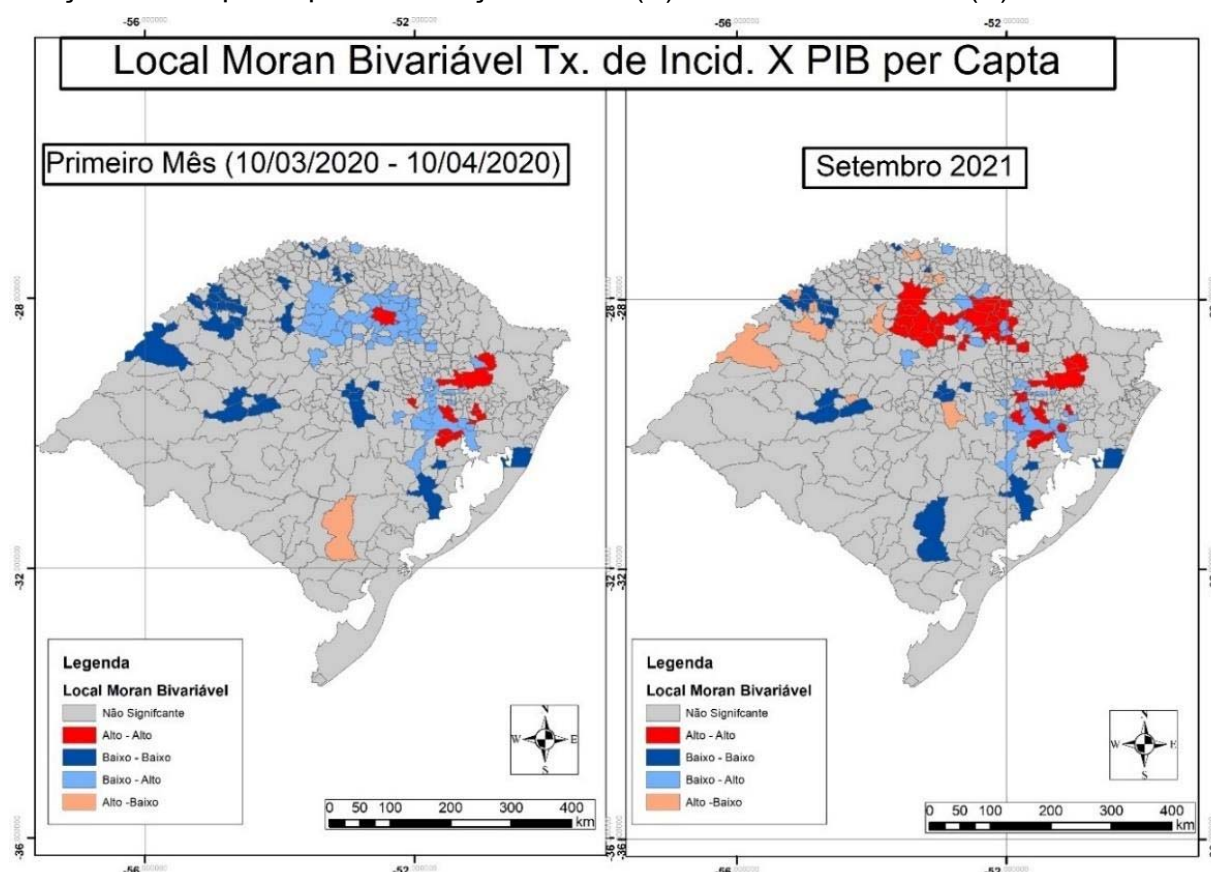
Fonte: Elaborado pelo autor (2022).

4.2.2.3 PIB per capita

Nos mapas de autocorrelação espacial local bivariados da taxa de incidência em relação ao PIB per capita, percebe-se que, no primeiro mês (Figura 17a), os *clusters* de taxa de incidência acima da média e de PIB per capita acima da média (*clusters* Alto – Alto) se encontravam em polos regionais como a Região Metropolitana de Porto Alegre, região de Passo Fundo e a Serra Gaúcha. Sendo que havia apenas um município classificado em Alto–Baixo, ou seja, taxa de incidência alta e PIB per capita baixo, evidenciando que, inicialmente, a pandemia afetou os municípios de maior atividade econômica. Passo Fundo, por exemplo, exerce uma função de centro regional por sua oferta de serviços especializados, em especial, de saúde e centros de formação de nível técnico e superior. Em setembro de 2021 (Figura 17b), percebe-se que

diversos municípios de alto PIB per capita possuem taxa de incidência acima da média, principalmente o espalhamento para os vizinhos de Passo Fundo. Entretanto, apesar de aumento considerável dos municípios classificados em Alto-Alto, há também aumento da presença de municípios de baixo PIB per capita com alta taxa de incidência, classificados em Alto-Baixo, ou seja, percebe-se que há o espalhamento para municípios de baixo PIB per capita de forma significativa.

Figura 17 - Mapas de autocorrelação espacial local bivariados da taxa de incidência em relação ao PIB per capita em março de 2020 (A) e setembro de 2021 (B).

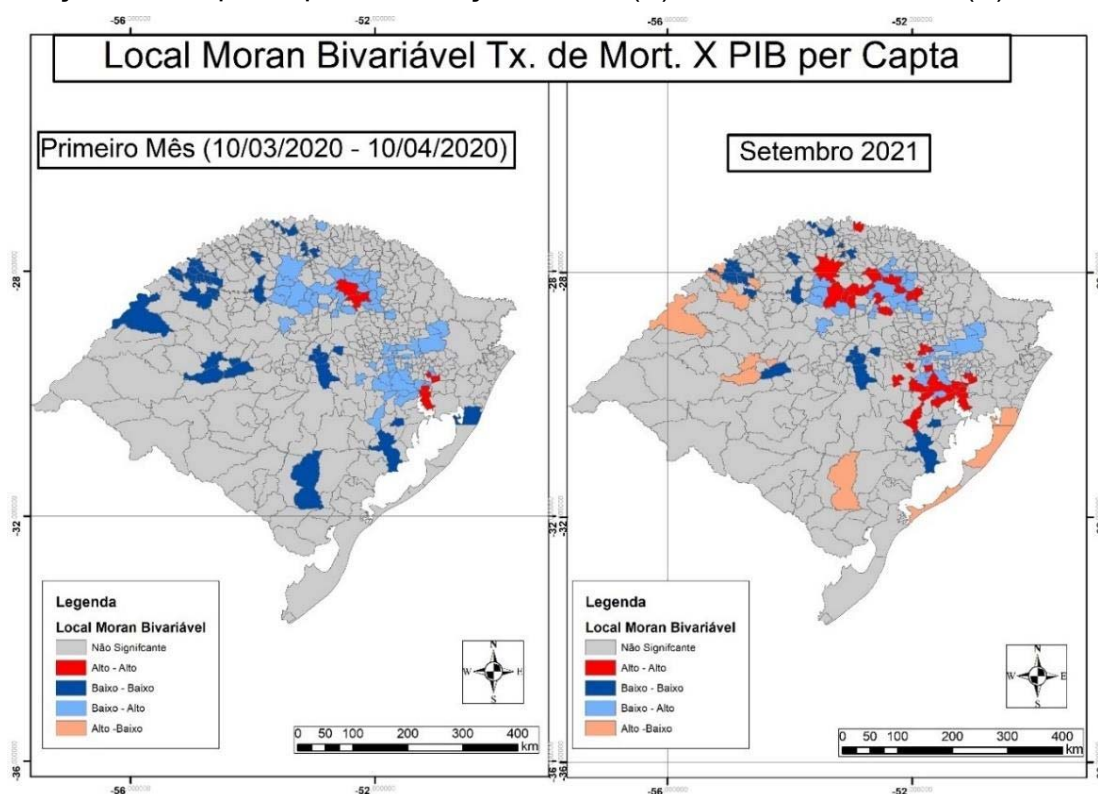


Fonte: Elaborado pelo autor (2022).

Os mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação ao PIB per capita explicitam que, no primeiro mês (Figura 18a), apenas municípios na proximidade de Porto Alegre e de Passo Fundo encontravam-se com esta taxa acima da média associada a alto PIB per capita. A mortalidade acima da média mostra-se, exclusivamente, presente nestes municípios com ausência total de municípios classificados em Alto-Baixo, ou seja, que teriam alta taxa de mortalidade e

baixo PIB per capita. Já em setembro de 2021 (Figura 18b), percebe-se um espalhamento da alta taxa de mortalidade entre os municípios de alto PIB per capita (*clusters* Alto – Alto), porém há agora a presença significativa de municípios classificados em Alto – Baixo, ou seja, com alta taxa de mortalidade e baixo PIB per capita, justificando a tendência de reversão observada nos histogramas anteriores, em que os municípios de menor PIB per capita começam a ter significância maior para a mortalidade do Estado, diferente da taxa de incidência que ainda encontra-se positivamente correlacionada. Desse modo, a taxa de mortalidade evidencia uma tendência de que mesmo os municípios de maior PIB per capita sendo mais significativos para a incidência de casos de COVID-19, os municípios de menor valor de PIB per capita são mais atingidos pelos óbitos, o que pode estar associado com menor capacidade estrutural para tratamento dos casos. Os mapas podem ser observados a seguir.

Figura 18 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação ao PIB per capita em março de 2020 (A) e setembro de 2021 (B).

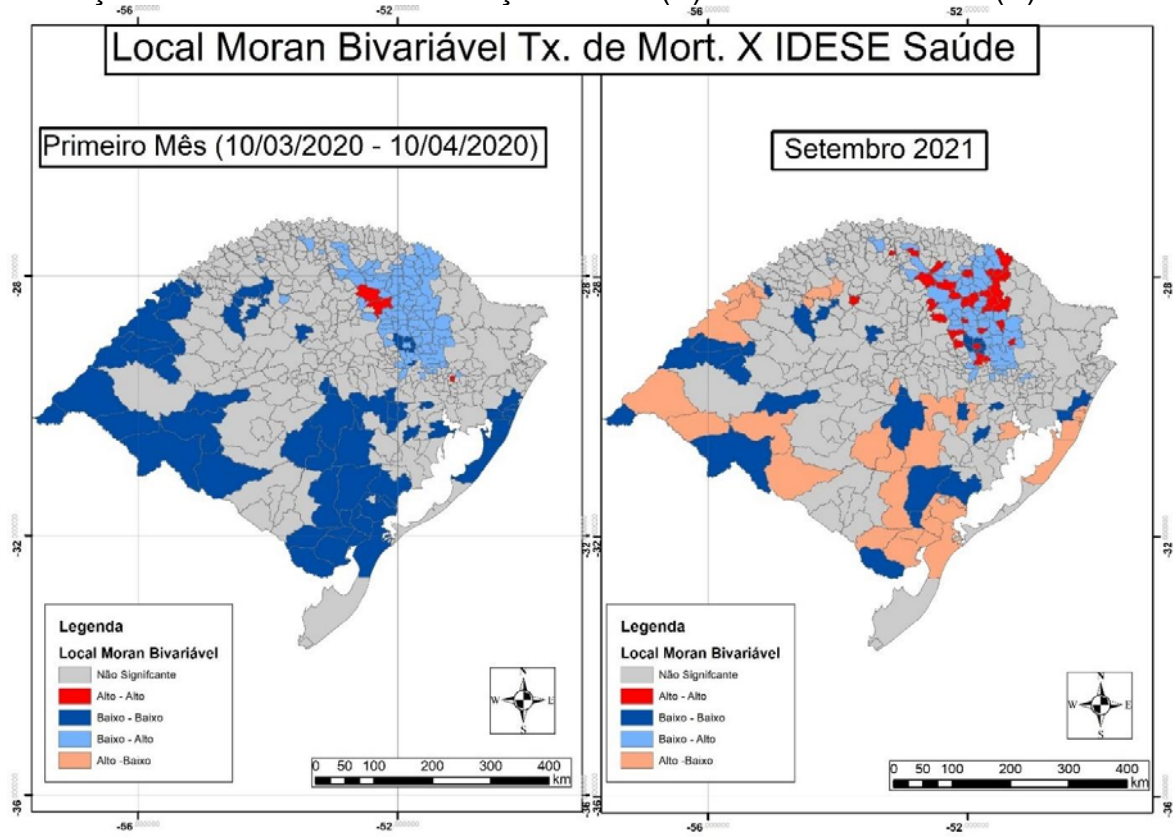


Fonte: Elaborado pelo autor (2022).

4.2.2.3 Índice IDESE Saúde

No mapa de autocorrelação espacial local bivariado da taxa de mortalidade em relação ao IDESE Saúde se percebe que, no primeiro mês (Figura 19a), os *clusters* de taxa de mortalidade acima da média eram apenas *hot spots* Alto–Alto, ou seja, uma alta mortalidade e uma avaliação alta no bloco saúde do IDESE. Este resultado evidenciou que a pandemia, inicialmente, afetou municípios mais bem estruturados em termos de serviços de saúde, no caso aqui três: Passo Fundo, Marau e Farroupilha, enquanto municípios de baixa avaliação ainda estavam com baixa taxa de mortalidade (Baixo–Baixo). Em setembro de 2021 (Figura 19b), a maioria dos municípios de baixa avaliação no bloco saúde, que antes formavam *cold spots* Baixo–Baixo, passaram a formar agrupamentos Alto–Baixo, ou seja, com uma taxa de mortalidade acima da média. Houve aumento também de *hot spots* Alto–Alto, entretanto os municípios que anteriormente estavam nessa categoria reduziram sua taxa de mortalidade, encontrando-se agora na classe Baixo–Baixo, evidenciando a capacidade de controle da letalidade da doença destes municípios.

Figura 19 - Mapas de autocorrelação espacial local bivariados da taxa de mortalidade em relação ao IDESE Saúde em março de 2020 (A) e setembro de 2021 (B).



5 DISCUSSÃO

Ao se observar o avanço espaço-temporal da COVID-19 a partir dos dados gerados, percebe-se a interiorização da doença, seu espalhamento para o interior, bem como a influência das diferenças estruturais e econômicas das diferentes regiões do Estado do Rio Grande do Sul.

No primeiro mês da presença do vírus no Estado, a incidência encontrava-se com taxas elevadas em locais específicos, começando a se instaurar ainda em locais mais distantes da região de onde parte o espalhamento da doença, a Região Metropolitana de Porto Alegre. Como visto anteriormente, os principais municípios com alta taxa de incidência são aqueles classificados como Alto-Baixo, ou seja, possuem alta taxa de incidência e baixa distância de Porto Alegre, no primeiro mês. Enquanto em setembro de 2021, é visível o espalhamento da doença para o interior e os locais mais distantes da centralidade do Estado, a Região Metropolitana de Porto Alegre (RMPA). Isso também pode ser visualizado na Figura 17, em que no primeiro mês há a presença de altas taxas de incidência majoritariamente em municípios de alto PIB per capita, como Passo Fundo e Caxias do Sul, centros regionais de alto fluxo de pessoas e atividades econômicas, propiciando o espalhamento do vírus através desse fluxo, havendo apenas um município de baixo PIB per capita com alta taxa de incidência. Entretanto, é perceptível o espalhamento depois para os demais municípios em setembro de 2021, o que evidencia o avanço da doença ao interior do Estado. Inicialmente, a pandemia se concentrava em municípios com alto fluxo e baixa distância de Porto Alegre e as taxas de incidência ainda se mantêm com taxas elevadas nestes municípios, entretanto, para a taxa de mortalidade o seu decorrer foi diferente.

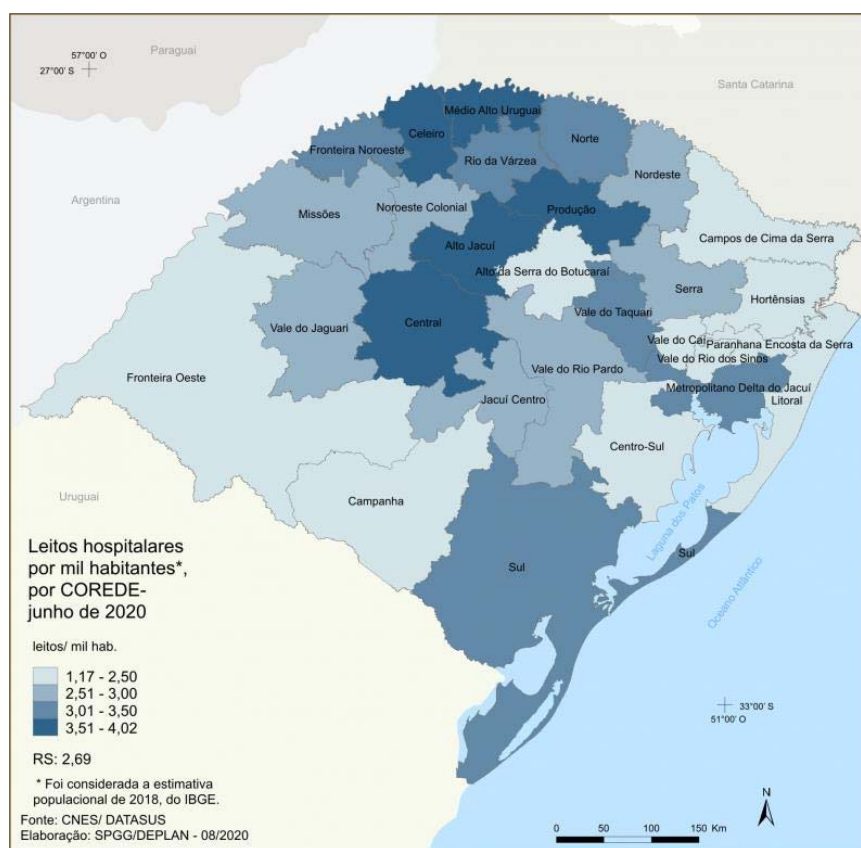
A taxa de mortalidade apresentou-se majoritariamente elevada, no primeiro mês, em municípios com as seguintes características: alta densidade, alto PIB per capita, baixa distância de Porto Alegre e alta avaliação no IDESE Saúde. Estes também são os de maior fluxo econômico e de mobilidade pendular, enquanto em municípios interioranos, apesar de alguns já possuírem alta taxa de incidência, a doença não causou alto número de mortes. É interessante analisar a Figura 19, em que, é associada a variável da taxa de mortalidade com a avaliação no IDESE Saúde, municípios como Passo Fundo, Marau e Farroupilha, no primeiro mês, estão

classificados como Alto–Alto, ou seja, alta mortalidade e alta avaliação no IDESE Saúde, não havendo municípios de baixa avaliação com alta mortalidade. Já, em setembro de 2021, estes três municípios encontravam-se com baixa mortalidade, explicitando a capacidade do sistema de saúde de se estruturar para lidar com os internados pela doença, enquanto a maioria dos municípios de baixa avaliação no IDESE se encontravam neste período com alta mortalidade. Estes municípios são de regiões com diferenças estruturais e econômicas significativas como a Fronteira Oeste e a Região Sul, que serão abordadas melhor em seguida.

Desse modo, observa-se a que além da interiorização da transmissão da doença, há também a dos impactos da doença à medida que, apesar de taxas de incidência altas em municípios diversos e heterogêneos em estruturas de serviços públicos e econômica. No período de setembro de 2021, a mortalidade ressalta suas desigualdades, à medida que municípios mais bem estruturados conseguem dar uma resposta significativa para impedir a morte de internados pela Covid-19.

Referente às diferenças estruturais, destaca-se a diferença dos diversos municípios da Serra e os da Região Metropolitana de Porto Alegre contrastando com municípios fronteiriços, interioranos e do litoral, onde uma estrutura pública de qualidade inferior acaba por influenciar em índices, principalmente, de mortalidade. Municípios como Rio Grande e São Borja acabam por possuir alta mortalidade e uma avaliação no IDESE baixa, mostrando que a falta de estrutura é crucial para altos índices de mortalidade e destacando diferenças regionais entre os municípios que influenciaram diretamente no desenrolar da pandemia. No início da pandemia é nítido que os principais municípios afetados são os próximos a Porto Alegre, de alta densidade, PIB per capita elevado e de alta avaliação na saúde, evidenciando também a entrada do vírus por locais de maior afluxo econômico. Entretanto, as taxas de mortalidade começam a se destacar em municípios do interior com PIB per capita baixo, baixa densidade demográfica, e, principalmente, em relação à variável referente ao IDESE Saúde, pois a maioria dos municípios de baixa avaliação no índice encontram-se com altas taxas de Isso destaca uma diferença estrutural de saúde entre que fica evidente na Figura 20, em que mostra a distribuição dos leitos de UTI por mil habitantes no Rio Grande do Sul.

Figura 20 - Leitos de UTI por mil habitantes no Estado do Rio Grande do Sul.



Fonte: SPGG/DEPLAN (08/2020).

Percebe-se que há concentração dos leitos de Unidade de Tratamento Intensivo (UTI) nas COREDES rumando a fronteira com o oeste de Santa Catarina, assim como a Região Metropolitana de Porto Alegre e a COREDE SUL. Há a baixa presença de leitos na COREDE Fronteira Oeste onde se evidenciou mortes elevadas com o desenrolar da pandemia e necessidade de absorção de diversos casos transfronteiriços, assim como uma falta de estrutura para tratamento destes casos, outras COREDES como a da Campanha apresentou situação similar. Essa menor estrutura de saúde para tratamento intensivo afeta diretamente o valor da taxa de mortalidade da COVID-19, à medida que a presença de leitos de UTI é essencial para evitar o óbito pela doença quando em estado grave. Outra região de destaque em relação às diferenças estruturais é a do Litoral, a qual possui baixa quantidade de leitos e em setembro de 2021 encontrava-se com taxa de mortalidade elevada como destacado nos produtos gerados, sendo também uma região com municípios de baixa

avaliação no IDESE Saúde e baixo PIB per capita. A partir disso, percebe-se uma característica de sindemia, a epidemia influenciada por fatores sociais, conforme é visível que estes fatores foram determinantes para a forma com que se agravou a pandemia no Estado, e também a característica de mistanásia, onde essas mortes mostram-se passíveis de terem sido evitadas com melhor planejamento e investimento estrutural, assim evidenciando, ainda mais, as distinções intrarregionais, diferenças estas que se mostram influentes no impacto do vírus nas municipalidades.

6 CONCLUSÃO

A principal hipótese que guiava o estudo de que existe correlação entre as taxas de incidência e mortalidade nos municípios sul-riograndenses com variáveis socioeconômicas, e que a partir destas é possível um melhor entendimento do desenvolvimento da pandemia no Estado, mostrou-se verdadeira com base na metodologia adotada. A sindemia mostrou-se um fato à medida que os impactos variaram conforme diferenças estruturais que vão além do indivíduo e se relacionam com fatores sociais. Percebe-se a importância da estrutura pública e da dinâmica espacial do Estado, que com o passar do tempo se destacou, principalmente evidenciando como municípios, de muitas vezes menor densidade, estrutura pública de qualidade relativa inferior e de menor desenvolvimento econômico, são mais vulneráveis. Assim, estes municípios, mesmo podendo possuir taxas de incidências menores, acabam por possuir maior taxa de mortalidades, sendo sinal da vulnerabilidade da população relacionada com a necessidade de utilização de um sistema público de saúde incapaz de corresponder a demanda exigida e estruturalmente fraco. Referente as variáveis concluiu-se que variáveis como; a Distância de Porto Alegre e a Densidade Demográfica foram perdendo significância com o desenrolar da pandemia, explicitando a interiorização da doença e aumento do impacto da mesma em municípios menores, já a variável de PIB per Capta evidenciou uma tendência inicial de absorção do impacto nestes municípios de maior fluxo econômico, que tendenciava a inversão em setembro de 2021, mostrando, que, municípios de menor fluxo econômico começavam a ser os mais impactados pelo vírus, a variável que se mostrou mais significativa fora a do IDESE-Saúde que destacou as diferenças estruturais entre municípios para enfrentamento da pandemia, e possuindo um índice elevado de autocorrelação espacial (-0,139) que mostra sua significância para o entendimento da distribuição das variáveis referentes a doença da Covid-19. Isso mostrou-se essencial para o entendimento da distribuição das taxas elevadas de mortalidade. Os resultados revelam a necessidade de pensar as políticas públicas para municípios que, apesar de possuírem baixa incidência da doença, mantém os níveis elevados de mortalidade, exigindo um foco específico do poder público levando em

conta as diferenças inter-regionais do Estado.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ANSELIN, Luc. **Local Spatial Autocorrelation (1), (2), (3) & (4)**. Geodacenter. Disponível em: <<https://geodacenter.github.io/>> Acesso em: 10 mar. 2022.
- ANSELIN, Luc. **An Introduction to Spatial Autocorrelation Analysis with GeoDa**. Spatial Analysis Laboratory, Department of Agricultural and Consumer Economics, University of Illinois, Urbana-Champaign, 2003.
- CÂMARA, Gilberto; MONTEIRO, Antônio Miguel; FUCKS, Suzana Druck; CARVALHO, Marília Sá. **Análise espacial e geoprocessamento**. Documento online, 2002. Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/analise/cap1-intro.pdf>>. Acesso em: 02 mai. 2022.
- CARVALHO, Marília Sá. **Aplicação de métodos de análise espacial na caracterização de áreas de risco à saúde**. 1997. 149 f. Tese (Doutorado em Engenharia Biomédica) – INPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1997.
- CORONEL, Daniel; ALVES, Fabiano Dutra; SILVA, Mariangela Amaral. Notas sobre o processo de desenvolvimento da Metade Sul e norte do Estado do Rio Grande do Sul: uma abordagem comparativa. **Perspectiva Econômica**, v. 3, n. 2, p. 27- 43, jul./dez. 2007.
- FEE. **PIBs dos Municípios Gaúchos**. Disponível em: <www.fee.rs.gov.br/sitefee/pt/content/estatisticas/pg_pib_municipal_sh.php> Acesso em: 05 mar. 2022.
- FERREIRA, Marcos César. Spatial association between the incidence rate of COVID-19 and poverty in the São Paulo municipality. **Geospatial Health**, v. 15, n. 2, 2020.
- SANTOS, GOMES, NARCISO, SCHRAMM, BRITO, PALÁCIOS, SIQUEIRA-BATISTA, REGO, SANTOS, MARINHO. **Mistanásia hoje: pensando as desigualdades sociais e a pandemia COVID-19**. Observatório da Covid-19 Fiocruz, 2020. Disponível em: <<https://portal.fiocruz.br/documento/mistanasia-hoje-pensando-desigualdades-sociais-e-pandemia-covid-19>>. Acesso em: 26 fev. 2022.
- LABCIDADE. **Territorialização da pandemia**. Disponível em: <<http://www.labcidade.fau.usp.br/category/territorializacao-da-pandemia/>>. Acesso em: 20 mar. 2022.
- LONDOÑO, Ernesto; CASADO, Letícia. **Um Colapso Previsto: Como o surto de Covid-19 no Brasil sobrecarregou os hospitais**. New York Times, 2021. Disponível em: <<https://www.nytimes.com/2021/03/27/world/americas/virus-brazil-bolsonaro.html?action=click&module=Spotlight&pgtype=Homepage>> Acesso em: 08 fev. 2022.

- MORAES, Roberto. **Metade Sul vs Metade Norte**: Uma Comparação a partir de Dados Municipais do Rio Grande do Sul. Disponível em: <<https://arquivofee.rs.gov.br/3ee/g/Artigos/m23t05.pdf>> Acesso em: 10 fev. 2022.
- PAIVA, Carlos. **Dependência Espacial**: Setores Censitários, Zonas OD, Distritos, Subprefeituras, etc. Documento online, CET/SP, PUC/SP, S/D. Disponível em: <<http://www.sinaldetransito.com.br/artigos/espacial.pdf>>. Acesso em: 02 mai. 2022.
- RAMIREZ-ALDANA, Ricardo; GOMEZ-VERJAN, Juan Carlos; BELLO-CHAVOLLA, Omar Yaxmehen. Spatial analysis of COVID-19 spread in Iran: Insights into geographical and structural transmission determinants at a province level. **PLOS Neglected Tropical Diseases**, v. 2, nov. 2020.
- ROLNIK, Raquel; SANTORO, Paula; MARINO, Aluizio; BRITO, Gisele; MENDONÇA, Pedro; KLINTOWITZ, Danielle. **Circulação para trabalho explica concentração de casos de Covid-19**. Labcidade, 30 de junho de 2020. Disponível em: <<http://www.labcidade.fau.usp.br/circulacao-para-trabalho-inclusive-servicos-essenciais-explica-concentracao-de-casos-de-covid-19/>>. Acesso em: 15 mar. 2022.
- SANTOS, Simone; BARCELLOS, Christovam. **Abordagens Espaciais na Saúde Pública**. Brasília: Ministérios da Saúde, 2006.
- SINGER, Merrill. **Introduction to Syndemics**. Editora Jossey-Bass, 2009
- SINGH, Abhishek; PATHAK, Praveen Kumar; CHAUHAN, Rajesh Kumar; PAN, William. Infant and Child Mortality in India in the Last Two Decades: A Geospatial Analysis. **PLoS One**, v. 6, n. 11, e26856, 2011.
- SUSSER, Mervyn. The Logic in Ecological 1 & 2. **American Journal of Public Health**, v. 84, n. 5, p. 825-829, 1994.
- VIEIRA, Rodrigo de Souza. **Crescimento econômico no Estado de São Paulo**: uma análise espacial. São Paulo: Editora UNESP, São Paulo: Cultura Acadêmica, 2009. 103 p.