

Confinis

Revue franco-brésilienne de géographie / Revista franco-brasileira de geografia

52 | 2021

Número 52

Dossiê Aspectos geográficos da pandemia de Covid-19

Análise de dependência espacial da taxa de mortalidade por Covid-19 nos municípios brasileiros

Analysis of the distribution of deaths by Covid-19 in Brazilian municipalities

Analyse de la distribution des décès par Covid-19 dans les communes brésiliennes

VÍTOR HUGO CAMPELO PEREIRA, GLAIRTON CARDOSO ROCHA, MARCO TÚLIO MENDONÇA DINIZ ET MARCOS ANTONIO CAVALCANTE DE OLIVEIRA JÚNIOR

Résumés

Português English Français

O presente artigo objetiva analisar a distribuição de óbitos por COVID-19 nos municípios brasileiros e a relação desta com aspectos socioeconômicos (renda) até a data de 14 de julho de 2020. A metodologia esteve pautada na verificação de autocorrelação espacial com base no Índice Global de Moran e no Índice Local de Moran (LISA) em suas formas univariada e bivariada. A forma univariada foi utilizada para investigação da distribuição da Taxa de Mortalidade por COVID-19 (TMC), enquanto que a forma bivariada foi utilizada para verificação de autocorrelação espacial entre as variáveis TMC (variável dependente) e IDHM Renda (variável independente) nos municípios brasileiros até a data de 14 de julho de 2020. Os resultados evidenciaram a presença de *clusters* formados a partir de agrupamentos de municípios com altos valores de TMC, sobretudo nas regiões Norte e Nordeste do Brasil. Além disso, foi constatada autocorrelação negativa entre as variáveis TMC e IDHM Renda, com destaque para grandes porções territoriais das regiões Norte e Nordeste setentrional. A quantidade de casos de COVID-19 em uma determinada área geográfica e a renda de sua população são fatores essenciais para a compreensão da distribuição dos óbitos relacionados a essa doença.

This article aims to analyze the distribution of deaths by COVID-19 in Brazilian municipalities and its relationship with socioeconomic aspects (income) until the data of July 14, 2020. A methodology was based on the selection of spatial autocorrelation based on the Global Index Moran and the Local Moran Index (LISA) in its univariate and bivariate forms. A univariate form was used to investigate the distribution of the Mortality Rate by COVID-19 (CMD), while the



bivariate form was used to verify spatial autocorrelation between the variables TMC (dependent variable) and MHDI Income (independent variable) in Brazilian municipalities until the data of July 14, 2020. The results show the presence of clusters formed from groups of municipalities with high CMD values, mainly in the North and Northeast regions of Brazil. In addition, a negative autocorrelation was found between the variables TMC and MHDI Income, with emphasis on large territorial portions of the North and Northeast regions. The number of cases of COVID-19 in a geographical area and the income of its population are essential factors for understanding the distribution of habits related to this disease.

Cet article vise à analyser la répartition des décès par COVID-19 dans les communes brésiliennes et sa relation avec les aspects socio-économiques (revenus) jusqu'à la date du 14 juillet 2020. La méthodologie était basée sur la vérification de l'autocorrélation spatiale basée sur le Global Moran Index et le Local Moran Index (LISA) sous ses formes univariée et bivariée. La forme univariée a été utilisée pour étudier la distribution du taux de mortalité par COVID-19 (TMC), tandis que la forme bivariée a été utilisée pour vérifier l'autocorrélation spatiale entre les variables TMC (variable dépendante) et le revenu MHDI (variable indépendante) dans les municipalités brésiliennes au 14 juillet 2020. Les résultats ont montré la présence de *clusters* formées de groupement de communes à valeurs élevées de CMD, en particulier dans les régions du Nord et du Nord-Est du Brésil. De plus, une autocorrélation négative a été trouvée entre les variables TMC et MHDI Income, l'accent étant mis sur de grandes portions territoriales des régions du Nord et du Nord-Nord-Est. Le nombre de cas de COVID-19 dans une zone géographique donnée et le revenu de sa population sont des facteurs essentiels pour comprendre la répartition des décès liés à cette maladie.

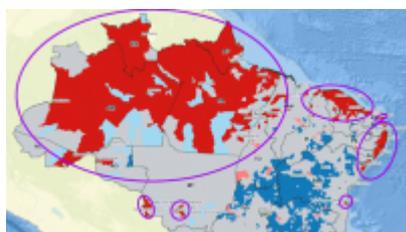
Entrées d'index

Index de mots-clés : autocorrélation spatiale, IDHM, revenu, mortalité, COVID-19.

Index by keywords: spatial autocorrelation, MHDI, income, mortality, COVID-19.

Índice de palavras-chaves: autocorrelação espacial, IDHM, renda, mortalidade, COVID-19.

Texte intégral



Afficher l'image

- 1 O objetivo principal da Análise Espacial é mensurar atributos e relacionamentos, levando em consideração a localização espacial do fenômeno em estudo de forma explícita (Camara *et alii*, 2004a). De acordo com Rosa (2011), a Análise Espacial está associada à Geografia e refere-se ao estudo da distribuição espacial de qualquer fenômeno a procura de padrões espaciais, fazendo ligação entre o domínio cartográfico e as áreas de análise aplicada, a estatística e a modelagem.
- 2 No contexto da Análise Espacial está a Análise Exploratória de Dados Espaciais (AEDE) ou *Exploratory Spatial Data Analysis* (ESDA). A AEDE é um conjunto de técnicas utilizadas para descrição e visualização de distribuições espaciais, identificação de localidades atípicas (*outliers* espaciais), identificação de padrões de associação espacial (*clusters* espaciais) e indicação de diferentes regimes espaciais e outras formas de instabilidade espacial (Anselin, 1999). Uma das principais funções da AEDE é a caracterização da dependência espacial, evidenciando como os valores estão correlacionados no espaço (Camara *et alii*, 2004b). A dependência espacial pode ser mensurada através da autocorrelação espacial que, por sua vez, pode ser estimada por meio de estatísticas (índices) globais (Campos *et alii*, 2013).
- 3 Dentre os indicadores globais de autocorrelação espacial, está o Índice I Global de Moran. Esse índice fornece um valor único como mensuração da associação espacial para todo o conjunto de dados. O Índice de Moran fornece uma medida geral da associação espacial existente no conjunto dos dados, cujo valor varia de -1 a 1 (Almeida, 2012). Valores próximos de zero estão relacionados à inexistência de autocorrelação



espacial significativa considerando os valores dos objetos e de seus vizinhos. Valores positivos para o índice sugerem autocorrelação espacial positiva, indicando semelhança entre o valor do atributo de um objeto e o valor dos seus vizinhos. Valores negativos para o índice indicam autocorrelação negativa.

- 4 Contudo, quando se dispõe de um grande número de áreas para análise, há possibilidade de existência de diversos regimes de correlação espacial em diferentes sub-regiões (Câmara *et alii*, 2004b). De modo a evidenciar tais regimes espaciais, são utilizados os Indicadores Locais de Autocorrelação Espacial ou *Local Indicator for Spatial Autocorrelation* (LISA), propostos por Anselin (1995). O índice local de Moran produz um valor específico para cada área, permitindo o mapeamento/identificação de agrupamentos ou padrões espaciais, que podem não ser verificados através do índice global de Moran (Luzardo *et alii*, 2017).
- 5 Em conjunturas de surtos, epidemias, pandemias, a Análise Espacial pode subsidiar a tomada de decisão dos gestores dos serviços de saúde, a partir da identificação de padrões espaciais característicos relativos à quantidade de casos e/ou óbitos associados a uma determinada doença (Kamel Boulos; Geraghty, 2020), além de direcionar ações de educação permanente, realocação de recursos humanos e físicos, fomentando a produção de informações necessárias para realização de vigilância dos casos (Nardi *et alii*, 2013).
- 6 O primeiro caso registrado da síndrome respiratória aguda grave foi na cidade de Wuhan, província de Hubei, China, no mês de dezembro de 2019. Em 11 de janeiro de 2020, o primeiro óbito relacionado à doença do Coronavírus (COVID-19) foi registrado na mesma cidade referente ao primeiro caso (De Souza Oliveira; De Moraes, 2020; Lai *et alii*, 2020; Wang *et alii*, 2020). No dia 11 de março de 2020, quando o total de mortes registradas no mundo era de 4.613, a Organização Mundial da Saúde (OMS) elevou o estado de contaminação por COVID-19 ao nível de pandemia (Who, 2020). Após aproximadamente 4 meses do anúncio da pandemia, no dia 14 de julho de 2020, haviam sido registradas 570.288 óbitos acumulados relacionados à COVID-19 (OPAS, 2020).
- 7 No Brasil, o primeiro caso foi registrado no estado de São Paulo, em 26 de fevereiro de 2020, e o primeiro óbito relacionado a essa doença foi registrado no dia 17 de março, também na cidade de São Paulo/SP (Brasil, 2020; De Souza *et alii*, 2020; França *et alii*, 2020). Até o dia 14 de julho de 2020, 74.262 óbitos por COVID-19 haviam sido registrados no país.
- 8 Em razão do impacto dos óbitos relacionados à COVID-19 no Brasil e no mundo, pesquisas recentes (Dias *et alii*, 2019; Cardoso *et alii*, 2020; Cavalcante; Abreu, 2020; Sá, 2020; Damette; Goutte, 2020) vêm sendo desenvolvidas no sentido de investigar o comportamento espacial, além de identificar quais variáveis podem contribuir para a compreensão da distribuição espacial dos óbitos associados a essa doença.
- 9 A robustez estatística da AEDE possibilita sua aplicação em diversos ramos, tais como: Geomarketing (Silva; Montanher, 2019), Geografia do crime (Faria *et alii*, 2018), Agricultura (Seffrin *et alii*, 2018), Geologia (Moreira *et alii*, 2003), entre outros. Mais especificamente em estudos sobre a COVID-19, foram encontrados os estudos: Cavalcante e Abreu (2020), Pedrosa e Albuquerque (2020), Kang *et alii* (2020), Dayang *et alii* (2020), Shim *et alii* (2020) e Desjardins; Hohl e Delmelle (2020).
- 10 Considerando a relevância do desenvolvimento de pesquisas acerca da COVID-19, no sentido de fornecer informações que possam embasar as ações dos gestores, sobretudo no âmbito da saúde pública brasileira, bem como as hipóteses de existência de autocorrelação espacial na distribuição dos óbitos relacionados a essa doença e de influência de aspectos socioeconômicos nessa distribuição, o presente estudo objetiva analisar a distribuição espacial dos óbitos por COVID-19 e sua relação com aspectos socioeconômicos nos municípios brasileiros até a data de 14 de julho de 2020.
- 11 Na primeira parte são apresentados os aspectos metodológicos relativos à pesquisa, onde são abordadas informações acerca do conjunto amostral, fonte dos dados e técnicas utilizadas. Na segunda parte são expostos os resultados e as respectivas discussões.



Metodologia

- 12 Trata-se de um estudo geográfico e exploratório, cujas unidades espaciais analisadas foram os municípios brasileiros com pelo menos um registro de óbito por COVID-19 até a data de 14 de julho de 2020 (3.116 municípios). A variável dependente utilizada foi a Taxa de Mortalidade por COVID-19 (TMC), calculada a partir da quantidade de óbitos a cada 100.000 habitantes nos municípios da amostra. Os dados sobre a COVID-19 foram obtidos junto às Secretarias Estaduais de Saúde e ao Ministério da Saúde do Brasil (MS). As informações populacionais dos municípios são oriundas das estimativas populacionais mais recentes para o ano de 2019, do Instituto Brasileiro de Geografia e Estatística (IBGE).
- 13 Considerando a hipótese de influência de aspectos socioeconômicos na distribuição de óbitos por COVID-19, foi utilizado o Índice de Desenvolvimento Econômico dos Municípios (IDHM) em sua dimensão denominada IDHM Renda como variável independente. Essa variável se baseia na renda per capita dos municípios e está pautada em uma escala de 0 a 1, de modo que os valores mais próximos de 1 indicam melhor renda per capita. Esse dado também foi obtido de forma secundária a partir de levantamento junto à publicação mais atual disponibilizada pelo Atlas do Desenvolvimento Humano no Brasil do Instituto de Pesquisa Econômica Aplicada (IPEA, 2013). No Quadro 1 é possível visualizar uma síntese dos dados utilizados e suas respectivas fontes.
- 14 Alguns estudos recentes analisam a relação entre renda per capita e o número de casos por COVID-19. Rafael *et alii.* (2020) analisam esta relação (renda per capita e a incidência de casos de COVID-19) em bairros do município do Rio de Janeiro, Brasil, indicando que taxas de incidência de COVID-19 são influenciadas pela renda dos bairros de residência onde os casos são identificados. Em outro estudo, Teixeira *et alii.* (2020) analisam a incidência e mortalidade por COVID-19 e suas relações com variáveis como renda média per capita, raça e densidade demográfica. Como resultado, identificaram uma correlação significativa entre a incidência de casos acumulados e os índices de mortalidade, assim como com a média da renda.

Quadro 1: Origem dos Dados Secundários

Dados	Fonte
Informações epidemiológicas sobre a COVID-19 no Brasil	https://covid.saude.gov.br/ e https://brasil.io/dataset/covid19/caso/ https://covid19br.wcota.me/
Estimativas populacionais para o ano de 2019 (IBGE)	https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html?=&t=resultados
IDHM Renda (Atlas do Desenvolvimento Humano no Brasil)	http://www.atlasbrasil.org.br/2013/pt/consulta/

Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021).

- 15 A análise de dependência espacial (autocorrelação espacial) foi realizada com base em AEDE, mais especificamente a partir do Índice I de Moran Global univariado (eq. 1), cuja função principal é estimar a autocorrelação espacial. Esse índice pode variar entre -1 e +1, de modo que valores positivos indicam autocorrelação positiva e valores negativos indicam autocorrelação negativa. Para a validação do Índice de Moran Global, foi utilizado o teste de permutação aleatória, com 999 permutações, e elaborado um diagrama de espalhamento de Moran (*Moran Scatterplot Map*), para visualização adicional da dependência espacial.



$$I(d) = \left[\frac{n}{W_d} \right] \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij}(d)(x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- 16 Onde: (1) n é o número de unidades; $w_{ij}(d)$ é a matriz de conectividade da classe de contiguidade dd (também conhecida como matriz de pesos); W_d é a soma de todos os $w_{ij}(d)$, sendo o número de pares de locais por classe de contiguidade; x_i e x_j são os valores da variável de interesse nas unidades (locais) i e j .
- 17 Após a análise de dependência espacial global, investigou-se a existência de *clusters*, através do Moran Local univariado ou *Local Indicators of Spatial Association* (LISA). Esta estatística deve atender aos seguintes critérios: um indicador *LISA* deve apresentar, para cada município, uma evidência de agrupamentos espaciais significantes com valores similares em torno do mesmo; a soma dos *LISA* para todos os municípios é proporcional ao Índice de Moran Global (Anselin, 1995). O indicador *LISA* pode ser definido pela equação (2).

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

- 18 Onde: (2) σ_i^2 - variância populacional da variável em estudo dos n municípios; x_i - observação de uma variável de interesse no município i para, e μ - média dos n municípios (populações).
- 19 Considerando o indicador *LISA*, elaborou-se um mapa com os valores de significância (p) relativo à TMC, e foram identificados os *clusters* com valor de $p = 0,05$, $p = 0,01$ e $p = 0,001$ a partir de um *MoranMap*, subdividido em quatro classes: Alto-Alto (*cluster*), Alto-Baixo (*outlier*), Baixo-Alto (*outlier*) e Baixo-Baixo (*cluster*).
- 20 Após a identificação dos *clusters* relativos à TMC, verificou-se a associação espacial dos mesmos com o indicador socioeconômico selecionado (IDHM Renda). Para isso, foram utilizados os Índices de Moran Global e Local bivariados e produzidos os respectivos diagramas de espalhamento de Moran e *MoranMap* para o par de análise, considerando os testes entre a variável dependente (óbitos por COVID-19 a cada 100.000 habitantes ou TMC) e a variável independente (IDHM Renda).
- 21 Com base na análise bivariada, elaborou-se o mapa de significância, e o *MoranMap* apenas para as áreas com significância (p) = 0,05 a 0,001, visando a verificação da existência de *clusters* ou *outliers* relativos à associação espacial entre as variáveis supracitadas. No Quadro 2 são apresentadas as classes de significância para autocorrelação espacial consideradas no estudo e suas respectivas cores no mapeamento temático, enquanto que no Quadro 3 estão descritas as classes do *MoranMap* e respectivas cores no mapeamento temático para as análises univariada e bivariada.

Quadro 2: Valores de significância para autocorrelação espacial considerados e respectivas cores no mapeamento temático.

Significância	Descrição	Mapeamento temático (cor)
$p > 0,05$	Não significativa	
$p = 0,05$	Valor de confiança quanto à existência de autocorrelação espacial em 95%	
$p = 0,01$	Valor de confiança quanto à existência de autocorrelação espacial em 99%	
$p = 0,001$	Valor de confiança quanto à existência de autocorrelação espacial em 99,9%	



Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021).

Quadro 3: Descrição das classes do *MoranMap* e suas respectivas cores no mapeamento temático.

Classe	Descrição	Mapeamento temático (cor)
Alto-Alto (<i>cluster</i>)	Valores positivos/médias positivas (vizinhos com altos valores semelhantes)	Red
Alto-Baixo (<i>outlier</i>)	Valores positivos/médias negativas (Valores altos com vizinhos com valores baixos)	Light Red
Baixo-Alto (<i>outlier</i>)	Valores negativos/médias positivas (Valores baixos com vizinhos com valores altos)	Light Blue
Baixo-Baixo (<i>cluster</i>)	Valores negativos/médias negativas (Valores baixos com vizinhos com valores baixos)	Dark Blue
Não significativa	Autocorrelação espacial não significativa	Grey

Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021).

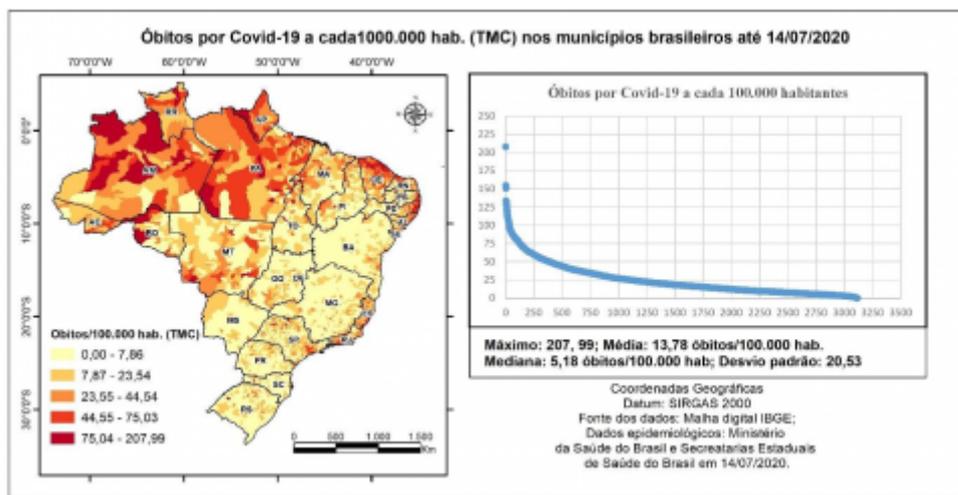
- 22 A espacialização dos dados se deu a partir dos módulos de cartografia temática estatística espacial no *software* ArcGIS 10.4 (versão acadêmica) para as análises espaciais univariadas (TMC). Para as análises espaciais bivariadas, utilizou-se o *software* GeoDA.

Resultados

- 23 O número total de óbitos por COVID-19 no Brasil até a data de 14 de julho de 2020 era 73.967 (MS, 2020c), distribuídos por 3.116 municípios, ou seja, 56,04% dos municípios brasileiros registraram óbitos relacionados a essa doença até a data de referência do estudo. São Paulo/SP (8.212 óbitos), Rio de Janeiro/RJ (7.355 óbitos) e Fortaleza/CE (3.534 óbitos) são os municípios brasileiros com mais óbitos por COVID-19 em termos absolutos. Em relação aos óbitos por COVID-19 a cada 100.000 habitantes (TMC), os municípios com maiores valores são: Gastão do Vidigal/SP (207,98), Areia Branca/RN (154,82) e Saldanha Marinho/RS (150,94). A partir da Figura 1 é possível visualizar a distribuição dos valores de óbitos por COVID-19 a cada 100.000 habitantes, relativa à amostra considerada.

Figura 1: Óbitos por COVID-19 a cada 100.000 habitantes (TMC) nos municípios brasileiros até o dia 14/07/2020.

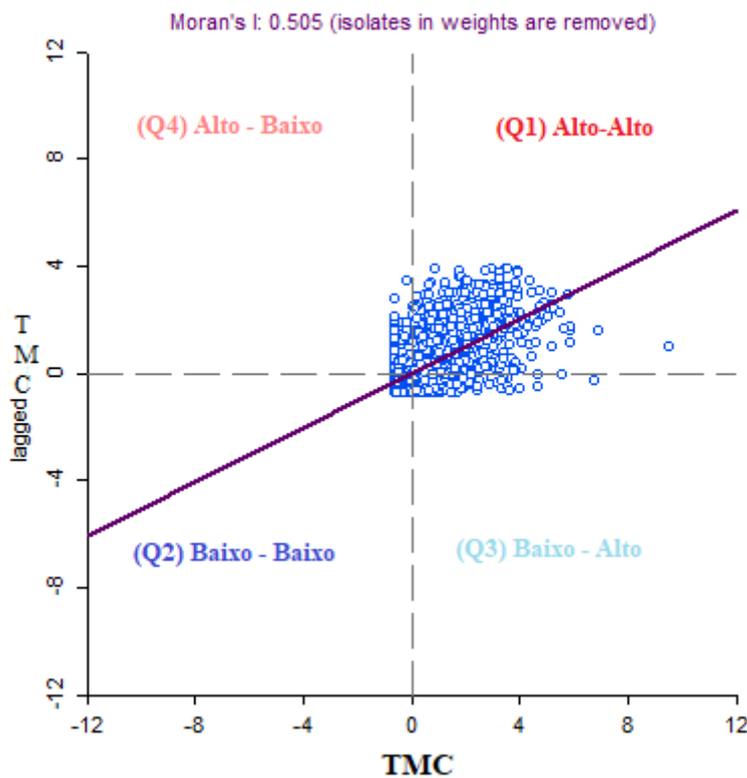




Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.

24 O índice I Global de Moran foi utilizado para verificar a existência de autocorrelação espacial na distribuição da TMC nos municípios brasileiros. O resultado obtido para esse índice foi de $I = 0,505$ (Figura 2), o que evidencia a existência de autocorrelação espacial no conjunto global dos dados.

Figura 2: Diagrama de espalhamento de Moran/Moran Scatterplot para a variável TMC.



Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.

25 Considerando o gráfico de espalhamento de Moran ou *Moran Scatterplot* da variável TMC, observa-se que os valores contidos na amostra estiveram concentrados principalmente no quadrante 1 (Q1) ou Alto-Alto (*High-High*), que indica a presença de valores positivos/médias positivas e vizinhos com valores semelhantes.

26 Para estimar a significância do índice I Global de Moran, foi realizado o teste de pseudo-significância, com 999 permutações. A distribuição simulada do teste resultou em valor de $p\text{-value} = 0,001$, indicando que o conjunto de dados possui significância estatística e rejeitando a hipótese nula quanto à autocorrelação espacial (Druck *et alii*, 2004).



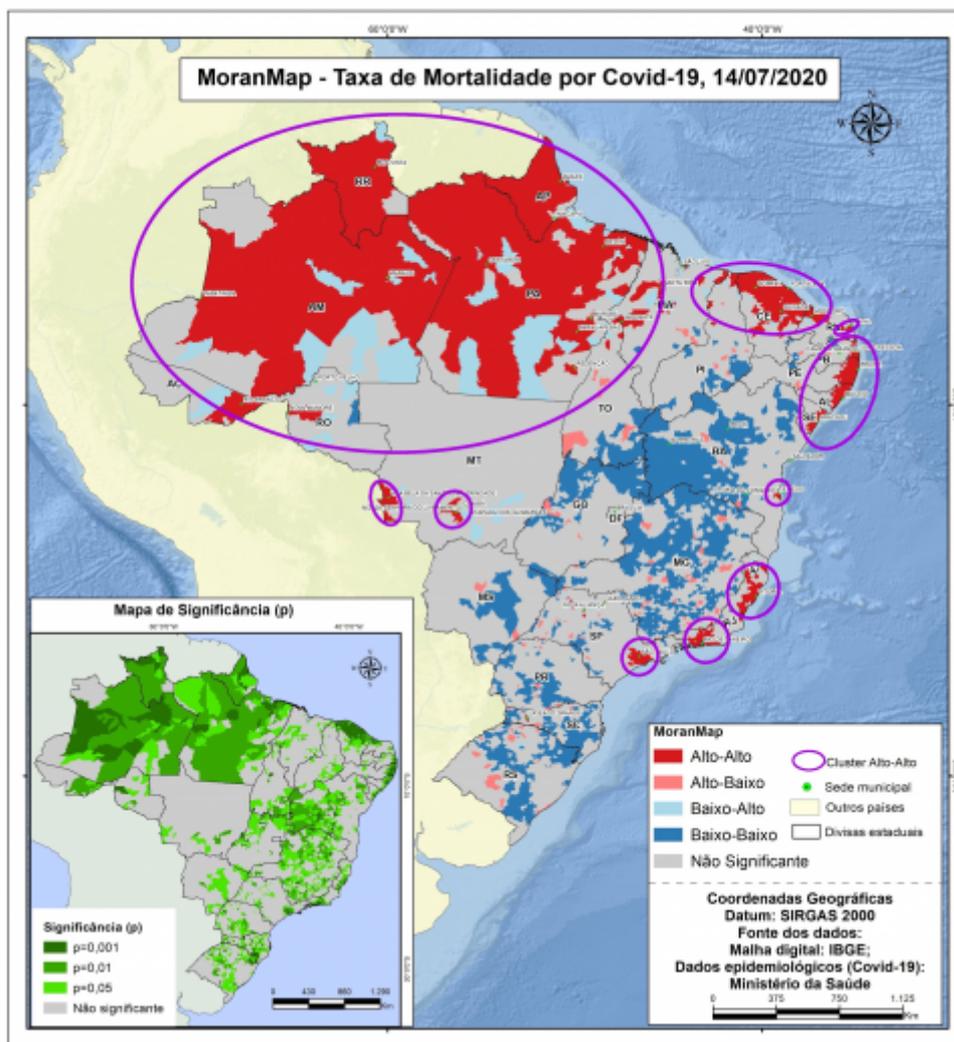
27 Após averiguação da significância quanto ao índice global, foi verificada a existência de associação espacial local. A partir do índice Local de Moran (LISA), investigou-se a existência de agrupamentos espaciais (*clusters*) relativos à variável TMC. Para

identificação da dependência espacial local, foram considerados os municípios com significância menor ou igual a 0,05 (95% a 99,9% de confiança). Dessa forma, no que se refere à significância do LISA, 1712 municípios (54,94% da amostra) apresentaram significância, sendo 998 municípios (32,03% da amostra) com significância de 0,05, 480 municípios (15,40% da amostra) com significância de 0,01 e 234 municípios (7,51% da amostra) com significância de 0,001.

- 28 Com base nos municípios com significância para o LISA, foi elaborado um *MoranMap*, subdividido em 5 classes: Alto-Alto, Alto-Baixo, Baixo-Alto, Baixo-Baixo e não significativa. As classes Alto-Alto e Baixo-Baixo são consideradas *clusters*, uma vez que são agrupamentos de municípios com valores médios semelhantes entre si. Na classe Alto-Alto estão presentes municípios com elevados valores de TMC e que possuem vizinhos com valores médios semelhantes, enquanto que na classe Baixo-Baixo estão presentes municípios com valores baixos de TMC e vizinhos com valores médios semelhantes.
- 29 As classes Alto-Baixo e Baixo-Alto compreendem municípios com valores de TMC com média de valores diferentes em relação aos seus vizinhos, ou seja, são *outliers*. Na classe Alto-Baixo estão os municípios com valores de TMC altos, mas com vizinhos com valores de TMC baixos, ao passo que na classe Baixo-Alto são compreendidos os municípios com valores baixos de TMC, mas com vizinhos com valores elevados no que diz respeito a variável estudada.
- 30 Os *clusters* mais significativos espacialmente, com altas taxas de mortalidade por COVID-19, estão localizados nas regiões Norte e Nordeste do Brasil. É também o recorte espacial onde ocorrem valores de significância mais expressivos. No Norte, os estados de Roraima, Amapá, Amazonas, Pará e leste do Acre abrangem a maior área contínua. Nesse *cluster* ainda estão inseridos territórios descontínuos do centro-oeste maranhense, norte do Tocantins e oeste de Roraima.
- 31 Na região Nordeste, destacam-se os *clusters* que abrangem continuamente parte do litoral setentrional, compreendendo a porção noroeste do estado do Rio Grande do Norte, estado do Ceará na porção centro-norte, fragmentos do litoral piauiense, bem como a capital Teresina, e fragmentos do território leste maranhense. O litoral Oriental do Nordeste também apresenta fragmento territorial expressivo, no entorno das capitais, se estendendo quase de forma contínua de Natal, no estado do Rio Grande do Norte, até Aracajú, em Sergipe.
- 32 As capitais do Nordeste que se apresentam como exceção aos altos valores de óbitos são Salvador (Bahia) e São Luís (Maranhão). Outros *clusters* de menor expressão espacial estão dispersos no território nacional, nos estados da Bahia (Ilhéus e adjacências), Mato Grosso, Espírito Santo, São Paulo e Rio de Janeiro.
- 33 Os *clusters* de baixa TMC são compostos por porções territoriais mais interiorizadas, com menores taxas demográficas e distantes das principais cidades do país, como é o caso do sudeste piauiense, centro-oeste baiano e norte de Goiás. Porções do sul e sudeste do país com melhores indicadores socioeconômicos também apresentaram baixa TMC até a data da coleta dos dados.
- 34 A partir da Figura 3 é possível visualizar a distribuição espacial das amostras com significância para associação espacial local – LISA e um *MoranMap* referente ao LISA para a variável TMC, com destaque para os *clusters* do tipo Alto-Alto identificados.

Figura 3: MoranMap para a variável TMC e Mapa de significância (p).





Fonte: Pereira; Rocha, Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.

- 35 A região Norte apresenta peculiaridades marcantes, pois não é um fragmento espacial com densidade demográfica significativa e possui no modal hidroviário importante meio de locomoção da população. Assim, a drenagem dos principais cursos fluviais irá conectar as principais cidades da região, podendo ser apontada como um fator relevante na disseminação do vírus.
- 36 Na região Nordeste, as áreas mais críticas estiveram de maneira geral concentradas no litoral. São agrupamentos espaciais marcados por adensamentos populacionais no entorno de capitais estaduais litorâneas e que apresentam como principal meio de mobilidade de pessoas os modais de transporte rodoviário. Assim, as principais cidades pertencentes a esses recortes espaciais no Nordeste estão conectadas por importantes eixos rodoviários. Estas questões relacionadas à distribuição da população e sua mobilidade através de diferentes modais de transporte apresentam-se como possíveis explicações para o delineamento das áreas com similaridade de altas taxas de mortalidade por COVID-19.
- 37 Outro fator explicativo é a Região de Influência das Cidades (REGIC), muito perceptível, por exemplo, no caso cearense, através da região de influência da cidade Fortaleza, capital do estado. Pereira *et alii* (2020) evidenciaram a influência dos principais centros de gestão do território (São Paulo, Rio de Janeiro, Fortaleza, entre outros) na disseminação da COVID-19 no Brasil. Segundo o referido estudo, a conformação dos fluxos entre municípios apontados pela REGIC (IBGE, 2020) fornece importante indício quanto à forma de disseminação do novo coronavírus ao longo do território brasileiro. Corroborando com o estudo de Pereira *et alii* (2020), a pesquisa realizada por Fortaleza *et alii* (2020) busca explicar a expansão geográfica da COVID-19 para cidades menores. Este estudo analisou taxas de incidência e mortalidade em 604 municípios do interior do estado de São Paulo e aponta como resultado dois padrões de distribuição da COVID-19 pelo interior do estado, o primeiro compreende a



área metropolitana indo para o interior do estado. O segundo vai dos centros urbanos de relevância regional para os municípios menores e menos conectados.

38 A abrangência da influência dos centros de gestão de território apontada pela REGIC também contribui para explicar a distribuição dos óbitos por COVID-19. Os maiores *clusters* de alta TMC incluem municípios da parte superior da hierarquia da rede urbana brasileira.

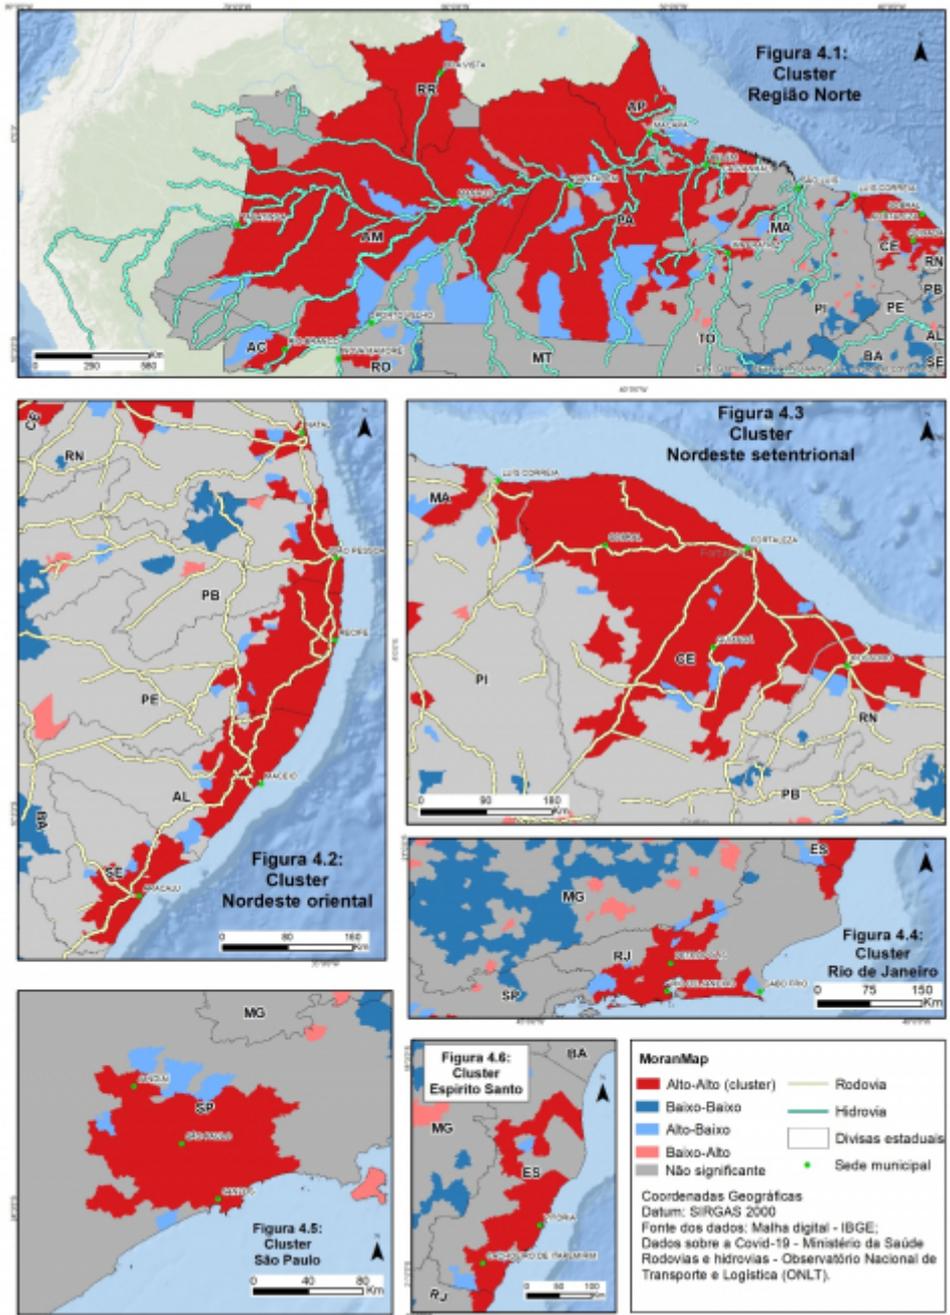
39 O maior *cluster* em extensão territorial e em número de municípios contíguos é o *cluster* denominado de “Região Norte”. Este *cluster* concentra 299 municípios contíguos da região Norte do Brasil, incluindo todas as suas capitais, exceto Porto Velho/RO e Palmas/TO.

40 Na região Nordeste foram identificados dois *clusters* principais em relação à contiguidade espacial. O *cluster* do “Nordeste Oriental” é o segundo maior *cluster* identificado, formado pelo agrupamento de 148 municípios contíguos, principalmente ao longo da rodovia BR-101 e adjacências. As capitais estaduais João Pessoa/PB, Recife/PE, Maceió/AL e Aracaju/SE fazem parte do referido *cluster*. O *cluster* do “Nordeste Setentrional” engloba 104 municípios contíguos dos estados do Ceará, Rio Grande do Norte e Piauí, incluindo a capital cearense, Fortaleza.

41 Na região Sudeste, é possível destacar 3 *clusters* de Alta TMC. Os *clusters* “São Paulo”, “Rio de Janeiro” e “Espírito Santo” são formados por agrupamentos de 44, 25 e 24 municípios, respectivamente. Esses *clusters* incluem as capitais estaduais: São Paulo/SP, Rio de Janeiro/RJ e Vitória/ES, além de outros municípios que exercem grande centralidade no contexto do direcionamento de fluxos de pessoas e mercadorias, como os municípios de Santos/SP e Jundiaí/SP. A partir da Figura 4 é possível visualizar os principais *clusters* de alta TMC identificados.

Figura 4: Maiores *clusters* relacionados à alta TMC até 14/07/2020.



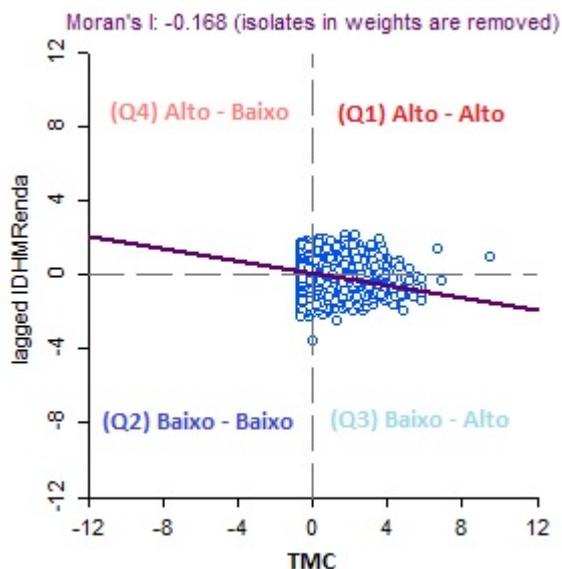


Fonte: Pereira; Rocha, Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.

42 Em se tratando da correlação entre variáveis socioeconômicas, investigou-se a influência da variável IDHM Renda na distribuição dos óbitos por COVID-19 até a data de referência do estudo. Neste sentido, com base no Índice I Global de Moran, observou-se autocorrelação espacial negativa, uma vez que o valor para o índice foi de -0,168 (Figura 5). Os resultados indicam, portanto, que as áreas que apresentam menores indicadores de renda são, em sua maioria, as que apresentaram maior TMC. Enquanto que as áreas com menor TMC são, predominantemente, as áreas com maior IDHM Renda.

Figura 5: Diagrama de espalhamento de Moran Bivariado para TMC e IDHM Renda.



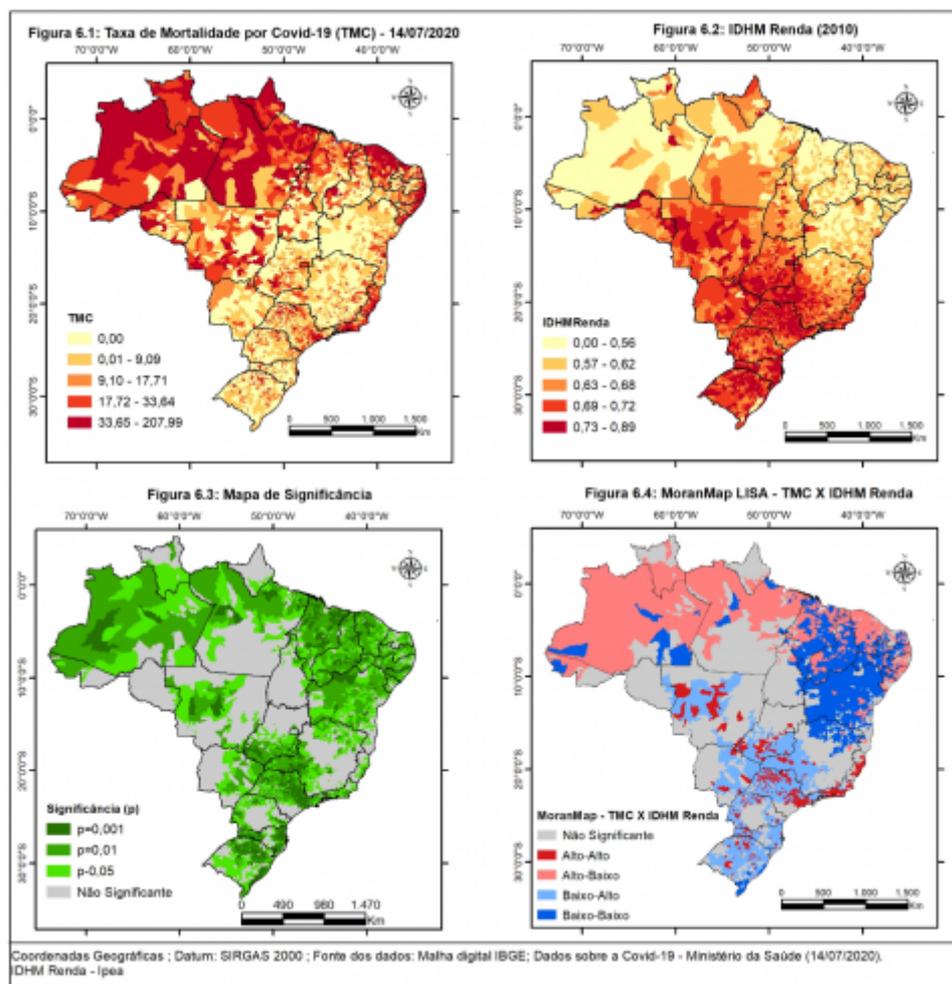


Fonte: Pereira; Rocha, Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.

- 43 Para verificação de autocorrelação espacial local entre as variáveis TMC e IDHM Renda, foi gerado um MoranMap bivariado, composto por *clusters* e *outliers* resultantes da distribuição dessas variáveis nos municípios de amostra. A classe Alto-Alto indica valores elevados para as duas variáveis e vizinhos com situação semelhante. A classe Alto-Baixo abrange os municípios com alta TMC e baixo IDHM Renda e vizinhos em situação semelhante. A classe Baixo-Alto indica municípios com valores baixos de TMC e valores altos de IDHM Renda. Por fim, a classe Baixo-Baixo é composta por municípios com valores baixos para as duas variáveis.
- 44 A porção territorial Norte-Nordeste apresenta, predominantemente, municípios com elevados números de óbitos a cada 100.000 habitantes e baixo valor de IDHM Renda, ao passo que na porção territorial Centro-Sul ocorre o predomínio de uma situação inversa, com baixos números relativos de óbitos por COVID-19 e altos valores para a variável IDHM renda.
- 45 A Figura 6 é uma coleção de mapas temáticos acerca da TMC até 14/07/2020, IDHM Renda (2010), Mapa de significância (p), considerando as variáveis TMC e IDHM Renda e o MoranMap LISA bivariado (TMC/IDHM Renda).

Figura 6: Significância para o LISA Bivariado entre TMC e IDHM Renda e MoranMap TMC X IDHM Renda.





Fonte: Pereira; Rocha, Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.

- 46 No Brasil, as TMC mais elevadas associadas à renda mais baixa (Alto-Baixo) estiveram nas regiões Norte e Nordeste nos mesmos *clusters* em que houve alta taxa de mortalidade nessas regiões. Na região Norte são as áreas interligadas pelas hidrovias às duas metrópoles da região, Belém e Manaus. No Nordeste existem dois grandes *clusters* com alta taxa de mortalidade, um setentrional, sob influência da metrópole Fortaleza, englobando cidades importantes como Mossoró/RN, Sobral/CE e Teresina, capital do Piauí; e outro mais oriental, sob influência do Recife, englobando também as cidades de João Pessoa, Maceió e Aracaju, capitais sob influência da metrópole Recife.
- 47 Pereira *et alii* (2020) identificaram que a pandemia entrou no Brasil e difundiu seus primeiros casos até o mês de março. Pode-se identificar que no mês de julho a difusão da pandemia se deu por meio de rodovias (no Nordeste) e hidrovias (no Norte) nas duas regiões onde estão localizados os *clusters* de alta taxa de mortalidade associada à baixo IDHM Renda.
- 48 Os *clusters* Baixo-Alto (Baixa TMC e Alto IDHM Renda) reforçam os resultados de auto correlação negativa entre as variáveis estudadas, indicando os municípios com renda elevada e poucos óbitos por Covid-19, sobretudo localizados na porção centro-sul do país. Os agrupamentos de baixa TMC e baixo IDHM Renda (Baixo-Baixo) estão concentrados no nordeste e norte de Minas Gerais, que são áreas com baixa incidência de casos de Covid-19 e estão mais distantes dos grandes centros de adensamento populacional.
- 49 Existem ainda três *clusters* bem delimitados onde ocorreram alta TMC associada ao alto IDHM Renda (Alto-Alto) no entorno das cidades de São Paulo, Rio de Janeiro e Vitória. Possivelmente a saturação do sistema de saúde dos estados de São Paulo, Rio de Janeiro e Espírito Santo explique esta associação. Com o relativo grande número de casos, há a tendência de redução da oferta de leitos de internação e um consequente aumento da dificuldade para o acesso ao serviço de saúde pública, sobretudo para a população com menor renda.



- 50 Damette e Goutte (2020) identificaram que o número de pessoas infectadas também é um preditor significativo da taxa de mortalidade por COVID-19, uma vez que um elevado número de casos em um curto intervalo temporal poderia levar os sistemas de saúde à saturação.
- 51 Cabe destacar que nesses *clusters* da região Sudeste, apesar do IDHM Renda elevado no contexto brasileiro, existem enormes bolsões de pobreza nas periferias urbanas, concentrando populações mais vulneráveis, que por sua vez responderam por grande parte dos óbitos registrados.
- 52 Os demais municípios onde o MoranMap apontou como “Alto-Alto” encontram-se de forma dispersa em municípios interioranos das Regiões Centro-Oeste, Sudeste e Sul. Vale pontuar que esta associação não foi identificada em nenhum município sequer das Regiões Norte e Nordeste, as mais pobres do país.

Considerações finais

- 53 As hipóteses norteadoras do estudo estavam relacionadas a: I - existe autocorrelação espacial da Taxa de Mortalidade por Covid-19 nos municípios brasileiros e II - existe autocorrelação espacial entre a Taxa de Mortalidade por Covid-19 e o IDHM Renda. Com base na metodologia adotada, os resultados evidenciaram que as duas hipóteses levantadas são verdadeiras.
- 54 Os padrões espaciais relativos à distribuição de óbitos por Covid-19 no Brasil, até a data de referência do estudo, estão relacionados à renda da população. Em áreas com maior adensamento populacional, sobretudo nos entornos dos principais centros de gestão do território no país, o grande número de infectados sobrecarregou o sistema de saúde e, conseqüentemente, reduziu a sua oferta. A vulnerabilidade/exposição à Covid-19 tende a ser ampliada para a população de menor renda, devido à necessidade urgente de obtenção de meios para sobrevivência e às condições incipientes de acesso aos instrumentos de prevenção ao contágio da doença.
- 55 A vulnerabilidade dessa população somada à necessidade de utilização de um sistema público de saúde saturado pela alta demanda e/ou não preparado adequadamente para o enfrentamento à pandemia são fatores relevantes para a compreensão da distribuição de óbitos por Covid-19 em grande parte dos municípios brasileiros.
- 56 Nesse sentido, os resultados revelam a necessidade de adoção de políticas públicas de assistência social voltadas para essas populações, de modo que as possam permitir o isolamento social e garantir o acesso das mesmas aos equipamentos de saúde.
- 57 Por fim, ressalta-se também a importância quanto à continuidade dos estudos voltados ao monitoramento da distribuição espacial de óbitos e casos da Covid-19, utilizando também recortes espaciais menores, permitindo assim, análises mais detalhadas sobre a pandemia.

Bibliographie

ALMEIDA, E. **Econometria Espacial Aplicada**. Alínea: Campinas/SP, 2012.

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

DOI : 10.1111/j.1538-4632.1995.tb00338.x

ANSELIN, L. Exploratory Spatial Data Analysis in a Geocomputational Environment. In: Longley, P. A.; Brooks, S. M.; MCDONNELL, R.; MACMILLIAN, B. **Geocomputation a primer**. Chichester: John Wiley & Sons Ltd, 1998, p.77-94.

BRASIL. Ministério da Saúde. Brasil confirma primeiro caso da doença. Agência Saúde, 26 de fevereiro de 2020. Disponível em: <https://www.saude.gov.br/noticias/agencia-saude/46435-brasil-confirma-primeiro-caso-de-novo-coronavirus>. Acesso em: 15 jul. 2020.



CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V. 2004. Análise espacial de áreas. In: DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. V. M. (eds.). **Análise Espacial de Dados Geográficos**. Brasília: EMBRAPA, 2004b.

CÂMARA, G.; MONTEIRO A. M.; CARVALHO, M. S. Análise Espacial e Geoprocessamento. In: Análise espacial de dados geográficos, eds. FUKS, S.D.; CARVALHO, M. S.; CÂMARA, G. A. M. V. – Divisão de Processamentos de Imagens – Instituto Nacional de Pesquisas Espaciais – São José dos Campos – Brasil. 2004a.

CAMPOS, A. C. P. et alii. Identificação da existência de padrão espacial aleatório na distribuição dos pacientes portadores de deficiência física decorrente de doença genética DAAACD de Pernambuco. **Rev. Bras. Biom.**, São Paulo, v.31, n.4, p.598-616, 2013.

CAVALCANTE, J. R.; ABREU, A. J. L. COVID-19 no município do Rio de Janeiro: análise espacial da ocorrência dos primeiros casos e óbitos confirmados. **Epidemiol. Serv. Saúde**, Brasília, v. 29, n. 3, e2020204, jun. 2020. doi: <http://dx.doi.org/10.5123/s1679-49742020000300007>.

DOI : 10.5123/s1679-49742020000300007

CARDOSO, P. V. et alii. A IMPORTÂNCIA DA ANÁLISE ESPACIAL PARA TOMADA DE DECISÃO: UM OLHAR SOBRE A PANDEMIA DE COVID-19. **Revista Tamoios**, v. 16, n. 1, 2020.

CONFINS, «Fatores associados a difusão da epidemia de Covid-19», *Confins* [Online], 46 | 2020, posto online no dia 05 julho 2020, consultado o 18 novembro 2021. URL: <http://journals.openedition.org/confins/31101>; DOI: <https://doi.org/10.4000/confins.31101>

DOI : 10.4000/confins.31101

DAMETTE, O.; GOUTTE, S. **The macroeconomic determinants of Covid19 mortality rate and the role of post subprime crisis decisions**. Disponível em SSRN: <https://ssrn.com/abstract=3610417>. Acesso em: 30. Maio. 2020.

DAYANG et alii. Dinâmica epidêmica espacial do surto de COVID-19 na China. **Revista Internacional de Doenças Infecciosas**, 2020.

DESJARDINS, M. R.; HOHL, A.; DELMELLE, E. M. Vigilância rápida do COVID-19 nos Estados Unidos usando uma estatística prospectiva de varredura no espaço-tempo: Detectando e avaliando clusters emergentes. **Geografia Aplicada**, p. 102202, 2020.

DE SOUZA OLIVEIRA, E.; DE MORAIS, A. C. L. N. Covid-19: uma pandemia que alerta à população. **InterAmerican Journal of Medicine and Health**, v. 3, p. 1-7, 2020.

DE SOUZA, C. D. F. et alii. Evolução espaçotemporal da letalidade por COVID-19 no Brasil, 2020. **Jornal Brasileiro de Pneumologia**, v. 46, n. 4, p. e20200208-e20200208, 2020.

DIAS, G. H. et alii. ANÁLISE DA DISTRIBUIÇÃO ESPACIAL DA COVID-19 E SUBNOTIFICAÇÃO DE CASOS NOVOS E ÓBITOS NO ESTADO DO RIO GRANDE DO NORTE, BRASIL. **PENSAR GEOGRAFIA**, v. 3, n. 2, p. 51-67, 2019.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. V. M. Análise espacial de dados geográficos. Brasília: EMBRAPA, 2004.

FARIA, A. H. P. et alii. Análise espacial aplicada ao estudo do crime: uma abordagem exploratória da distribuição dos atrativos para o crime no espaço urbano de Belo Horizonte. **Caderno de Geografia**, Belo Horizonte, v. 28, n. 55, p. 1006-1020, out. 2018. ISSN 2318-2962. doi: <https://doi.org/10.5752/P.2318-2962.2018v28n55p1006-102>

FORTALEZA, C.; GUIMARÃES, R.; DE ALMEIDA, G.; PRONUNCIATE, M.; FERREIRA, C. (2020). Taking the inner route: Spatial and demographic factors affecting vulnerability to COVID-19 among 604 cities from inner São Paulo State, Brazil. **Epidemiology and Infection**, 148, E118. doi:10.1017/S095026882000134X

DOI : 10.1017/S095026882000134X

FRANÇA, E. B. et alii. Óbitos por COVID-19 no Brasil: quantos e quais estamos identificando? **Revista Brasileira de Epidemiologia**, v. 23, p. e200053, 2020.

KAMEL-BOULOS, M. N., GERAGHTY, E. M. Geographical tracking and mapping of coronavirus disease COVID-19/severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) epidemic and associated events around the world: how 21st century GIS technologies are supporting the global fight against outbr. **Int J Health Geogr**. v.19, n.8, 2020; doi:10.1186/ s12942-020-00202-8.

KANG et alii. Spatial epidemic dynamics of the COVID-19 outbreak in China **Int. J. Infect. Dis.**, v. 94 , p. 96-102, 2020.

LAI et alii. Síndrome respiratória aguda grave coronavírus 2 (SARS-CoV-2) e doença do vírus corona-2019 (COVID-19): a epidemia e os desafios. **Revista internacional de agentes antimicrobianos**, p. 105924, 2020. <https://doi.org/10.1016/j.ijantimicag.2020.105924>.

DOI : 10.1016/j.ijantimicag.2020.105924

LUZARDO, A. J. R. et alii. Análise espacial exploratória com o emprego do Índice de Moran. **GEoGraphia**, vol. 19, n.40, p.162- 179, 2017. doi: 10.22409/GEOgraphia2017.v19i40.a13807

DOI : 10.22409/GEOgraphia2017.v19i40.a13807



MOREIRA, F. R. S. et alii. Spatial Analysis techniques applied to mineral prospecting: an evaluation in the Poços de Caldas Plateau. **Rev. bras. geociênc.**, vol. 33, n. 2 – Suplemento, jun. 2003. p. 183 - 190.

NARDI, S. M. T. et alii. Geoprocessamento em Saúde Pública: fundamentos e aplicações. **Revista do Instituto Adolfo Lutz**, v.72, n.3, p.185-191, 2013.

DOI : 10.18241/0073-98552013721562

ORGANIZAÇÃO PANAMERICANA DA SAÚDE (OPAS). **Folha informativa – COVID-19 (doença causada pelo novo coronavírus)**. Disponível em : <paho.org/bra/index.php?option=com_content&view=article&id=6101:covid19&Itemid=875> Acesso em: 14 jul.2020.

PEDROSA N. L.; ALBUQUERQUE, N. L. S. Análise espacial dos casos de Covid-19 e leitos de terapia intensiva no estado do Ceará, Brasil. **Cienc Saude Coletiva**. 2020, p. 1-19.

DOI : 10.1590/1413-81232020256.1.10952020

PEREIRA, V. H. C. et alii. IDENTIFICATION OF INITIAL COVID-19 IMPORT AND DISSEMINATION ROUTES IN BRAZIL. **Geosaberes**, Fortaleza, v. 11, p. 423-436, jul. 2020. ISSN 2178-0463. o. doi: <https://doi.org/10.26895/geosaberes.v11i0.1043>.

DOI : 10.26895/geosaberes.v11i0.1043

POURGHASEMI, H. R. et alii. Modelagem espacial, mapeamento de riscos, detecção de alterações e análise de tendências de surtos de coronavírus (COVID-19) no Irã (dias entre 19 de fevereiro e 14 de junho de 2020). **Revista Internacional de Doenças Infecciosas**, 2020.

ROSA, R. Análise espacial em geografia. **Revista da ANPEGE**, Dourados-MS, v. 7, n. 1, número especial, p. 275-289, out. 2011.

DOI : 10.5418/RA2011.0701.0023

SÁ, F. **Socioeconomic Determinants of COVID-19 Infections and Mortality: Evidence from England and Wales**. 2020. Disponível em SSRN: <https://ssrn.com/abstract=3612850>. Acesso em: 05. Junho. 2020.

SEFFRIN, R.; ARAUJO, E. C.; BAZZI, C. L. Análise espacial de área aplicada a produtividade de soja na região oeste do Paraná utilizando o software R. **R. bras. Geom.**, Curitiba, v. 6, n. 1, p. 23-43, jan/mar. 2018.

DOI : 10.3895/rbgeo.v6n1.5912

SHIM, E. et alii. Potencial de transmissão e gravidade de COVID-19 na Coreia do Sul. **Revista Internacional de Doenças Infecciosas**, 2020.

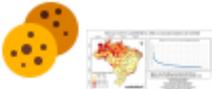
SILVA, A. N. et alii. **Sistemas de Informação Geográfica: Análise Espacial**. DGRM: Lisboa, Portugal, 2016.

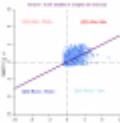
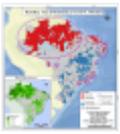
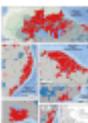
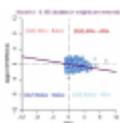
SILVA, R. B. L. DA; MONTANHER, O. C. Análise Espacial Aplicada ao Estabelecimento de Novos Varejos Alimentícios na Cidade de Maringá/PR: Estudo de Caso de Geomarketing. **Revista Brasileira de Cartografia**, v. 71, n. 4, p. 1135-1155, 13 dez. 2019.

WANG, Y. et alii. Unique epidemiological and clinical features of the emerging 2019 novel coronavirus pneumonia (COVID19) implicate special control measures. **J Med Virol**. 2020; 92:568–576. <https://doi.org/10.1002/jmv.25748576>.

WORLD HEALTH ORGANIZATION (WHO). **Coronavirus disease 2019 (COVID-19) Situation Report – 510**. Março 2020. Disponível em : <https://www.who.int/docs/defaultsource/coronaviruse/situation-reports/20200311-sitrep-51-covid19.pdf?sfvrsn=1ba62e57_10> Acessado em: 14 jul. 2020.

Table des illustrations

	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-1.png
	Fichier	image/png, 10k
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-2.png
	Fichier	image/png, 5,9k
	Titre	Quadro 2: Valores de significância para autocorrelação espacial considerados e respectivas cores no mapeamento temático.
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021).
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-3.jpg
	Fichier	image/jpeg, 42k
	Titre	Quadro 3: Descrição das classes do <i>MoranMap</i> e suas respectivas cores no mapeamento temático.
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021).
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-4.jpg
	Fichier	image/jpeg, 61k
	Titre	Figura 1: Óbitos por COVID-19 a cada 100.000 habitantes (TMC) nos municípios brasileiros até o dia 14/07/2020.

	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-5.png
	Fichier	image/png, 613k
	Titre	Figura 2: Diagrama de espalhamento de Moran/ <i>Moran Scatterplot</i> para a variável TMC.
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-6.png
	Fichier	image/png, 16k
	Titre	Figura 3: MoranMap para a variável TMC e Mapa de significância (p).
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-7.png
	Fichier	image/png, 5,2M
	Titre	Figura 4: Maiores <i>clusters</i> relacionados à alta TMC até 14/07/2020.
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-8.jpg
	Fichier	image/jpeg, 942k
	Titre	Figura 5: Diagrama de espalhamento de Moran Bivariado para TMC e IDHM Renda.
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-9.png
	Fichier	image/png, 50k
	Titre	Figura 6: Significância para o LISA Bivariado entre TMC e IDHM Renda e MoranMap TMC X IDHM Renda.
	Crédits	Fonte: Pereira; Rocha. Diniz e Oliveira Júnior(2021) com base nos dados da pesquisa.
	URL	http://journals.openedition.org/confins/docannexe/image/40509/img-10.png
	Fichier	image/png, 1,1M

Pour citer cet article

Référence électronique

Vítor Hugo Campelo Pereira, Glairton Cardoso Rocha, Marco Túlio Mendonça Diniz et Marcos Antonio Cavalcante de Oliveira Júnior, « Análise de dependência espacial da taxa de mortalidade por Covid-19 nos municípios brasileiros », *Confins* [En ligne], 52 | 2021, mis en ligne le 18 novembre 2021, consulté le 29 novembre 2021. URL : <http://journals.openedition.org/confins/40509>

Auteurs

Vítor Hugo Campelo Pereira

Universidade Federal do Rio Grande do Norte – UFRN, <http://orcid.org/0000-0002-8550-7016>, vitor.pereira95@yahoo.com.br

Glairton Cardoso Rocha

Instituto Federal de Educação, Ciência e Tecnologia do Piauí – IFPI, <http://orcid.org/0000-0002-1706-7338>, glairtongeo@ifpi.edu.br

Marco Túlio Mendonça Diniz

Universidade Federal do Rio Grande do Norte – UFRN, <http://orcid.org/0000-0002-7676-4475>, tuliogeografia@gmail.com



Marcos Antonio Cavalcante de Oliveira Júnior

Instituto Federal de Educação, Ciência e Tecnologia do Piauí – IFPI, <http://orcid.org/0000-0003-0630-4913>, marcos.cavalcante@ifpi.edu.br

Droits d'auteur



Confins – Revue franco-brésilienne de géographie est mis à disposition selon les termes de la licence Creative Commons Attribution - Pas d'Utilisation Commerciale - Partage dans les Mêmes Conditions 4.0 International.

